

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

张海波^① 荆昆仑^① 刘开健^{*①} 贺晓帆^②

^①(重庆邮电大学通信与信息工程学院 重庆 400065)

^②(武汉大学电子信息学院 武汉 430000)

摘 要: 在新兴的车联网络中, 汽车终端请求卸载的任务对网络带宽、卸载时延等有着更加严苛的需求, 而新型通信网络研究中移动边缘计算(MEC)的提出更好地解决了这一挑战。该文着重解决的是汽车终端进行任务卸载时卸载对象的匹配问题。文中引入了软件定义车载网络(SDN-V)对全局变量统一调度, 实现了资源控制管理、设备信息采集以及任务信息分析。基于用户任务的差异化性质, 定义了重要度的模型, 在此基础上, 通过设计任务卸载优先级机制算法, 实现任务优先级划分。针对多目标优化模型, 采用乘子法对非凸优化模型进行求解。仿真结果表明, 与其他卸载策略相比, 该文所提卸载机制对时延和能耗优化效果明显, 能够最大程度地保证用户的效益。

关键词: 车联网; 软件定义网络; 移动边缘计算; 卸载机制

中图分类号: TN929.5

文献标识码: A

文章编号: 1009-5896(2020)03-0645-08

DOI: [10.11999/JEIT190304](https://doi.org/10.11999/JEIT190304)

An Offloading Mechanism Based on Software Defined Network and Mobile Edge Computing in Vehicular Networks

ZHANG Haibo^① JING Kunlun^① LIU Kaijian^① HE Xiaofan^②

^①(School of Communication and Information Engineering, Chongqing University of Posts and Telecommunications, Chongqing 400065, China)

^②(School of Electronic Information, Wuhan University, Wuhan 430000, China)

Abstract: In the emerging vehicular networks, the task of the car terminal requesting offloading has more stringent requirements for network bandwidth and offload delay, and the proposed Mobile Edge Computing (MEC) in the new communication network research solves better this challenge. This paper focuses on matching the offloaded objects when the car terminal performs the task offloading. By introducing the Software-Defined in-Vehicle Network (SDN-V) to schedule uniformly global variables, which realizes resource control management, device information collection and task information analysis. Based on the differentiated nature of user tasks, a model of importance is defined. On this basis, task priority is divided by designing the task to offload the priority mechanism. For the multi-objective optimization model, the non-convex optimization model is solved by the multiplier method. The simulation results show that compared with other offloading strategies, the proposed offloading mechanism has obvious effects on delay and energy consumption optimization, which can guarantee the benefit of users to the greatest extent.

Key words: Vehicular networks; Software Defined Network (SDN); Mobile Edge Computing (MEC); Offloading mechanism

收稿日期: 2019-04-30; 改回日期: 2019-09-05; 网络出版: 2019-09-18

*通信作者: 刘开健 liukj@cqupt.edu.cn

基金项目: 国家自然科学基金(61801065, 61601071), 长江学者和创新团队发展计划基金(IRT16R72), 重庆市基础与前沿项目(cstc2018jcyjAX0463)

Foundation Items: The National Natural Science Foundation of China (61801065, 61601071), The Program for Changjiang Scholars and Innovative Research Team in University (IRT16R72), The General Project on Foundation and Cutting-edge Research Plan of Chongqing (cstc2018jcyjAX0463)

1 引言

伴随着汽车智能化发展趋势,越来越多的汽车和路边基础设施都装备了通信设备,车联网以及依托车联网发展衍生的相关应用已经成为未来发展的必然趋势^[1]。面对车联网的迅速发展,无线通信网络系统也将面临全新的挑战,例如计算密集型任务所导致的指数级增长的移动流量,新型服务应用对于更高延迟敏感度的需求等。为了解决上述所面临的挑战,将移动边缘计算(Mobile Edge Computing, MEC)集成到通信网络架构中是一个有效且合理的处理方案,该网络架构可以自适应地支持各种通信模式,并且能够利用虚拟化技术有效地实现资源共享^[2]。移动车载终端可以将计算密集型任务卸载到云端进行处理,基于云的车载网络是通过在远程云和本地车载终端之间分配计算任务从而来改善车辆服务的新场景。在支持云的网络中,通过集成通信和计算技术,应用程序既可以在本地运行,也可以卸载到远程计算云。而基于云的MEC卸载框架的提出能够进一步降低了任务持续时间,包括移动设备将任务卸载到云端的传输时间,云中的执行时间以及云发送的传输任务结果到移动设备的时间,同时减少移动设备的能耗、传输成本^[3-5]。

在任务处理方面,云计算和软件定义网络(Software Defined Network, SDN)架构对于提高车载网络的性能和灵活性具有重要意义。云计算的主要目的是为用户提供一种运行计算密集型应用程序的方法,这些应用程序不易在资源受限的移动设备上执行^[6]。文献^[7]提出了一种基于SDN的网络资源选择多目标优化模型,通过定制化资源分配方式,帮助用户实现选择资源、网络分配。文献^[8]基于SDN的核心思想将网络设备的控制面与数据面分离,研究了超密集网络中的任务卸载问题,将任务卸载问题表示为NP-hard的混合整数非线性程序,并将这个优化问题转化为任务放置问题和资源分配问题来进行解决。然而该文献目标优化模型较为单一,没有全面地考虑影响用户卸载的影响因子。

在基于MEC的网络架构中,关于资源分配的策略是研究热点。文献^[9]提出了一种基于分层云的车载边缘计算卸载框架,通过引入邻域中的备份服务器来解决MEC服务器计算资源有限问题。为了解决MEC服务分配问题,文献^[10]提出了一种基于Pareto的最优k-Medoids的动态服务分配算法,旨在找到平均网络延迟和负载平衡之间的权衡。文献^[11]提出了一种新的架构,它结合了远程中央云,附近的边缘计算服务器和车载云,以扩展车辆移动应用的可用云服务。文献^[12]为了解决车载网络的

安全问题,提出了信誉管理系统,服务提供商根据车辆的信誉来确定资源分配。文献^[13]研究了联合任务卸载和资源分配(Joint Task Offload and Resource Allocation, JTORA)问题,以便最大化用户的卸载增益。

上述文献主要着手解决用户终端计算资源不足,以及如何优化资源分配算法确保用户终端效益最大化等相关问题。但是关于任务具体卸载策略的研究较少,大多数文献默认卸载决策是在MEC服务器上执行,而且关于卸载任务类型没有明确划分,另一方面,关于移动终端自身能量问题的研究也鲜有涉及。因此,关于上述文献所面临的挑战,本文提出的基于SDN与MEC的卸载机制主要做了以下工作:

(1)在基于MEC的车联网络中引入SDN-V的概念,构建了一个新的任务卸载框架。实现了对全局信息变量的统一调度管理,获取汽车终端自身电池容量限制范畴;(2)在任务卸载的过程中,考虑到任务的多样性,根据目标优化函数的影响因子定义了关于任务的“重要度”的概念,对终端请求的任务分类,并且根据重要度的计算模型,设计了任务卸载优先级机制算法;(3)针对多目标优化模型,设计了基于Q-学习的任务决策机制算法,同时证明了目标函数的非凸性质,并且采用了拉格朗日乘子法求解,实现了最优的资源分配策略。

2 系统模型

2.1 系统分析

考虑到车辆、基站、路边单元与其附属的MEC服务器所构成的通信网络架构,定义服从Poisson分布的车辆用户集为 $V = \{v_1 v_2 \cdots v_m\}$,沿道路均匀分布的移动边缘云服务器集为 $B = \{b_1 b_2 \cdots b_n\}$,将车辆 v_i 请求的任务定义为 $Q_i = \{C_i, S_i\}$,其中 C_i 表示任务完成所需周期数, S_i 表示任务完成卸载所需资源量。 $t_i^{\max}$ 表示任务最大容忍时延, $e_i^{\max}$ 表示车辆用户最大剩余电量。 x_i 表示系统卸载决策,卸载决策由SDN-V控制器统一调度,当 $x_i = 1$ 时表示汽车终端请求的任务卸载到移动边缘云服务器 b_i ,当 $x_i = 0$ 时表示汽车终端请求的任务卸载到本地进行运算。

由于不同的车辆用户在任务请求卸载的过程中对时延、能耗、误码率、所需资源大小等约束条件的要求不同,因此为了更好地对任务的优先级进行划分,定义任务 Q_i 的重要度为 $\text{Imp}_i = \{\text{imp}_1 \text{imp}_2 \cdots \text{imp}_i\}$,重要度越大表示任务的优先级越高,意味着在多个任务同时请求卸载的过程中能够优先进行卸载。

在图1系统模型图中,描述了在SDN辅助下的车联网中基于MEC的卸载框架。系统模型图被划




图1 系统模型图

分为3个平面，分别是控制平面、数据平面、用户平面，其中控制平面是由控制基站构成，其主要功能就是完成车辆信息、任务信息、基站信息的收集，并完成控制管理；数据平面是由部署在道路一侧的路边单元及其附属的MEC服务器构成；用户平面就是指在道路上行驶的车辆用户。

本文所定义的SDN-V的概念本质上和SDN是一脉相承的，它们都是通过虚拟化将控制平面与数据平面分离^[14]。控制基站支持对整个路边单元的控制覆盖，资源分配和调度等主要控制功能集中在SDN-V控制器上^[8]。

2.2 计算与通信模型

(1) 本地卸载：当任务 Q_i 在本地卸载执行时，其计算时延 t_{mn}^l 为

$$t_{mn}^l = \frac{C_i}{f_v} \quad (1)$$

同时可以获得任务在车辆用户 v_i 卸载的能耗 e_{mn}^l 为

$$e_{mn}^l = p_v C_i \quad (2)$$

其中， f_v 表示车辆用户 v_i 的计算能力(单位时间内CPU周期数)， p_v 是指单位CPU周期内能耗功率。

(2) 边缘云卸载：当任务 Q_i 卸载到路边的MEC服务器时，其计算时延 t_{mn}^b 不仅要考虑到卸载时间，同时也要考虑到任务在进行上行传输，以及计算结果下行回传的时延。其中上行速率 $R_{m,n}$ 表达式为

$$R_{m,n} = B \log_2 \left(1 + \frac{p_i h_{m,n}}{\sigma^2 + I_{m,n}} \right) \quad (3)$$

其中， B 表示信道带宽， p_i 表示汽车用户功率， $h_{m,n}$ 表示车辆用户 v_i 与边缘云服务器 b_i 之间的信道增益， σ^2 表示汽车用户的噪声， $I_{m,n}$ 表示移动汽车用户与边缘服务器之间的干扰功率。

$$h_{m,n} = 127 + \lg(d_{mn}) \quad (4)$$

其中， d_{mn} 表示任务传输距离。边缘计算时延 t_{mn}^b 表示为

$$t_{mn}^b = \frac{C_i}{\theta_i f_b} + \frac{S_i}{R_{m,n}} \quad (5)$$

θ_i 表示当前任务卸载目标相对应的资源分配比例系数， f_b 表示MEC服务器的计算能力(单位时间内CPU周期数)。式(5)不包含下行回传时延，因为通常情况下边缘云将计算结果发送回移动设备的时间可以忽略。

车辆用户 v_i 进行任务卸载时的能耗 e_{mn}^b 为

$$e_{mn}^b = p_i \frac{S_i}{R_{m,n}} \quad (6)$$

2.3 问题形成

考虑到移动汽车用户在有限的电池容量内，最小化任务卸载时延以及传输能耗是需要优化的目标。前文已经定义了卸载决策变量 x_i ，因此 $X = \{x_1 x_2 \cdots x_n\}$ 与其相对应的服务节点 $B = \{b_1 b_2 \cdots b_n\}$ ，其中每个边缘云服务节点所对应的资源分配比例系数集合为 $\theta = \{\theta_1 \theta_2 \cdots \theta_n\}$ 。优化目标建模函数为

$$\begin{aligned} \min \quad & \sum_{i=1}^n \left\{ (1-x_i) \left[\lambda_i \frac{C_i}{f_v} + (1-\lambda_i) p_v C_i \right] \right. \\ & \left. + x_i \left[\lambda_i \left(\frac{C_i}{\theta_i f_b} + \frac{S_i}{R_{m,n}} \right) + (1-\lambda_i) p_i \frac{S_i}{R_{m,n}} \right] \right\} \\ \text{s.t.} \quad & \left. \begin{aligned} \text{C1: } & (1-x_i) e_{mn}^l \leq R_e E_{\max}^L, \quad \forall i = 1, 2, \dots, n \\ \text{C2: } & x_i e_{mn}^b \leq R_e E_{\max}^L, \quad \forall i = 1, 2, \dots, n \\ \text{C3: } & x_i \in \{0, 1\}, \quad \forall i = 1, 2, \dots, n \\ \text{C4: } & 0 < \theta_i \leq 1, \quad \forall i = 1, 2, \dots, n \\ \text{C5: } & t_{mn}^l \leq t_Q^{\max} \\ \text{C6: } & t_{mn}^e \leq t_Q^{\max} \\ \text{C7: } & 0 < \lambda_i < 1, \quad \forall i = 1, 2, \dots, n \end{aligned} \right\} \quad (7) \end{aligned}$$

其中, C1, C2表示任务上传功耗要小于汽车用户自身最大剩余能量 $R_e E_{\max}^L$; C3表示卸载决策属于01选择问题; C4表示MEC服务器资源分配比例系数属于0~1区间; C5和C6任务在本地以及边缘云服务器处理时延要小于该任务最大时延容忍度; C7表示关于时延以及能耗的权衡因子 λ_i 取值范围介于0~1之间。

式(7)的数学模型可以进一步简化(约束条件不变), 新的优化目标函数表示为

$$\min \sum_{i=1}^n \left\{ (1-x_i) [\lambda t_{mn}^l + (1-\lambda) e_{mn}^l] + x_i [\lambda t_{mn}^e + (1-\lambda) e_{mn}^b] \right\} \quad (8)$$

任务在进行卸载请求时, 基于SDN-V控制器的调度下, 首先通过重要度的概念对任务进行优先级划分, 并在此基础上确定卸载策略; 其次路边单元(RSU)对其服务范围内的车辆以比例 θ_i 进行资源分配; 然后利用Hesse矩阵的特征证明优化目标属于非凸优化问题; 最终利用拉格朗日乘子法对优化目标进行求解。

3 卸载决策机制与资源分配

3.1 卸载优先级

本文为了解决卸载决策的问题, 根据目标函数的影响因子定义了关于任务的“重要度”的概念。利用重要度的计算模型, 对终端请求的任务进行分类, 并在此基础上进一步确定任务的优先级。重要度的定义主要涉及到两个影响因子, 分别是完成该任务的最大时延约束以及完成计算任务资源量大小, 因此重要度的数学模型表示为

$$\text{imp}_i = \zeta \frac{C_i}{\sum_{i=1}^n C_i} + (1-\zeta) \frac{\sum_{i=1}^n t_{Q_i}^{\max}}{t_{Q_i}^{\max}}, 0 < \zeta < 1 \quad (9)$$

其中, ζ 表示关于任务时延以及所需资源量的权衡因子, $t_{Q_i}^{\max}$ 表示完成任务 Q_i 的最大时延限制。

在上述文献中提出了SDN-V控制器的概念,

它的主要功能包含对全局变量信息的控制, 因此通过SDN-V控制器能够统计出所有车辆用户的任务信息, 因此可以完成对卸载任务的重要度计算, 根据重要度 imp_i 的大小, 进而确定任务卸载优先等级以及卸载顺序。任务卸载优先级机制如表1所示。

3.2 基于Q-学习的卸载决策

在传统的卸载决策中, 卸载匹配对象单一化, 一般只涉及到关于本地卸载与边缘云卸载决策的研究。但是在实际应用中, 有些卸载任务对时延要求不是十分严格, 对计算资源的需求也相当有限。在这种场景下, 基于SDN-V辅助下的车联网系统可以将任务的一部分卸载交给本地计算处理, 剩余部分上传到边缘云计算, 这种卸载方式更加符合实际情况, 同时也能最大程度地保证用户的效益, 减少用户的卸载成本。

基于上述场景的研究, 车辆用户请求的任务由本地计算和边缘云协同卸载, 因此优化目标函数式(8)的卸载决策变量 x_i 需要引入新的决策变量 ψ_i 进行更新, 其中 $\psi_i \in (0, 1)$ 的比例因子。目标优化函数更新为

$$\min \sum_{i=1}^n \left\{ (1-\psi_i) \left[\lambda_i \frac{C_i}{f_v} + (1-\lambda_i) p_v C_i \right] + \psi_i \left[\lambda_i \left(\frac{C_i}{\theta_i f_b} + \frac{S_i}{R_{m,n}} \right) + (1-\lambda_i) p_i \frac{S_i}{R_{m,n}} \right] \right\} \quad (10)$$

为了计算卸载决策变量 ψ_i 的最优取值范围, 通过引入Q-学习算法解决这一挑战。Q-学习是一种典型的强化学习方法, 现有文献已经证明其具有收敛性, 它使代理人能够学习在给环境中遵循的最优策略。代理人能够估计每个状态-行动对的预期折扣奖励, 并选择使其实现最大化的行动^[15]。预期的累积奖励提供为

$$Z^\pi(s) = E_\pi \left[\sum_{t=0}^{\infty} \eta^t g_t(s, a) \right] \quad (11)$$

其中, η^t 是指折扣因子, g_t 是指从第 t 次迭代时, 在状态 s 的情况下, 通过策略 π 选择行为 a 获得的奖励。

表 1 任务卸载优先级机制

-
- | |
|--|
| (1) 输入: 车辆 i 的请求信息为 $\{C_i, S_i, t_{Q_i}^{\max}\}$, 定义 ζ 的取值, $i \in \{1, 2, \dots, n\}$, $\text{Imp}_i = \{\text{imp}_1, \text{imp}_2, \dots, \text{imp}_n\}$ |
| (2) 输出: 降序排列的重要度 imp_i |
| (3) for $i = 1; i < n; i++$ |
| (4) 将 $C_i, t_{Q_i}^{\max}$ 代入式(9)求出 imp_i |
| (5) $\text{Imp}_i = \{\text{imp}_1, \text{imp}_2, \dots, \text{imp}_i\}$ |
| (6) for $i = 1 : n$ do |
| (7) if $\text{Imp}(i) < \text{Imp}(i+1)$; temp = $\text{Imp}(i+1)$; $\text{Imp}(i+1) = \text{Imp}(i)$; $\text{Imp}(i) = \text{temp}$ |
| (8) end |
-

在此基础上可以通过引用一组行为和奖励来进行最优决策变量 ψ_i 的选择。行为 a_i 定义为 $a_i = [\psi_i, \lambda_i, \theta_i]$ ，由于每个行为都有被随机 p 的概率选择，因此行为可以表达为

$$a_i = \begin{cases} \arg \max_{i \in V} Q^*(a_i), & 1 - p \\ \text{随机}, & p \end{cases} \quad (12)$$

最优的选择策略 $\pi^* = \arg \max_{\pi} Z^{\pi}(s)$ ，Q-学习是采用Q函数作为评估函数，在此基础上最大化总预期回报函数表示为

$$Q^*(s) = E \left[g(s' | s, a) + \eta \max_{a'} Q^*(s', a') | s_0 = s, a_0 = a \right] \quad (13)$$

式(13)中 η 取值范围是(0~1)，它反映了未来回报相对于当前回报的重要性，如果它更倾向于0，代理人倾向于考虑即时奖励；如果更倾向于1，则更关注未来的改写。因此Q值的更新公式可以表示为

$$\hat{Q}_{t+1}(s, a) \leftarrow (1 - \varsigma) \hat{Q}_t(s, a) + \varsigma \left(g + \eta \max_{a'} \hat{Q}_t(s', a') \right) \quad (14)$$

其中， ς ($0 \leq \varsigma \leq 1$) 定义为学习率，表示当前知识对先前学习知识的影响。每个车辆用户奖励设置为

$$g_i^t = \min \sum_{i=1}^n \left\{ (1 - \psi_i) \left[\lambda_i \frac{C_i}{f_v} + (1 - \lambda_i) p_v C_i \right] + \psi_i \left[\lambda_i \left(\frac{C_i}{\theta_i f_b} + \frac{S_i}{R_{m,n}} \right) + (1 - \lambda_i) p_i \frac{S_i}{R_{m,n}} \right] \right\} \quad (15)$$

其中，分子表示车辆单一的在边缘云进行卸载的效益函数，分母表示车辆完全在本地进行卸载的效益函数。根据上述概念，制定了基于Q-学习的任务卸载策略机制，如表2所示。

在表2中 τ_1, τ_2 属于阈值门限，通过计算 imp_i 具

体数值与 τ_1, τ_2 进行对比，进而确定卸载决策，其中第(4)至(10)行伪代码是对目标函数的进一步更新，通过Q-学习算法求出以最优分配比例 ψ_i 。将传统的0, 1选择问题改进为按比例 ψ_i 分配的协同处理问题。

3.3 资源分配问题

根据式(8)可以求出目标函数是混合整数非线性优化问题(Mixed Integer Non-Linear Problem, MINLP)。当卸载决策变量 x_i 更新为 ψ_i ，此时的优化函数属于非线性优化问题。上述文献已经求出最优分配比例因子 ψ_i^* ，因此新的目标函数为

$$\min \sum_{i=1}^n \left\{ (1 - \psi_i^*) \left[\lambda t_{mn}^l + (1 - \lambda) e_{mn}^l \right] + \psi_i^* \left[\lambda t_{mn}^e + (1 - \lambda) e_{mn}^b \right] \right\} \quad (16)$$

将式(16)转化为关于变量 λ, θ_i 的2元1次函数

$$f(\lambda, \theta_i) = \sum_{i=1}^n \left\{ (1 - \psi_i^*) \left[\lambda t_{mn}^l + (1 - \lambda) e_{mn}^l \right] + \psi_i^* \left[\lambda t_{mn}^e + (1 - \lambda) e_{mn}^b \right] \right\} \quad (17)$$

引理1 在给定约束条件下，优化目标函数式(17)是一个非凸优化问题。

证明 假设优化目标函数式(17)是一个凸优化问题，当 $\psi_i = 1$ 时，目标函数式(17)的表达式为

$$f(\lambda, \theta_i) = \sum_{i=1}^n \left[\lambda \left(\frac{C_i}{\theta_i f_b} + \frac{S_i}{R_{m,n}} \right) + (1 - \lambda) p_i \frac{S_i}{R_{m,n}} \right] \quad (18)$$

其Hesse矩阵表达式为

$$\mathbf{H} = \begin{bmatrix} 0 & \frac{2\lambda C_i}{\theta_i^2 f_b} \\ \frac{2\lambda C_i}{\theta_i^2 f_b} & \frac{-C_i}{\theta_i f_b} \end{bmatrix} \quad (19)$$

其中，余子式 $|\mathbf{H}| = -\left(\frac{2\lambda C_i}{\theta_i^2 f_b} \right)^2$ ，余子式的值恒小

表 2 基于Q-学习的任务卸载策略机制

-
- | |
|--|
| (1) 输入：车辆 i 的请求信息 $\{Q_i, T_i\}$, τ_1, τ_2 , ($0 < \tau_1 < \tau_2$), $i \in \{1, 2, \dots, n\}$, $\text{Imp}_i = \{\text{imp}_1, \text{imp}_2, \dots, \text{imp}_i\}$ |
| (2) 输出： x_i, ψ_i |
| (3) if $\text{imp}_i < \tau_1$: $x_i = 0$; $\text{imp}_i > \tau_2$: $x_i = 1$ |
| (4) elif $\tau_1 < \text{imp}_i < \tau_2$: 初始化 $g, x_{ij} = 1, \varsigma, p, \hat{Q}(a_i) = 0, t = 0$ 最大收敛时间 $t_{c-\max}$ |
| (5) while $t < t_{c-\max} + 1$: 按照时延约束对车辆用户排序 |
| (6) for $i = 1 : N$ do |
| (7) 根据贪婪方法选择行为 a_i 、根据式(15)求出用户奖励 |
| (8) 更新 $\hat{Q}$ 数值矩阵通过 $\hat{Q}_{t+1}(s, a) \leftarrow (1 - \varsigma) \hat{Q}_t(s, a) + \varsigma \left(g + \eta \max_{a'} \hat{Q}_t(s', a') \right), p \leftarrow (p/\sqrt{t})$ |
| (9) end for; $t = t + 1$; end while |
| (10) 利用 ψ_i 更新目标优化式(7) |
| (11) end |
-

于0, 因此优化目标函数式(18)属于非凸优化问题。式(17)亦为非凸优化问题。证毕

拉格朗日乘子法求出目标函数最优解, 定义拉格朗日优化函数为

$$\begin{aligned} L(\theta_i, \lambda, V_1, V_2) &= \sum_{i=1}^n (1 - \psi_i^*) \left[\lambda \frac{C_i}{f_v} + (1 - \lambda) p_v C_i \right] \\ &+ \psi_i^* \lambda \left[\left(\frac{C_i}{\theta_i f_b} + \frac{S_i}{R_{m,n}} \right) + (1 - \lambda) p_i \frac{S_i}{R_{m,n}} \right] \\ &+ V_1 (1 - \lambda) + V_2 (1 - \theta_i) \end{aligned} \quad (20)$$

优化目标函数式(20) $L(\theta_i, \lambda, V_1, V_2)$ 在 θ_i^*, λ^* 取得极值的必要充分条件为

$$\left. \begin{aligned} \frac{\partial F}{\partial \theta_i} &= \lambda \frac{\psi_i^* C_i}{\theta_i f_b} - V_2 = 0, \\ \frac{\partial F}{\partial \lambda} &= (1 - \psi_i^*) \left(\frac{C_i}{f_v} - p_v C_i \right) + \psi_i^* \left(\frac{C_i}{\theta_i f_b} + \frac{S_i}{R_{m,n}} \right) \\ &\quad - \psi_i^* p_i \frac{S_i}{R_{m,n}} - V_1 = 0 \\ \frac{\partial F}{\partial v_1} &= (1 - \lambda) = 0, \quad \frac{\partial F}{\partial v_2} = (1 - \theta_i) = 0 \end{aligned} \right\} \quad (21)$$

其中, V_1, V_2 采用梯度下降法进行更新

$$\begin{cases} V_1(m+1) = V_1(m) + \mu_1(1 - \lambda) \\ V_2(m+1) = V_2(m) + \mu_2(1 - \theta_i) \end{cases} \quad (22)$$

$$\left. \begin{aligned} \frac{\partial F}{\partial \lambda} &= (1 - \psi_i^*) \left(\frac{C_i}{f_v} - p_v C_i \right) \\ &+ \psi_i^* \left[\left(\frac{C_i}{\theta_i f_b} + \frac{S_i}{R_{m,n}} \right) - p_i \frac{S_i}{R_{m,n}} \right] \\ &\quad - [V_1(m) + \mu_1(1 - \lambda)] = 0 \\ \frac{\partial F}{\partial \theta_i} &= \lambda \frac{\psi_i^* C_i}{\theta_i f_b} - [V_2(m) + \mu_2(1 - \theta_i)] = 0 \end{aligned} \right\} \quad (23)$$

上述公式联立可以得出关于 θ_i 的1元3次方程组

$$\begin{aligned} &- \mu_1 \mu_2 \theta_i^3 + (\mu_1 V_2(m) + \mu_1 \mu_2) \theta_i^2 \\ &- \frac{C_i}{f_b} \left[(1 - \psi_i^*) \left(\frac{C_i}{f_v} - p_v C_i \right) - (\mu_1 + \mu_2) \right. \\ &\quad \left. - \psi_i^* p_i \frac{S_i}{R_{m,n}} \right] \theta_i + \left(\psi_i^* \frac{C_i}{f_b} \right)^2 = 0 \end{aligned} \quad (24)$$

根据1元3次方程组的盛金公式进行重根判别, 并求出最优比例 θ_i^* 以及最优均衡因子系数 λ^* 为

$$\left. \begin{aligned} \theta_i^* &= \frac{-b - (\sqrt[3]{Y_1} + \sqrt[3]{Y_2})}{3a} \\ \lambda^* &= \frac{f_b [V_2(m) + \mu_2(1 - \theta_i^*)] \theta_i^*}{\psi_i^* C_i} \end{aligned} \right\} \quad (25)$$

4 仿真分析

在本节中, 基于MATLAB仿真平台对所提出的基于MEC服务器的卸载匹配机制进行验证。文

中相关参数是在IEEE 802.11p标准规定下的车联网场景以及移动边缘计算白皮书相关规定约束下设定。详细模拟参数如表3所示。

表3 模拟参数表

参数	数值
计算任务 Q_i	1~50 MB
传输带宽 W	100 MHz
汽车用户发射功率 p_i	0.2 W
任务所需CPU周期数 C_i	0.1~1 GHz
MEC服务器CPU周期频率 f_b	6 GHz
车辆用户的CPU周期频率 f_v	0.5~1 GHz
高斯噪声 σ^2	-100 dBm
信道传输距离 d_{mn}	5~500 m
汽车CPU能耗功率系数 p_v	80 W/GHz
电池最大容量	20 kWh

在仿真分析中主要选择随机卸载策略、统一卸载策略、文献[8]所设计的SDTO卸载策略进行对比。随机卸载策略是指随机生成等概率数字0, 1来模拟卸载决策; 统一卸载策略是指任务在卸载过程中, 预设好决策门限来确定卸载决策。在仿真的过程中, 为了模拟用户在现实应用的实际情况, 仿真所采用的模拟数据均是在设定的范围内随机生成, 并通过多次仿真尽量避免偶然误差。

图2、图3显示数据大小以及任务所需周期对于能耗的影响。随着数据大小的增加和任务所需周期的增加, 任务卸载的能耗也随之增加, 其中SDN-V卸载策略能耗表现优于另外3种策略。产生上述现象的原因是因为SDN概念的引入能够更加合理地实现全局变量的统一的调度。

图4, 图5是关于数据大小以及任务所需周期对卸载时延的影响, 随着数据大小以及任务所需周期数的增加, 任务卸载所产生的时延也随之增加。文中所采用的SDN-V卸载策略在减少时延方面, 明显优于另外3种卸载策略。导致上述仿真效果的主要原因是: 随着仿真数据的增加, 相较于传统模式




图2 数据大小与能耗关系图

机械化的卸载机制，基于SDN辅助地卸载机制能够更加灵活地资源调度，保证资源有效利用，减少任务卸载阻塞。由于SDTO策略缺少对能耗因子的优化，因此能耗因素对最终优化目标效果的影响逐渐增大。

图6、图7是任务数据大小以及任务所需周期数




图3 任务所需周期与能耗关系图




图4 数据大小与时延关系图




图5 任务所需周期与时延关系图




图6 数据大小与总开销关系图




图7 任务所需周期数与总开销关系图

对总开销的影响，总开销越低，优化效果越好。SDN-V卸载策略对目标函数的影响因子做了更加全面的优化，因此总的优化效益最好。意味着该卸载决策能够为汽车用户提供一种更低时延，更低能耗的卸载策略，最大程度的保证车辆用户的效益。

5 结束语

本文提出了车联网中基于SDN-V辅助的卸载对象匹配策略，旨在解决车辆用户请求任务在卸载过程中产生的时延以及能耗。本文考虑了任务多样性，定义了关于重要度的数学模型，并在此基础上设计了关于任务卸载顺序算法。构建了基于Q-学习算法的卸载决策，利用乘法法对目标函数进行优化求解。仿真结果表明，SDN-V卸载策略优化效果良好，目标函数的总开销显著降低。在未来的工作中，将继续深入研究关于卸载决策问题，建立一个基于本地、边缘云、远程云多维协作的卸载策略。

参考文献

- [1] 程刚, 郭达. 车联网现状与发展研究[J]. 移动通信, 2011, 35(17): 23-26. doi: 10.3969/j.issn.1006-1010.2011.17.004.
CHENG Gang, and GUO Da. Research on the status and development of internet of vehicles[J]. *Mobile Communications*, 2011, 35(17): 23-26. doi: 10.3969/j.issn.1006-1010.2011.17.004.
- [2] 齐彦丽, 周一青, 刘玲, 等. 融合移动边缘计算的未来5G移动通信网络[J]. 计算机研究与发展, 2018, 55(3): 478-486. doi: 10.7544/issn1000-1239.2018.20170801.
QI Yanli, ZHOU Yiqing, LIU Ling, et al. MEC coordinated future 5G mobile wireless networks[J]. *Journal of Computer Research and Development*, 2018, 55(3): 478-486. doi: 10.7544/issn1000-1239.2018.20170801.
- [3] LI Yong, JIN Depeng, HUI Pan, et al. Optimal base station scheduling for device-to-device communication underlying cellular networks[J]. *IEEE Journal on Selected Areas in Communications*, 2015, 34(1): 27-40. doi: 10.1109/JSAC.2015.2452415.
- [4] AMEMIYA K, AKIYAMA Y, KOBAYASHI K, et al. On-site evaluation of a software cellular based MEC system

- with downlink slicing technology[C]. The 7th IEEE International Conference on Cloud Networking, Tokyo, Japan, 2018: 1–7. doi: [10.1109/CloudNet.2018.8549380](https://doi.org/10.1109/CloudNet.2018.8549380).
- [5] WANG Hansong, LI Xi, JI Hong, *et al.* Dynamic offloading scheduling scheme for MEC-enabled vehicular networks[C]. 2018 IEEE/CIC International Conference on Communications in China, Beijing, China, 2018: 206–210. doi: [10.1109/ICCChinaW.2018.8674508](https://doi.org/10.1109/ICCChinaW.2018.8674508).
- [6] YU Rong, DING Jiefei, HUANG Xumin, *et al.* Optimal resource sharing in 5G-enabled vehicular networks: A matrix game approach[J]. *IEEE Transactions on Vehicular Technology*, 2016, 65(10): 7844–7856. doi: [10.1109/tvt.2016.2536441](https://doi.org/10.1109/tvt.2016.2536441).
- [7] 鲍楠, 左加阔, 胡晗, 等. 基于SDN的网络资源选择多目标优化算法[J]. 通信学报, 2019, 40(2): 51–59. doi: [10.11959/j.issn.1000?436x.2019031](https://doi.org/10.11959/j.issn.1000?436x.2019031).
BAO Nan, ZUO Jiakuo, HU Han, *et al.* SDN based network resource selection multi-objective optimization algorithm[J]. *Journal on Communications*, 2019, 40(2): 51–59. doi: [10.11959/j.issn.1000?436x.2019031](https://doi.org/10.11959/j.issn.1000?436x.2019031).
- [8] CHEN Min and HAO Yixue. Task offloading for mobile edge computing in software defined ultra-dense network[J]. *IEEE Journal on Selected Areas in Communications*, 2018, 36(3): 587–597. doi: [10.1109/JSAC.2018.2815360](https://doi.org/10.1109/JSAC.2018.2815360).
- [9] ZHANG Ke, MAO Yuming, LENG Supeng, *et al.* Optimal delay constrained offloading for vehicular edge computing networks[C]. 2017 IEEE International Conference on Communications, Paris, France, 2017: 1–6. doi: [10.1109/ICC.2017.7997360](https://doi.org/10.1109/ICC.2017.7997360).
- [10] HU Bo, CHEN Jianye, and LI fengcun. Dynamic service allocation algorithm in mobile edge computing[C]. 2017 International Conference on Information and Communication Technology Convergence, Jeju, South Korea, 2017: 104–109. doi: [10.1109/ICTC.2017.8190951](https://doi.org/10.1109/ICTC.2017.8190951).
- [11] LI Baozhu, ZHAO Xuhui, HAN Shiyuan, *et al.* New SDN-based architecture for integrated vehicular cloud computing networking[C]. 2018 International Conference on Selected Topics in Mobile and Wireless Networking, Tangier, Morocco, 2018: 1–4. doi: [10.1109/MoWNet.2018.8428935](https://doi.org/10.1109/MoWNet.2018.8428935).
- [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. doi: [10.1109/ACCESS.2017.2769878](https://doi.org/10.1109/ACCESS.2017.2769878).
- [13] TRAN T X and POMPILI D. Joint task offloading and resource allocation for multi-server mobile-edge computing networks[J]. *IEEE Transactions on Vehicular Technology*, 2019, 68(1): 856–868. doi: [10.1109/TVT.2018.2881191](https://doi.org/10.1109/TVT.2018.2881191).
- [14] JAIN R and PAUL S. Network virtualization and software defined networking for cloud computing: A survey[J]. *IEEE Communications Magazine*, 2013, 51(11): 24–31. doi: [10.1109/MCOM.2013.6658648](https://doi.org/10.1109/MCOM.2013.6658648).
- [15] WILHELM F, BELLALTA B, CANO C, *et al.* Implications of decentralized Q-learning resource allocation in wireless networks[C]. The 28th IEEE Annual International Symposium on Personal, Indoor, and Mobile Radio Communications, Montreal, Canada, 2017: 1–5. doi: [10.1109/PIMRC.2017.8292321](https://doi.org/10.1109/PIMRC.2017.8292321).

张海波: 男, 1979年生, 副教授, 研究方向为无线资源管理。

荆昆仑: 男, 1995年生, 硕士生, 研究方向为移动边缘计算。

刘开健: 女, 1981年生, 讲师, 研究方向为最优化算法。

贺晓帆: 男, 1985年生, 助理教授, 研究方向为无线资源优化。