

基于 5G 毫米波通信的高速公路车联网任务卸载算法研究

邱旭, 卞浩卜, 吴铭骁, 朱晓荣

引用本文

邱旭, 卞浩卜, 吴铭骁, 朱晓荣. 基于 5G 毫米波通信的高速公路车联网任务卸载算法研究[J]. 计算机科学, 2022, 49(6): 25-31.

QIU Xu, BIAN Hao-bu, WU Ming-xiao, ZHU Xiao-rong. Study on Task Offloading Algorithm for Internet of Vehicles on Highway Based on 5G MillimeterWave Communication[J]. Computer Science, 2022, 49(6): 25-31.

相似文章推荐 (请使用火狐或 IE 浏览器查看文章)

Similar articles recommended (Please use Firefox or IE to view the article)

[空中智能反射面辅助边缘计算中基于 PPO 的任务卸载方案](#)

PPO Based Task Offloading Scheme in Aerial Reconfigurable Intelligent Surface-assisted Edge Computing
计算机科学, 2022, 49(6): 3-11. <https://doi.org/10.11896/jsjcx.220100249>

[超密集物联网中多任务多步计算卸载算法研究](#)

Multi-Task and Multi-Step Computation Offloading in Ultra-dense IoT Networks
计算机科学, 2022, 49(6): 12-18. <https://doi.org/10.11896/jsjcx.211200147>

[面向铁路集装箱的高可靠低时延无线资源分配算法](#)

Wireless Resource Allocation Algorithm with High Reliability and Low Delay for Railway Container
计算机科学, 2022, 49(6): 39-43. <https://doi.org/10.11896/jsjcx.211200143>

[基于金字塔演化策略的彩色图像多阈值分割](#)

Multi-threshold Segmentation for Color Image Based on Pyramid Evolution Strategy
计算机科学, 2022, 49(6): 231-237. <https://doi.org/10.11896/jsjcx.210300096>

[面向集能型中继窄带物联网的非正交多址接入和多维网络资源优化](#)

Non-orthogonal Multiple Access and Multi-dimension Resource Optimization in EH Relay NB-IoT Networks
计算机科学, 2022, 49(5): 279-286. <https://doi.org/10.11896/jsjcx.210400239>

基于5G毫米波通信的高速公路车联网任务卸载算法研究

邱旭 卞浩卜 吴铭骁 朱晓荣

南京邮电大学江苏省无线通信重点实验室 南京 210003

(1460732039@qq.com)

摘要 随着车联网的快速发展,不断涌现的新型车载任务对通信、计算能力提出了更高的要求。5G毫米波基站的大量部署为高速公路车辆用户提供了更加高速可靠的服务。同时,移动边缘计算技术将具有计算和存储能力的MEC(Mobile Edge Computing)服务器部署在用户终端周围,为车载任务提供计算服务的同时降低了传输时延。文中针对高速公路场景下车辆任务的卸载决策及通信资源分配问题,将计算及通信资源联合优化问题建模为0-1混合整数线性规划问题。首先,将原优化问题解耦为资源块分配子问题及卸载决策子问题;其次,使用注水算法及粒子群算法分别对子问题进行求解;最后,基于启发式算法对子问题进行迭代求解,以获得最优的资源块分配方案及卸载决策向量。仿真结果表明,该算法可在满足所有车载任务需求的同时最小化系统平均时延。

关键词 任务卸载;资源分配;注水算法;粒子群算法

中图分类号 TN915.81

Study on Task Offloading Algorithm for Internet of Vehicles on Highway Based on 5G Millimeter Wave Communication

QIU Xu, BIAN Hao-bu, WU Ming-xiao and ZHU Xiao-rong

Jiangsu Key Laboratory of Wireless Communications, Nanjing University of Posts and Telecommunication, Nanjing 210003, China

Abstract With the rapid development of the Internet of vehicles, the emerging new types of in-vehicle tasks put forward higher requirements for communication and computing capabilities. The development of satellite communication technology and the large-scale deployment of 5G millimeter-wave base stations provide safer and more reliable services for highway vehicle users. At the same time, mobile edge computing technology deploys mobile edge computing (MEC) servers with computing and storage capabilities around user terminals to provide computing services for on-board tasks while reducing transmission delays. Aiming at the problem of offloading decision-making and communication resource allocation of vehicle tasks in highway scenarios, the joint optimization problem of computing and communication resources is modeled as a 0-1 mixed integer linear programming problem. Firstly, the original optimization problem is decoupled into the resource block allocation sub-problem and the offloading decision sub-problem. Secondly, the sub-problems are solved by using the water injection algorithm and the particle swarm algorithm. Finally, the sub-problems are iteratively solved based on the heuristic algorithm to obtain the optimal resource block allocation scheme and offload decision vector. Simulation results show that the algorithm minimizes the average system delay while meeting the requirements of all on-board missions.

Keywords Task offload, Resource allocation, Water injection algorithm, Particle swarm optimization

1 引言

车联网(Internet of Vehicles, IoV)技术作为新兴物联网技术的关键应用场景之一,是智慧交通的重要组成部分^[1]。无人智能驾驶、车载超清视频、增强现实等大量新型服务应用的不断涌现对车联网中的网络资源也提出了更高的要求。

由于云计算和边缘计算技术可以提供大量的计算和存储资源,因此车联网与边缘计算的结合弥补了车辆数据处理能力不足的问题,促进了车联网的发展^[2]。由于车辆用户本身具备一定的计算能力,在支持云计算的车联网架构中,车辆用户所产生的计算任务既可以在本地进行计算,也可以卸载至云端进行处理^[3]。而且移动边缘计算技术将具有计算及存储

到稿日期:2021-11-18 返修日期:2022-02-22

基金项目:国家自然科学基金(61871237,92067101);江苏省高校“青蓝工程”和江苏省重点研发计划(BE2021013-3)

This work was supported by the National Natural Science Foundation of China(61871237,92067101) and “Blue Project” of Universities in Jiangsu Province and Key R & D Program of Jiangsu Province(BE2021013-3).

通信作者:朱晓荣(xrzhu@njupt.edu.cn)

资源的 MEC 服务器部署在用户周围,进一步降低了车载任务的卸载时延。由于计算资源、通信和存储资源的紧密关联,在进行资源分配时不能只从单方面考虑,因此如何合理利用有限的计算、通信和存储资源为更多的用户提供多样化的服务,成为了目前车联网中亟需解决的关键问题之一。

目前国内外对车联网中移动边缘计算的研究工作主要集中在资源分配、计算卸载和内容缓存的策略研究上。文献[4]根据贝叶斯分类器对任务的分类结果为车辆用户设备选择合适的卸载模式,并提出了基于 Q-learning 的解决方案,实现了任务执行过程中延时要求和能量消耗之间的平衡。文献[5]提出了一种在线学习的方法以达到最小化任务时延的目的,在一定程度上缓解了移动边缘计算中资源有限的问题。文献[6]基于模拟退火算法,提出了一种任务卸载与资源分配方案,该方案对优先级较高的任务进行协同卸载计算处理。文献[7]研究了车辆的移动信息,并提出了一种考虑不同移动性模式和信道分布信息的迭代预测资源分配方案,提高了车联网中无线资源的利用率。文献[8]分析了 MEC 服务器中副本的成本及利润,提出了一种 MEC 自适应复制算法,在每个时间间隔内动态地调节副本,通过该算法将用户请求转发到相邻的 MEC 服务器,保证 MEC 服务器的负载均衡,此方案在缩短平均响应时间的同时提高了数据包的服务质量(Quality of Service QoS),可以获得更高的收益。安全相关应用的严格延迟要求是智能交通系统的一大挑战,文献[9]引入了感知反应时间(Perception-Reaction Time, PRT)的度量,并将以信息为中心的网络技术和雾虚拟化方法相结合,提出了一种新颖的雾资源调度机制来最小化 PRT。针对边缘计算中存在计算资源容易受到限制的问题,文献[10]提出了一种两个数据中心协同共享的方案,在任务请求的阻塞概率和服务时延方面均得到了很大的改善。文献[11]综合考虑了任务卸载过程中子任务的调度顺序和不同服务节点的处理顺序,提出了一种基于 DQN(Deep Q-Network)的任务调度与卸载方案,用于解决单车多个独立子任务的卸载问题。文献[12]提出了一种 MEC 服务器与用户终端匹配的组合拍卖机制,通过将任务卸载至最优的 MEC 服务器进行计算,以达到最短的任务完成时延。为了减轻边缘服务器的负载压力,文献[13]充分利用车辆自身的计算资源,提出了一种联合任务卸载和资源分配方案。车辆可以将产生的计算任务卸载至边缘服务器或其他车辆处进行处理。为了给高速移动的车辆用户提供高效稳定的数据传输,文献[14]提出了一种基于深度强化学习的预缓存和任务分配方法。文献[15]提出了一种基于预留的资源块(Resource Block, RB)分配方案,路边单元(Road Side Units, RSUs)根据可用 RB 的数量和服务请求的到达率,动态地为用户分配资源,以降低服务请求的拒绝率并提高 RB 利用率。车辆的高速移动性给通信的连续性带来了严峻的挑战,针对此问题,文献[16]将 MEC 服务器引入车辆网络设计了一种动态卸载调度方案。该方案综合考虑了车速、小区覆盖情况和数据传输速率等因素,求解出最优的卸载比例和传输单元。同时,该方案对车辆的移动速度和无线环境的变化

有很好的适应性,且在时延和能耗方面较大的提升。文献[17]对卸载决策问题和资源分配问题进行了联合优化,通过对优化问题的求解得到最优的通信资源及计算资源的分配方案,以降低整个系统的时延。文献[18]以最大化车载云计算系统的总长期预期回报为目标提出了一种最优计算资源分配方案。综合考虑车载云计算系统的收入和成本以及可用资源的可变性以得出系统奖励。将优化问题建模为具有车载云计算系统定义的状态空间、动作空间,奖励模型和转移概率分布的无限时域半马尔可夫决策过程,并利用迭代算法求解在特定状态下应该采取哪种动作的最优方案。文献[19]综合考虑了车辆计算资源的异构性和计算任务的独立性,提出了一种高效的调度方案。该方案将目标车辆产生的计算任务分割成多个独立的子任务并卸载至不同的车辆处进行处理,以任务完成时延为优化目标建立优化模型。Fei 等^[19]基于遗传算法提出了一个新的任务调度方案,该方案在有效提高车辆计算资源利用率的同时降低了问题求解的时间复杂度。

上述文献对通信与计算协同技术进行研究,其研究主要集中在一个 MEC 服务器同时服务多个车辆用户,而 MEC 服务器之间的协同计算很少被考虑到。为此,本文针对毫米波高速移动场景提出了一种通信与计算资源联合优化方案。该方案采用部分卸载策略,将车辆任务卸载至车辆本地和多个 MEC 服务器,以保证所有用户的平均任务完成时延最小。

2 系统模型

2.1 网络模型

高速公路系统模型如图 1 所示。在高速公路一侧按照一定的间隔部署 5G 毫米波微基站,微基站通过光纤连接到核心网。在高速公路车联网模型中,车辆通过 V2I(Vehicle-to-Infrastructure)技术与 5G 毫米波微基站通信,多个 5G 微基站构成一个簇,共享一个 MEC 服务器。MEC 服务器可以为车辆任务提供计算资源,缩短任务处理时延,降低车辆能耗。

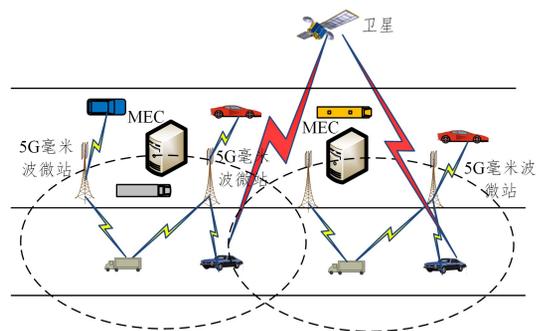


图 1 高速公路系统模型

Fig. 1 Highway system model

车辆在行驶过程中会产生需要大量计算资源的任务,这些任务可以在车辆本地处理,也可以通过 V2I 链路卸载到 MEC 服务器上处理。考虑到单个 MEC 服务器的计算资源有限,当 MEC 计算资源不足时,可将计算任务通过光纤卸载至相距一跳至两跳范围内的邻居 MEC 服务器上协同

计算,邻居 MEC 服务器集合为 $M = \{1, 2, \dots, m\}$ 。图 1 中, $N = \{1, 2, \dots, n\}$ 表示簇内车辆的集合,车辆的总数 $\psi = |N|$ 。假设车辆 n 产生的计算任务数据量为 s_n ,由于任务可以在本地进行处理,也可以卸载到多个 MEC 上进行处理,因此,本文将车辆产生的计算任务划分为多个子任务,进一步定义 $\lambda_n = [\lambda_0, \lambda_1, \dots, \lambda_m]$ 为任务的卸载比例向量, λ_0 表示在车辆本地处理的比例, λ_i 表示卸载到 MEC 服务器 i 上处理的比例。

2.2 通信模型

在上述场景中, $S = \{1, 2, \dots, s\}$ 表示簇内 5G 毫米波基站的集合,簇内可用资源块记为 $k \in K$,每个资源块的带宽为 ω_0 。假设簇内所有的 5G 毫米波基站共用这 K 个资源块服务其覆盖范围内的车辆。根据文献[17],在 60GHz 的毫米波环境下,车辆 n 与基站 i 在资源块 k 上的信道增益为:

$$h_{i,n}^k = 10\delta_{i,n} \lg(d_{i,n}) + \frac{15d_{i,n}}{1000} \quad (1)$$

其中, $\delta_{i,n}$ 表示车辆 n 与基站 i 之间的损失指数, $d_{i,n}$ 为车辆 n 与基站 i 之间的欧氏距离。此外, $15d_{i,n}/1000$ 表示 60GHz 的毫米波信号在大气中的衰减损耗。

因此,车辆 n 使用资源块 k 与基站 i 进行通信时,基站的信干噪比为:

$$SINR_{i,n}^k = \frac{p_n h_{i,n}^k}{\sigma_{n,k}^2 + I_{m,j}^k + I_0} \quad (2)$$

$$I_{m,j}^k = \sum_{\substack{m \in \psi, m \neq n \\ j \in \psi, j \neq i}} p_m h_{j,m}^k \quad (3)$$

其中, p_n 表示车辆 n 的最大发射功率, $\sigma_{n,k}^2$ 表示资源块 k 的高斯白噪声功率, $I_{m,j}^k$ 表示来自其他基站和车辆的干扰, φ 表示当前簇内的车辆与相邻簇内车辆的集合, φ 表示当前簇内的基站与相邻簇内基站的集合, I_0 表示来自卫星通信的干扰。

根据香农公式可知,基站 i 服务的车辆 n 使用子信道 k 时的数据传输速率为:

$$r_{i,n}^k = \omega_0 \alpha_{i,n}^k \log_2(1 + SINR_{i,n}^k) \quad (4)$$

其中, $\alpha_{i,n}^k$ 表示资源块分配指示因子。当 $\alpha_{i,n}^k = 1$ 时,表示 5G 毫米波基站 i 将资源块 k 分配给其服务车辆;当 $\alpha_{i,n}^k = 0$ 时,表示 5G 毫米波基站 i 未将资源块 k 分配给其服务车辆。

因此,基站 i 服务的车辆 n 的传输速率为:

$$r_{i,n} = \sum_{k \in K} r_{i,n}^k \quad (5)$$

由于车辆 n 产生的任务的数据量为 s_n ,且卸载到车辆本地进行处理的子任务量比例为 λ_0 ,因此卸载到 MEC 处进行处理的子任务数据量为 $(1 - \lambda_0)s_n$,不考虑 MEC 之间的子任务卸载时延。由于计算结果数据量较小,因此计算结果的接收时延可忽略。因此,基站 i 服务的车辆 n 将子任务卸载至 MEC 服务器的传输时延为:

$$D_{i,n}^t = \frac{(1 - \lambda_0)s_n}{r_{i,n}} \quad (6)$$

2.3 计算模型

由于车辆本身拥有一定的计算资源,车辆产生的计算任务可以在本地进行处理,也可以卸载至 MEC 服务器进行处理。为了提高计算资源的利用率,本文考虑将车载任务分成若干个子任务,由车辆及 MEC 服务器进行协同处理,以缩短任务处理时延。

2.3.1 本地计算模型

车辆本地处理数据量为 $\lambda_0 s_n$ 的子任务所需要的计算时延为:

$$D_n^l = \frac{\lambda_0 s_n C_n}{f_n} \quad (7)$$

其中, C_n 表示车辆每处理 1 bit 数据所需要的 CPU 周期数, f_n 表示车辆的计算资源。

2.3.2 MEC 服务器计算模型

MEC_i 服务器处理数据量为 $\lambda_i s_n$ 的子任务所需的计算时延为:

$$D_{MEC_i}^t = \frac{\lambda_i s_n C_{MEC_i}}{f_{MEC_i,n}} \quad (8)$$

其中, C_{MEC_i} 表示 MEC 服务器 i 每处理 1 bit 数据所需要的 CPU 周期数, $f_{MEC_i,n}$ 表示 MEC 服务器 i 分配给车辆 n 的计算资源。

2.4 排队模型

尽管 MEC 服务器的 CPU 计算能力远大于车辆终端,但同时 MEC 服务器具有较高的负载,当大量任务被卸载至 MEC 服务器进行处理时,可能会产生较高的排队时延,从而导致整个任务的处理时延增大。假设 MEC 服务器的任务处理可看作一个排队系统,任务平均到达率为 γ ,平均服务率为 μ ,服务密度为 ρ 。

将子任务卸载至 MEC 服务器处进行处理时,其排队等待时延为:

$$D_{MEC}^w = E(D_{MEC}^{queue} + D_{MEC}^{service}) \quad (9)$$

其中, D_{MEC}^{queue} 表示 MEC 服务器的平均排队时延, $D_{MEC}^{service}$ 表示 MEC 服务器的平均服务时延。

$$E(D_{MEC}^{queue}) = \frac{\rho}{1 - \rho} \frac{1}{\mu} \quad (10)$$

$$E(D_{MEC}^{service}) = \frac{1}{\mu} \quad (11)$$

由式(10)、式(11)可得:

$$D_{MEC}^w = \frac{1}{1 - \rho} \frac{1}{\mu} \quad (12)$$

因此,车辆 n 处理任务的总时延包括将子任务卸载至 MEC 服务器的传输时延、子任务在本地和在 MEC 服务器处的计算时延及排队时延,其表达式为:

$$D_n = \max \left\{ \frac{\lambda_0 s_n C_n}{f_n}, \frac{(1 - \lambda_0) s_n}{r_{i,n}} + \beta \max \left\{ \frac{\lambda_i s_n C_{MEC_i}}{f_{MEC_i,n}} + \frac{1}{1 - \rho} \frac{1}{\mu} \right\} \right\} \quad (13)$$

其中, $\beta = \begin{cases} 1, & \lambda_0 \neq 1 \\ 0, & \lambda_0 = 1 \end{cases}$ 表示当任务全部在车辆处进行处理时, MEC 服务器不产生计算和排队时延。

2.5 优化目标

在上述场景中,车辆通过 5G 毫米波基站将产生的计算任务部分卸载至 MEC 服务器进行处理。车辆获得的通信资源、计算资源及卸载比例联合决定了业务的完成时间,因此本文以所有车辆任务完成时间的均值为优化目标,同时考虑了基站的通信资源,建立了如下的优化模型:

$$\begin{aligned}
P_0: & \min \frac{1}{\lambda_n \cdot \alpha_{i,n}^k} \sum_{n \in N} D_n & (14) \\
\text{s. t. } & C_1: \alpha_{i,n}^k \in \{0, 1\}, \forall i \in S, n \in N, k \in K \\
& C_2: \lambda_i \in [0, 1], \forall i \in MU \setminus \{0\} \\
& C_3: \sum_{i=0}^m \lambda_i = 1, \forall i \in MU \setminus \{0\} \\
& C_4: \sum_{n \in N_i, k \in K} \alpha_{i,n}^k \leq |K|, \forall i \in S \\
& C_5: \sum_{n \in N_i} \alpha_{i,n}^k \leq 1, \forall i \in S, k \in K \\
& C_6: D_n \leq \frac{d}{v_n}, \forall n \in N \\
& D_n = \max \left\{ \frac{\lambda_0 s_n C_n}{f_n}, \frac{(1-\lambda_0) s_n}{r_{i,n}} + \right. \\
& \quad \left. \beta \max \left\{ \frac{\lambda_i s_n C_{MEC_i}}{f_{MEC_{i,n}}} + \frac{1}{1-\rho} \frac{1}{\mu} \right\} \right\}
\end{aligned}$$

其中,约束条件 C_1 限制了资源块分配指示因子只能是二元变量,约束条件 C_2 表示卸载比例因子的取值范围,约束条件 C_3 表示对于车辆 n 其卸载比例因子和为 1,约束条件 C_4 表示分配给车辆的资源块数之和不能超过基站处可用的资源块数量,约束条件 C_5 表示基站 i 不能为其服务的用户分配相同的资源块,约束条件 C_6 限制了车辆必须在规定的距离内完成计算任务, d 表示规定的距离, v_n 表示车辆的平均速度。

3 优化问题求解

由于优化变量资源块分配指示因子是一个二元变量,而卸载比例因子是一个连续的变量,因此优化问题 P_0 是一个 0-1 混合整数非线性规划问题。优化变量在约束条件 C_5 中耦合,常规的凸优化算法难以直接使用来对问题进行求解。本文考虑将优化问题 P_0 分解为资源块分配子问题和卸载决策子问题分别进行求解。

3.1 资源块分配子问题

优化问题 P_0 的目标是最小化车辆计算任务的完成时间,而对于车辆用户来说,资源块的分配则是为了得到最优的数据传输速率,从而缩短数据上传至 MEC 服务器的时间。首先对每个车辆用户的任务卸载比例向量进行初始化,假设计算任务在车辆及各 MEC 之间均匀分配,即 $\lambda_i = 1/(m+1)$ 。在得到卸载比例向量后,可通过约束条件 C_6 计算求出车辆的最小数据传输速率 $r_{i,n}^{\min}$ 。

$$r_{i,n}^{\min} \geq \frac{(1-\lambda_0) s_n}{\frac{d}{v_n} - \max \left\{ \frac{\lambda_i s_n C_{MEC_i}}{f_{MEC_{i,n}}} + \frac{1}{1-\rho} \frac{1}{\mu} \right\}} \quad (15)$$

本文假设车辆用户的接入是已知的,因此簇内基站使用注水算法对其服务的用户进行第一阶段的资源块分配。首先计算所有用户在占用不同资源块时的 SINR 值,基站优先将 SINR 值最高的资源块分配给其服务的用户。若该资源块已经被分配给了其他用户使用,则基站从剩余的资源块中选择 SINR 值最大的资源块分配给用户。在第一阶段资源块分配完成后,计算所有用户的数据传输速率,对数据传输速率未达到要求的用户进行第二阶段的子信道分配,直至每个车辆用户的数据传输速率都满足要求。若第二阶段结束后仍有资源块剩余,则将车辆用户按数据传输速率升序排列,依次给数据

传输速率较小的车辆用户分配 SINR 值最大的资源块,直至所有的资源块被分配完成,以保证用户间的公平性。

算法 1 基于注水算法的资源块分配算法

1. 初始化阶段。簇内可用资源块 $k \in K$; 簇内 5G 毫米波基站集合表示为 $S = \{1, 2, \dots, s\}$; N_i 表示接入基站 i 的车辆数; U_i 表示基站 i 服务的车辆未满足数据传输速率要求。
2. 计算阶段。计算每个基站的用户在 K 个资源块上的 SINR 值。
3. 第一阶段资源块分配
4. for $i = 1 : s$
5. for $n = 1 : N_k$
6. $\alpha_{i,n}^k = \operatorname{argmax} \text{SINR}_{i,n}^k$
7. 将 $\alpha_{i,n}^k$ 分配给车辆 n , 同时更新资源块集合, 令 $K = K/k$
8. end
9. end
10. 计算基站 i 服务车辆的数据传输速率, 并将不满足要求的用户添加进集合 U_i
11. for $n = 1 : N_i$
12. if $r_{i,n} \leq r_{i,n}^{\min}$
13. $U_i = U_i \cup n$
14. end
15. 对未满足传输速率的用户进行第二阶段资源块分配
16. for $n \in U_i$
17. $\alpha_{i,n}^k = \operatorname{argmax} \text{SINR}_{i,n}^k$
18. 将 $\alpha_{i,n}^k$ 分配给车辆 n , 同时更新资源块集合, 令 $K = K/k$ 。
19. end
20. 重复步骤 10—步骤 19 直到所有用户满足数据传输速率要求。
21. 计算基站 i 服务用户的数据传输速率并按升序排序, 将第二阶段分配后剩余的资源块分配给传输速率较小的车辆用户, 以保证用户的公平性。

3.2 卸载决策子问题

通过资源块分配子问题的求解可以得到每个车辆用户最优的数据传输速率, 因此原优化问题 P_0 可转换为关于卸载比例向量的优化问题。

$$\begin{aligned}
P_1: & \min_{\lambda} D_n & (16) \\
\text{s. t. } & C_1: \lambda_i \in [0, 1], \forall i \in MU \setminus \{0\} \\
& C_2: \sum_{i=0}^m \lambda_i = 1, \forall i \in MU \setminus \{0\} \\
& C_3: D_n \leq \frac{d}{v_n}, \forall n \in N
\end{aligned}$$

本文采用粒子群算法对上述子问题进行求解。假设车辆用户可卸载的 MEC 服务器的数量为 M , 即搜索空间维度为 $M+1$, 初始化产生 L 个粒子表示, 表达式如下:

$$W^{(l)} = (\lambda_0, \lambda_1, \dots, \lambda_m) \quad (17)$$

其中, $l = 1, 2, \dots, L$, 每个粒子按照自己的飞行速度搜索最优的解, 粒子 l 经过的个体最优位置记为 $(p_{l0}, p_{l1}, \dots, p_{lm})$, 整个群体中所有粒子经过的最优位置记为 $(p_{g0}, p_{g1}, \dots, p_{gm})$, 粒子的速度和位置按式(18)进行更新:

$$v_d^{(l)}(t+1) = \omega v_d^{(l)}(t) + c_1 r_1 (p_{ld}(t) - W_d^{(l)}(t)) + c_2 r_2 (p_{gd}(t) - W_d^{(l)}(t)) \quad (18)$$

$$W_d^{(l)}(t+1) = W_d^{(l)}(t) + v_d^{(l)}(t+1) \quad (19)$$

由于原始粒子群算法前期的收敛速度快,并且随着迭代次数的增加,种群多样性不断减少而造成停滞现象,因此存在局部最优解问题。权重系数 c_1 用于表示粒子的认知能力,粒子会向自身历史最优的位置移动。因此,本文通过在迭代求解的过程中动态非线性地增大 c_1 来使粒子的学习能力不断增强,解决了过早收敛的问题。学习因子 c_1 按式(20)进行更新:

$$c_1 = c_{1\min} + (c_{1\max} - c_{1\min}) \frac{t}{T} \quad (20)$$

其中, $c_{1\min}$ 为 c_1 的最小值, $c_{1\max}$ 为 c_1 的最大值, t 为当前迭代次数, T 为设置的最大迭代次数。

在求解过程中,不断调节粒子的位置并更新其速度,使用户以最短的时间完成业务。本文以用户的业务完成时间 D_n 为适应度函数 U_n ,来更新粒子最优的位置。当前全局最优粒子位置的效用函数值为 U_g^{opt} ,粒子 l 经历过的最优位置效用函数值为 U_l^{opt} ,粒子的全局最优位置记为 W_g^{opt} ,粒子 l 经历过的最优位置记为 W_l^{opt} ,算法的具体步骤如算法2所示。

算法2 基于粒子群优化的卸载比例向量算法

1. 初始化阶段:随机初始化产生1个粒子 $W^{(1)}(t)$,设置 $U = U_n, U_g^{\text{opt}} = \min U^{(1)}(t)$
2. 当 $t \leq T$ 时
3. for $l = 1 : L$
4. 计算当前粒子的适应值 $U^{(l)}(t)$
5. if $U^{(l)}(t) \leq U_l^{\text{opt}}$
6. 更新个体最优: $U_l^{\text{opt}} = U^{(l)}(t), W_l^{\text{opt}} = W^{(l)}(t)$
7. end
8. end
9. 将每个粒子的适应值与全局最优效用函数值进行比较,以更新全局最优位置:
10. $U_g^{\text{opt}} = \min U_l^{\text{opt}}, W_g^{\text{opt}} = \min W_l^{\text{opt}}$
11. for $l = 1 : L$
12. 更新权重 $c_1 = c_{1\min} + (c_{1\max} - c_{1\min}) \frac{t}{T}$
13. 更新粒子速度 $v^{(l)}(t+1) = \omega v^{(l)}(t) + c_1 r_1 (W_l^{\text{opt}}(t) - W^{(l)}(t)) + c_2 r_2 (W_g^{\text{opt}}(t) - W^{(l)}(t))$
14. 更新粒子位置 $W^{(l)}(t+1) = W^{(l)}(t) + v^{(l)}(t+1)$
15. end
16. $t = t + 1$
17. end

3.3 资源块和卸载向量联合优化算法

算法1在固定卸载比例向量后,基于注水算法得到了最优的资源块分配策略,算法2基于算法1的结果,使用粒子群算法求得最优的卸载比例向量。本文基于上述算法,提出了一种资源块和卸载比例向量联合优化算法,算法的具体流程如算法3所示。

算法3 资源块和卸载向量联合优化算法

1. 初始化卸载比例向量 $\lambda = \left\{ \frac{1}{m+1}, \frac{1}{m+1}, \dots, \frac{1}{m+1} \right\}$,随机初始化产生1个粒子 $W^{(1)}(t)$ 。
2. 通过算法1求解得到最优的资源块分配策略。

3. 通过算法2求解得到最优的卸载比例向量。

4. 若优化问题 P_1 目标函数不收敛,则跳转至步骤2。

算法3的时间复杂度主要取决于每一轮迭代过程中步骤2和步骤3的时间复杂度,算法1对每一个用户遍历资源块集合以找到最优的资源块,同时对不满足速率要求的用户进行第二阶段的资源块分配,因此步骤2的时间复杂度为 $O(|S| |N_k| + |U_i|)$ 。算法2提出的粒子群算法是一个循环迭代的过程,在每一轮迭代中,每个粒子计算自身的效用值并对其最优效用值进行更新,同时全局最优位置选择效用值最好的粒子的位置。每个粒子还需要对其速度和位置进行更新,因此步骤3的时间复杂度为 $O(2LT)$ 。综上所述,假设算法3经过 \max_ite 次达到收敛,则算法3的时间复杂度为 $O((|S| |N_k| + |U_i| + 2LT) \max_ite)$ 。

4 仿真分析和性能评估

本文利用python对资源块和卸载向量的联合优化算法的性能进行了仿真验证,具体的仿真参数如表1所列。

表1 仿真参数设置

Table 1 Simulation parameters setting	
仿真参数	参数设置
任务数据/Gbit	0.5~1
MEC的CPU处理能力/GHz	30
本地终端CPU处理能力/GHz	5
处理1bit所需CPU周期	1440
任务到达率	0.2~0.3
信道带宽/MHz	800
可用资源块数目	50
车辆终端发射功率/mW	50
噪声功率谱密度/(dBm/Hz)	-174

4.1 仿真环境与参数设置

系统带宽设置为800MHz,每个5G毫米波微基站可分配的资源块数量为50,则每个资源块的带宽为16MHz。微基站的覆盖半径设置为30m,假设车辆的到达过程服从泊松分布,车辆的速度为28m/s。噪声功率谱密度为-174(dBm/Hz),车辆的计算能力设置为5GHz,MEC服务器的处理能力为30GHz,MEC服务器的任务平均到达率为0.2~0.3,平均服务率为0.35~0.45,车辆终端的上行发射功率为50mW。

4.2 基于Q学习的快速卸载算法

综合考虑时延和能耗两个因素,将车辆终端效益作为优化目标建立优化模型。文献[20]提出的基于Q学习的快速卸载算法,将车辆终端制定卸载决策后获得的即时奖励与经验奖励相结合对累积折扣奖励进行更新,最终获得最佳的资源分配方案和任务卸载策略,以最大化车辆终端的效益。

4.3 仿真结果与分析

图2给出了粒子种群规模对算法收敛情况的影响。从图中可以看出,当种群规模较小时,算法的收敛速度较慢且存在陷入局部最优解的风险。当种群规模增大时,本文算法有较好的优化能力且收敛速度快,但当种群数目增长至一定水平时,将不再有显著的作用。

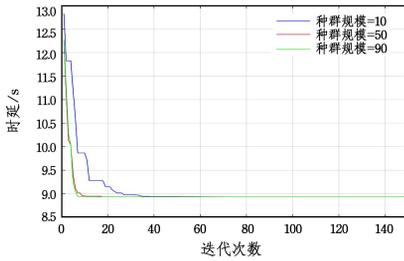


图2 不同种群规模对比图

Fig. 2 Comparison of different population sizes

图3给出了几种算法在任务处理时延上的差异。各算法的任务处理时延随着任务数据量的增大而增大。当将任务全部卸载至 MEC 服务器时,由于未充分利用车辆本地的计算资源,造成 MEC 服务器的任务负载过大,从而增大了任务传输时延和排队时延。而基于 Q 学习的快速卸载算法在车辆终端每经过一个 MEC 服务器服务区域时都要进行卸载决策,因此要进行多次任务卸载,增大了任务处理时延。此外,在输入的任务数据量一致时,本文算法充分利用了车辆本地的计算资源和 MEC 服务器的资源,因此可以实现最小的处理时延。

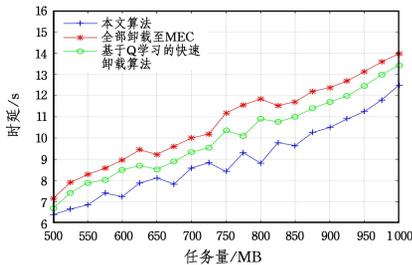


图3 不同算法的任务处理时延对比图

Fig. 3 Comparison of task processing delay of different algorithms

图4给出了在任务平均到达率不同时,车辆任务处理时延的差异。从仿真结果可以看出,随着任务平均到达率的提高,任务处理时延也随之增加,主要原因是随着任务平均到达率的提高,MEC 服务器的任务负载也随之增大,导致任务堆积,从而增大了排队时延。

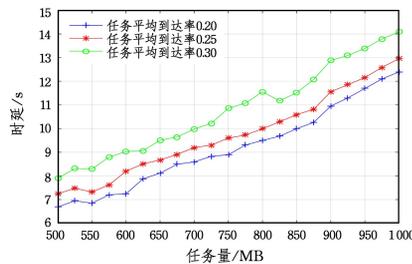


图4 不同任务平均到达率的对比图

Fig. 4 Comparison of average arrival rate of different tasks

图5给出了各算法在不同车速情况下任务的处理情况。从仿真结果可以看出,各算法的任务处理时延并未随着车速的加快而产生上升或下降的趋势,而是在某一值附近波动,这表明本文算法有较好的稳定性。

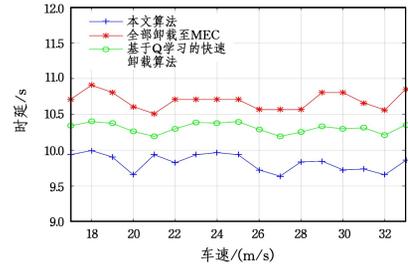


图5 不同车速的对比图

Fig. 5 Comparison of different speeds

图6给出了在 MEC 服务器平均服务率不同的情况下,车辆任务处理时延的差异。平均服务率表示单位时间内 MEC 服务器能够服务的用户数量。随着平均服务率的提高,MEC 服务器处堆积的任务数量减少,从而任务的排队时延降低。从图中可以看出,当任务量为 800 M 且平均服务率为 0.35 时,任务处理时延分别减少了 8.3% 和 22.1%。

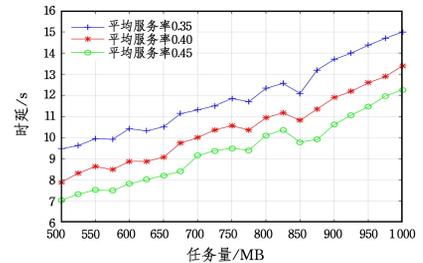


图6 不同平均服务率对比图

Fig. 6 Comparison of different average service rates

结束语 本文主要研究了毫米波高速移动场景下,车辆任务的卸载决策与资源块分配问题,并提出了一种资源块和卸载向量的联合优化算法,从而求解出最优的资源块分配策略和卸载向量,以达到所有用户平均任务处理时延最小化的目的。由于原优化问题是一个 0-1 混合整数非线性规划问题,因此本文将分解为资源块分配子问题和卸载决策子问题,并使用注水算法和粒子群算法分别对其求解,以得到最优的策略。相比其他算法,本文提出的资源块和卸载向量联合优化算法充分利用了车辆本地和 MEC 服务器的计算资源,因此可达到较小的任务处理时延。

参考文献

- [1] LEE U, CHEUNG R, GERLA M. Emerging Vehicular Applications[J/OL]. Vehicular Networks: From Theory to Practice, 2009; 6: 1-6. 30. <http://citeseerx.ist.psu.edu/viewdoc/download;jsessionid=30C299E6B1F2AD3CD8FD3C6A44ABE72?doi=10.1.1.459.2888&rep=rep1&type=pdf>.
- [2] YANG Y, BAGRODIA R. Evaluation of VANET-based Advanced Intelligent Transportation Systems[C]// The 6th ACM International Workshop on Vehicular Internet Working. ACM, 2009; 3-12.
- [3] SASAKI K, SUZUKI N, MAKIDO S, et al. Layered vehicle control system coordinated between multiple edge servers[C]// 2017 IEEE Conference on Network Softwarization (NetSoft). Bologna; 2017; 1-5.

- [4] JIANG F, LIU W, WANG J, et al. Q-Learning Based Task Offloading and Resource Allocation Scheme for Internet of Vehicles [C]//2020 IEEE/CIC International Conference on Communications in China (ICCC). 2020:460-465.
- [5] KAO Y, KRISHNAMACHARI B, RA M, et al. Hermes: Latency Optimal Task Assignment for Resource-constrained Mobile Computing[J]. IEEE Transactions on Mobile Computing, 2017, 16(11):3056-3069.
- [6] LI Z, XUE J B. Task offloading and resource allocation based on simulated annealing algorithm in C-V2X Internet of Vehicles [J/OL]. Computer Applications: 1-11. <http://www.joca.cn/CN/10.11772/j.issn.1001-9081.2021081490>.
- [7] XUE N, ZHANG H, ZHANG C, et al. Data-Driven Energy Efficient Predictive Resource Allocation in Internet of Vehicles [C]//2020 International Conference on Wireless Communications and Signal Processing (WCSP). 2020:56-61.
- [8] CHANG W, WANG P. Adaptive Replication for Mobile Edge Computing[J]. IEEE Journal on Selected Areas in Communications, 2018, 36(11):2422-2432.
- [9] CHEN X, LENG S, ZHANG K, et al. A machine-learning based time constrained resource allocation scheme for vehicular fog computing[J]. China Communications, 2019, 16(11):29-41.
- [10] BERALDI R, MTIBAA A, ALNUWEIRI H. Cooperative load balancing scheme for edge computing resources[C]//2017 Second International Conference on Fog and Mobile Edge Computing (FMEC). Valencia, 2017:94-100.
- [11] YU Z, TANG Y, ZHANG L, et al. Deep Reinforcement Learning Based Computing Offloading Decision and Task Scheduling in Internet of Vehicles[C]//2021 IEEE/CIC International Conference on Communications in China (ICCC). 2021:1166-1171.
- [12] ZHANG H, GUO F, JI H, et al. Combinational auction-based service provider selection in mobile edge computing networks [J]. IEEE Access, 2017, 5:13455-13464.
- [13] FAN W, LIU J, HUA M, et al. Joint Task Offloading and Resource Allocation for Multi-Access Edge Computing Assisted by Parked and Moving Vehicles[J/OL]. IEEE Transactions on Vehicular Technology, 2022. <https://ieeexplore.ieee.org/stamp/stamp.jsp?tp=&arnumber=9709120>.
- [14] MA T, CHEN X, MA Z, et al. Deep Reinforcement Learning for Pre-caching and Task Allocation in Internet of Vehicles[C]//2020 IEEE International Conference on Smart Internet of Things (SmartIoT). 2020:79-85.
- [15] ZHANG J, CHEN X, SUN Y, et al. Reservation based Resource Allocation Scheme for Internet of Vehicles [C]//2021 IEEE 93rd Vehicular Technology Conference (VTC2021-Spring). 2021:1-5.
- [16] WANG H, LI X, JI H, et al. Dynamic Offloading Scheduling Scheme for MEC-enabled Vehicular Networks[C]//2018 IEEE/CIC International Conference on Communications in China (ICCC Workshops). IEEE, 2018.
- [17] ZHENG K, MENG H, CHATZIMISIOS P, et al. An SMDP-Based Resource Allocation in Vehicular Cloud Computing Systems[J]. IEEE Transactions on Industrial Electronics, 2015, 62(12):7920-7928.
- [18] MOLINA M, MUÑOZ O, PASCUAL-ISERTE A, et al. Joint scheduling of communication and computation resources in multiuser wireless application offloading[C]//2014 IEEE 25th Annual International Symposium on Personal, Indoor, and Mobile Radio Communication (PIMRC). 2014:1093-1098.
- [19] FEI S, HOU F, NAN C, et al. Cooperative Task Scheduling for Computation Offloading in Vehicular Cloud[J]. IEEE Transactions on Vehicular Technology, 2018, 67:11049-11061.
- [20] YAMAMOTO A, OGAWA K, HORIMATSU T, et al. Path-Loss Prediction Models for Intervehicle Communication at 60 GHz[J]. IEEE Transactions on Vehicular Technology, 2008, 57(1):65-78.
- [21] WU L Q. Research on Mobile Edge Computing Task Offloading and Resource Allocation Management [D]. Nanjing: Nanjing University of Posts and Telecommunications, 2020.



QIU Xu, born in 1995, postgraduate. His main research interests include task offloading and resource allocation in Internet of vehicles.



ZHU Xiao-rong, born in 1977, Ph. D. professor, Ph. D supervisor. Her main research interests include 5G communication system, heterogeneous network and Internet of Things.

(责任编辑:柯颖)