

基于 DQN 的车载边缘网络任务分发卸载算法

赵海涛^{1,2,3}, 张唐伟^{1,2,3}, 陈跃^{1,2,3}, 赵厚麟^{1,2,3}, 朱洪波^{1,2,3}

(1. 南京邮电大学教育部泛在网络健康服务系统工程研究中心, 江苏 南京 210003;
2. 南京邮电大学江苏省无线通信重点实验室, 江苏 南京 210003;
3. 南京邮电大学通信与信息工程学院, 江苏 南京 210003)

摘要:为实现车辆终端用户任务执行时延与处理速率、能耗的最佳均衡关系, 针对车联网的边缘接入环境, 提出了一种基于深度 Q 网络 (DQN) 的计算任务分发卸载算法。首先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, 从而为计算任务处理速率赋予不同的权重建立关系模型; 然后引入基于深度 Q 网络的边缘计算方法, 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; 最后建立基于 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。仿真结果表明, 相比 Q 学习算法, 所提算法有效提高了任务执行效率。

关键词: 车联网; 移动边缘计算; 计算卸载; 深度 Q 网络; 计算速率

中图分类号: TP399

文献标识码: A

doi: 10.11959/j.issn.1000-436x.2020160

Task distribution offloading algorithm of vehicle edge network based on DQN

ZHAO Haitao^{1,2,3}, ZHANG Tangwei^{1,2,3}, CHEN Yue^{1,2,3}, ZHAO Houlin^{1,2,3}, ZHU Hongbo^{1,2,3}

1. Ministry of Education Ubiquitous Network Health Service System Engineering Research Center, Nanjing 210003, China

2. Jiangsu Key Wireless Communication Laboratory, Nanjing 210003, China

3. College of Communication and Information Engineering, Nanjing University of Posts and Telecommunications, Nanjing 210003, China

Abstract: In order to achieve the best balance between latency, computational rate and energy consumption, for a edge access network of IoV, a distribution offloading algorithm based on deep Q network (DQN) was considered. Firstly, these tasks of different vehicles were prioritized according to the analytic hierarchy process (AHP), so as to give different weights to the task processing rate to establish a relationship model. Secondly, by introducing edge computing based on DQN, the task offloading model was established by making weighted sum of task processing rate as optimization goal, which realized the long-term utility of strategies for offloading decisions. The performance evaluation results show that, compared with the Q-learning algorithm, the average task processing delay of the proposed method can effectively improve the task offload efficiency.

Key words: IoV, MEC, computational offloading, DQN, computational rate

收稿日期: 2020-04-17; 修回日期: 2020-06-13

基金项目: 国家自然科学基金资助项目 (No.61771252); 江苏省自然科学基金资助项目 (No.BK20171444); 江苏省高等学校自然科学基金资助项目 (No.18KJA510005); 江苏省科技成果转化专项基金资助项目 (No.BA2019058); 江苏省“333 高层次人才培养工程”基金资助项目 (No.JSCX17_0224)

Foundation Items: The National Natural Science Foundation of China (No.61771252), The Natural Science Foundation of Jiangsu Province (No.BK20171444), The Major Natural Science Research Project of Jiangsu Higher Education Institutions (No.18KJA510005), Jiangsu Province Special Fund Project for Transformation of Scientific and Technological Achievements (No.BA2019058), The Object of Jiangsu Province “333 High-level Talent Training Project” (No.JSCX17_0224)

1 引言

作为 5G 移动通信代表性应用场景之一，车联网及自动驾驶已经成为热点研究领域，在未来将会经历前所未有的发展^[1]。随着车联网等技术的快速发展及数据量的日益庞大，大量对计算资源高需求的车载应用任务随之出现，如自动驾驶、智能识别、实时路况等^[2]。这些车载应用任务不仅需要大量的存储与计算资源，同时对于任务执行时延的要求非常严格，给现有车载设备的通信能力、计算能力带来了很大的挑战^[3]。为了解决车辆终端与车载应用任务之间的矛盾，融合移动边缘计算（MEC, mobile edge computing）的协同通信技术被引入车联网中^[4]。车辆终端携带的计算任务可以卸载到路边单元（RSU, road side unit）配置的 MEC 服务器上，在车辆终端旁边就能够完成任务的计算及分析，有效缓解了车辆终端计算、存储资源不足的困境，减小了计算任务的处理时延与车辆终端能耗^[5]。针对任务迁移和资源调度问题，国内外进行了大量相关研究。文献[6]对通信与计算融合技术的机遇与挑战做了大量的介绍，并针对“边缘智能”提出了具体的实施方案。然而，动态的车联网场景给 MEC 技术的大规模应用带来了许多问题，车辆终端的高速移动及通信参数的变化导致计算任务卸载决策复杂化^[7]。

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、能耗及时延与能耗的权衡等^[8]。文献[9]提出了一种面向 5G 的边缘计算多用户卸载方案，将问题转换为多重背包问题，有效降低了任务执行时延。文献[10-12]基于各种数值优化算法，提出了一系列计算卸载决策及资源配置方案。基于马尔可夫决策过程理论（MDP, Markov decision process）的强化学习方法，如 Q 学习算法、深度强化学习（DRL, deep reinforcement learning）方法如深度 Q 网络（DQN, deep Q network）也被研究人员用来解决卸载问题。文献[13]构建了马尔可夫决策过程函数，解决了车辆终端由于 MEC 服务器服务范围不足而导致的服务中断问题，解决了单纯基于距离进行卸载服务的不足，但是该方法在卸载过程中没有对服务方的时延、能耗等成本进行合理的评估。文献[14]提出了一种基于 DQN 的多用户单小区计算卸载与资源分配算法，联合优化任务执行时延与能耗的加权和，实现了任务

总成本的下降。与其他方法明显不同的是，DQN 可以在没有任何先验信息的前提下与环境进行交互，从中学习并调整卸载策略以达到最佳的长期回报^[15-16]，这对于动态时变的车联网环境来说尤其重要。

上述方法都没有针对不同车辆终端进行任务优先级划分，从而不能实现处理程序的优化。同时这些方法需要实时准确的信道状态消息，算法复杂度高、迭代步骤长，难以满足时延敏感型的车联网通信系统。针对以上研究中存在的问题，本文通过引入移动边缘计算，根据车辆终端任务属性的不同进行优先级划分，使车辆终端携带的计算任务能够在边缘节点进行处理；在车辆终端，基于 DQN 研究了计算速率最优的任务卸载策略，在信道条件时变的环境中能够根据过去的经验实现卸载策略的自我更新，从而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。

2 系统模型

本文选取车辆终端、RSU 与其连接的 MEC 服务器所构成的网络通信模型。由于车辆终端的快速移动，车联网网络拓扑架构会产生动态变化。为了满足时延要求，车辆终端将其携带的计算任务迁移至 RSU 连接的 MEC 服务器中。这产生了 2 个问题，具体如下。

1) 卸载决策的制定问题。由于计算任务的类型、信道增益均不相同，如果将计算任务统一卸载到 MEC 服务器，在信道增益很差的情况下会造成非常严重的传输时延问题，同时车辆终端计算资源也得不到充分利用，导致计算资源浪费。因此本文根据车辆终端信道实时状态制定卸载决策，将部分车辆终端的计算任务卸载至边缘侧服务器，从而降低计算任务处理时延、提高计算资源利用率。

2) 计算资源分配问题。系统会根据业务类型分配优先级，但是相同类型业务由于其属性的不同，也可能具有不同的优先级需求，因此，必须在计算资源分配之前根据计算任务属性的不同进行预处理，否则相同的卸载决策会导致 MEC 服务器不能合理分配计算资源，影响用户使用体验。

车联网环境下的计算任务卸载模型架构如图 1 所示。在该模型架构中，受限于较弱的计算能力，部分车辆终端会将自身携带的计算任务通过无线网络卸载到 RSU 连接的 MEC 服务器进行处理。首先，车辆终端会将自身携带的计算任务信息如最大

可容忍时延、数据量大小、计算复杂度等上传至 RSU。RSU 通过计算得到计算任务优先级，然后根据 MEC 服务器的计算任务调度算法决定将哪些车辆终端的计算任务卸载至服务器。车辆终端随后接受 RSU 的调度信息，开始卸载或执行计算任务。假设在计算任务执行过程中，一旦执行时间超过其最大容忍时延，就判定当前计算任务执行失败，并将当前计算任务执行时间设置为最大值。

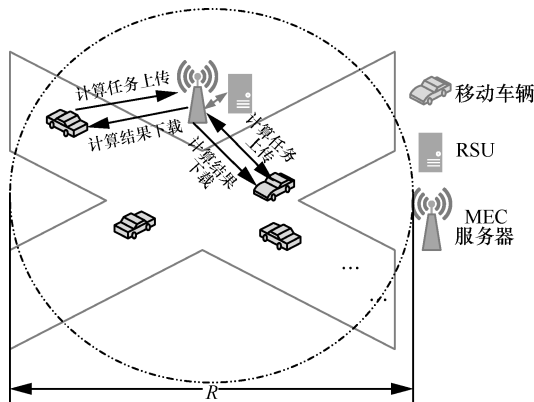


图 1 计算任务卸载模型架构

本文假设 RSU 覆盖范围内有 K 个车辆终端，车辆终端携带的计算任务表示为 $C_k = (V_k, D_k, \Gamma_k, P_k)$ ，其中， D_k 表示计算任务的数据大小，单位为 bit； V_k 表示计算任务计算复杂度，单位为 round/bit； Γ_k 表示计算任务最大可容忍时延，单位为 ms； P_k 表示计算任务的优先级，由 RSU 计算后得出。假设计算任务无论是在车辆终端执行还是卸载到 MEC 服务器执行，以上参数均保持不变。RSU 覆盖范围内的所有车辆终端的计算任务表示为 $M = \{M_1, M_2, \dots, M_k\}$ ，其中 $k \in K$ 。

3 车载边缘网络计算任务分发卸载方案

3.1 计算任务优先级划分

车辆终端将携带的计算任务卸载到 MEC 服务器时，由于计算任务类型的不同导致所需要的计算资源也不同。层次分析法 (AHP, analytic hierarrhy process) 指将与决策总是有关的元素分解成目标层、准则层、方案层等层次，并在此基础之上进行定性和定量分析的决策方法，是一个多标准决策/多属性决策模型，非常适用于权重分配的计算任务调度应用场景^[17]。本文通过 AHP 算法可以给容忍时延小、计算复杂度高的计算任务分配相对高一些的权重系数，为 MEC 服务器的计算资源调度过程

提供更合理的依据，提高车辆终端计算任务的卸载执行成功率。

当确定计算任务的权重系数时，本文主要考虑计算任务的计算复杂度、数据总量和最大容忍时延这 3 个评价因素，其中，计算复杂度的重要程度最高，数据总量次之，最大容忍时延最低。本文将计算任务目标层的因素进行两两比较，构造出评价因素判断矩阵 $A = (a_{ij})_{3 \times 3}$ ，以及目标层相对于准则层的判断矩阵 $B_1, B_2, \dots, B_3 = (a_{ij})_{K \times K}$ 。其中，

$$a_{ij} = \begin{cases} 1 & n, n = \{1, 2, 3, \dots, 9\}, i \neq j \\ a_{ji} & \\ 1 & i = j \end{cases} \quad (1)$$

根据方根法求得判断矩阵 B_k 对应的权重向量元素，如式(2)所示。

$$u_k^i = \frac{\sqrt[K]{\prod_{j=1}^K a_{ij}}}{\sum_{i=1}^K \sqrt[K]{\prod_{j=1}^K a_{ij}}} \quad (2)$$

其中， k 表示第 k 个终端车辆， i 表示第 k 个终端车辆所携带任务的第 i 个评价因素，可以得到所有车辆终端计算任务的权重矢量矩阵为

$$U = \begin{bmatrix} u_1^1 & u_1^2 & u_1^3 \\ u_2^1 & u_2^2 & u_2^3 \\ \vdots & \vdots & \vdots \\ u_k^1 & u_k^2 & u_k^3 \end{bmatrix} \quad (3)$$

根据同样的方法求得评价因素判断矩阵 A 的权重向量 $\Delta = [\Delta^1, \Delta^2, \Delta^3]$ ，其权重元素为

$$\Delta^i = \frac{\sqrt[3]{\prod_{j=1}^3 a_{ij}}}{\sum_{i=1}^3 \sqrt[3]{\prod_{j=1}^3 a_{ij}}} \quad (4)$$

权重元素通过一致性检验后，得到所有计算任务的权重向量 W ，其中每一个元素分别代表对应车辆终端计算任务的权重，如式(5)所示。

$$W = U\Delta = \begin{pmatrix} \sum_{i=1}^3 U_1^i \Delta^i \\ \sum_{i=1}^3 U_2^i \Delta^i \\ \vdots \\ \sum_{i=1}^3 U_K^i \Delta^i \end{pmatrix} \quad (5)$$

3.2 卸载决策制定问题的建模

车辆终端携带的计算任务分为车辆终端计算模式和卸载计算模式。车辆终端用于执行计算任务的总能耗 $E_{\text{constraint}}$ 为额定值, 当前计算任务执行能耗 E_{current} 表示为

$$E_{\text{constraint}} \geq E_{\text{current}} = p_k t_k = k_k f_k^3 t_k \quad (6)$$

其中, p_k 为车辆终端发射功率, k_k 为能量效率系数, f_k 为车辆终端处理器频率, t_k 为计算任务传输时间或车辆终端执行时间。

车辆终端计算模式中, 计算任务的处理速率 $R_L = \frac{f_k}{V_k}$ 。卸载计算模式中, 由于 MEC 服务器能够持续供能, 不受能耗约束, 因此计算任务处理能力强于能耗受限的车辆终端, 例如文献[18]的参数假设, MEC 服务器的处理能力超过车辆终端 2 个数量级。因此在卸载计算模式中, 本文将计算任务传输速率等价于计算任务的处理速率, 如式(7)所示。

$$R_o = \frac{B_k}{K} \ln \left(1 + \frac{p_k g_k}{N_0 \frac{B_k}{K}} \right) \quad (7)$$

其中, B_k 为当前车辆终端传输带宽, 其中最大传输带宽为 B Hz, N_0 为信道传输噪声。基于 LTE-V2X (long term evolution-vehicle to X) 技术, 本文假设无线信道增益 g_k 、车辆终端发射功率 p_k 及传输带宽 B_k 在对应的时段内均是时变的, 并且基于分布式方式下的 SPS (semi persistent scheduling) 资源分配算法^[19]对 RSU 覆盖范围内的车辆终端进行统一控制。本文以最大化计算任务处理速率为优化目标, 以车辆终端能耗与传输带宽为约束, 在求得计算任务处理速率最大加权和之后, 可求得对应的计算任务最小执行时延。同时, 基于式(5)得出的计算任务权重 w_k , 对于优先级别更高的计算任务可以分配更多的计算资源, 使其执行时间小于计算任务最大容忍时延, 保证计算任务卸载过程成功进行。本文的优化目标为

$$\begin{aligned} R_{\text{all}} &= \max \left(\left(w_k \sum_{k=1}^K (x_k R_o + (1-x_k) R_L) \right) \right) \\ \text{s.t.} \quad \text{C1: } &x_k \in \{0, 1\} \\ \text{C2: } &\sum_{k=1}^K t_k (x_k p_k + (1-x_k) k_k f_k^3) \leq \sum_{k=1}^K E_{\text{constraint}} \\ \text{C3: } &\sum_{k=1}^K B_k \leq B \end{aligned} \quad (8)$$

其中, x_k 表示为卸载决策向量元素, $x_k=0$ 表示车辆终端计算模式, $x_k=1$ 表示卸载计算模式; 约束条件 C2 和 C3 分别表示计算任务执行能耗和车辆终端传输带宽不能超过额定值。

通过求出卸载决策向量的最优值可以求解式(8)所示优化问题。然而该问题是一个非凸问题, 随着车辆终端数量及计算任务大小的增加, 该问题的计算复杂度也会迅速增加。

3.3 AHP-DQN 任务分发卸载算法

面对上述挑战, 传统的数值优化方法效率较低。本文提出了一种 AHP-DQN 任务分发卸载算法, 其核心思想是将 Q 网络作为策略评判标准, 通过 Q 网络遍历当前状态下的各种动作与环境进行实时交互, 其动作、状态值、奖励值存放于回访记忆单元通过 Q 学习算法经历多个迭代过程来反复训练 Q 网络, 最后得到最佳卸载策略。与文献[14]算法不同的是, 本文算法通过引入层次分析法对车辆终端计算任务进行预处理, 提高 MEC 服务器对计算资源的合理分配能力。同时重新定义了 Q 网络中的奖励函数, 以加权后的计算任务处理速率和为优化目标, 减小算法迭代过程中的计算复杂度, 加快算法收敛速度。本文的卸载决策算法致力于设计一个卸载策略函数, 当 MEC 服务器收到车辆终端的计算任务信息并得出计算任务对应的权重时, 能够根据当前车辆终端的无线信道增益情况, 快速调整深度学习网络参数 θ_i , 并生成计算任务卸载策略, 策略函数可以表示为 $\pi: g \rightarrow x$ 。该策略函数的产生可以分为两步, 具体如下。

1) 卸载决策动作的产生。当 MEC 服务器收到车辆终端当前的信道增益信息后, 深度学习网络根据当前观测到的状态 s_t 得到卸载动作向量 $\mathbf{X}_t = [x_1, x_2, \dots, x_K]$, 并根据式(7)生成奖励值 r_t 。同时本文的动作状态函数 $Q(s_t, x_t, \theta_t)$ 由深度学习网络确定, 深度学习网络激活函数为 ReLu 函数, 网络输出函数为 Sigmoid 函数, 其对应卸载动作的概率值。

2) 卸载决策动作的更新。根据式(9)实现动作状态函数的更新。

$$\begin{cases} Q_{k+1}(s_t, x_t, \theta_t) = Q_k(s_t, x_t, \theta_t) + \alpha_k E_k \\ E_k = r_t + \gamma \max_{x' \in \mathcal{X}} Q(s', x', \theta_t) - Q(s_t, x_t, \theta_t) \end{cases} \quad (9)$$

其中, α_k 与 γ 分别为学习速率与折扣因子, s' 为第 k 次迭代过程中执行动作 x_t 后的状态观测值, x' 为

状态 s' 下奖励值最大的动作, E_k 为迭代过程中的累积奖励值。对于第 k 次迭代过程而言, 通过最小化式(10)目标函数, 可以更新网络参数 θ , 从而实现卸载决策动作的更新。

$$\min E = \min \left(r_t + \gamma \max_{x \in X} Q(s', x', \theta'_t) - Q(s_t, x_t, \theta_t) \right) \quad (10)$$

重复上述 2 个步骤得到 t 时刻最佳状态对后, 将该状态-动作对 (g_t, x_t^*) 放入经验池, 作为新的训练样本。当经验池容量足够后, 新生成的状态-动作对会代替旧的数据样本。深度学习网络反复学习最佳状态对 (g_t, x_t^*) , 并随着时间的推移生成更好的卸载决策输出。在存储空间有限的约束下, DNN 仅从最新生成的数据样本中进行学习, 这种闭环强化学习机制会不断改善其卸载策略, 直到收敛。本文算法伪代码如算法 1 所示。

算法 1 AHP-DQN 计算任务分发卸载算法

输入 计算任务的计算复杂度 V_k 、数据总量 D_k 及最大容忍时延 T_k 。根据式(1)~式(5)得到每个计算任务的优先级 P_k , 即计算任务的计算资源分配权重

输出 车辆终端携带任务的最终卸载决策 $X = [x_1, x_2, \dots, x_k]$

- 1) 初始化经验池存储空间容量并且用随机权重 θ 初始化动作-价值函数 $Q_\theta(s_t, x_t)$
- 2) for each episode
- 3) 初始化状态 s_1 及预处理序列 $\phi_1 = \phi(s_1)$
- 4) for each iteration
- 5) 以 ε 的概率选择随机动作 x_t , 否则选择潜在回报最大的动作 $x_t = \max_x Q(\phi(s_t), x; \theta)$
- 6) 执行动作 x_t , 将步骤 1)中求出的权重值代入式(8)后得到奖励值 r_t 与 s_{t+1}
- 7) 令 $s_{t+1} = s_t, x_t$, 处理 $\phi_{t+1} = \phi(s_{t+1})$
- 8) 将 $(\phi_t, x_t, r_t, \phi_{t+1})$ 存放于经验池中
- 9) 从经验池中对向量进行均匀随机抽样, 令深度 Q 网络输出如式(9)所示。
- 10) 根据式(10)构建误差函数, 采用反向传播算法更新网络参数 θ
- 11) 若 s_{t+1} 是终止状态, 则结束本轮迭代过程
- 12) end for
- 13) end for

4 仿真结果与分析

本节通过 Python 编程语言对本文算法进行仿真以评估算法性能。本文仿真场景为 IEEE 802.11p 标准规定下的车联网场景, 仿真实验参数根据文献[20]及移动边缘计算白皮书相关约束进行假设。在车联网场景下, 每个 RSU 的覆盖范围为 1 000 m, 车辆终端速度假设为 40 km/h, 每个车辆终端计算能力为 10^8 round/s, 车载车辆终端计算功率为 3 W, 发射功率为 0.3 W。携带的计算任务数据 (以 kbit 为单位) 服从 [300, 500] 的均匀分布, 计算任务复杂度 (以兆轮为单位) 服从 [9 000, 11 000] 的均匀分布。下面将本文算法分别与全部车辆终端计算、Q 学习算法、DQN^[14] 进行比较。

本文算法收敛过程如图 2 所示。纵轴分别表示训练过程中所有车辆终端的归一化计算速率及损失函数值。根据经验风险最小化的知识, 收敛概率与网络复杂度负相关, 结合应用场景的实际维度情况, 本文选择了两层 DNN 结构, 同时在时延要求较高的车载边缘网络中并不注重未来的潜在回报, 因此本文设置了一个较小的折扣因子 γ 。在样本不多的初期采用较高的学习速率 α_k , 随着经验池样本增加, 逐渐减小 α_k , 避免损失函数过于震荡。在设计 Q 函数与奖励值时, 一方面尽量使收敛过程中 Q 的均值为 0, 另一方面使奖励值的正反馈稍大些, 保证初期奖励值的负反馈过程中能够采取人工干预提升正回报, 加速收敛过程。从图 2 可以看出, 在车辆终端数目为 10 的情况下, 本文算法经过 50 次迭代后, DQN 已经逐渐收敛到最优解。与 Q 学习算法的收敛结果相比较, 本文算法得到的优化目标具有更好的效果。从图 2 还可以看出, 尽管设置了较大的经验回放池尺度, 由于贪婪概率 ε 的存在, 收敛曲线存在些许波动, 但不影响算法整体的收敛性。




图 2 3 种算法的收敛过程

图 3 中，在车辆终端数目为 10 的情况下，将本文算法与全部车辆终端计算、Q 学习算法^[14]进行比较。从图 3 可以看到，随着计算任务复杂度的增加，3 种算法的计算任务执行成功率都在下降。当计算任务复杂度最高时，全部车辆终端计算的计算任务执行成功率只有 24%，Q 学习算法的执行成功率由 81% 下降到了 64%。与之相对应的是，本文算法的执行成功率保持了一个相对稳定的状态。与 Q 学习算法一样，本文算法只对能耗及传输带宽做了相应的约束，但是随着计算任务复杂度的上升，计算任务的差异度变大，基于 AHP 算法对计算任务做的预处理能够使 MEC 服务器更加合理地调度计算资源，从而提高计算任务卸载执行成功率。




图 3 计算任务执行成功率与计算复杂度的关系

在计算任务复杂度不变的情况下，将本文算法与全部车辆终端计算、Q 学习算法、DQN 进行比较，如图 4 所示。从图 4 可以看到，随着车辆终端数的增加，计算任务量变大，计算任务执行时延都随之上升。当车辆终端数目小于 10 时，本文算法与 Q 学习算法、DQN 的执行时延几乎没有不同。当车辆终端数目超过 10 时，本文算法的计算任务平均执行时延相比全部车辆终端计算的时延减少了 95 ms，相比 Q 学习算法减少了 24 ms，相比于 DQN 有些许提升。随着计算任务数目的增加，相比全部车辆终端计算与 Q 学习算法，本文算法的卸载方案能够根据信道实际情况进行学习，从而做出更合适的卸载决策，使计算任务执行时延更小。但是在仿真实验中，仅改变车辆终端数目，车辆终端计算任务的计算复杂度、数据量大小等属性保持不变，基于 AHP 算法对计算任务做出的预处理产生的效果有限，因此本文算法与 Q 学习算法的效果提升有限。




图 4 任务平均时延与车辆终端数目的关系

在车辆终端数目为 10 的情况下，随着一半的车辆终端计算任务计算复杂度的增加，4 种算法的计算任务平均执行时延都在增加，如图 5 所示。从图 5 中可以看出，在计算任务复杂度最高时，本文算法的计算任务执行时延与全部车辆终端计算相比减少了 219 ms，与 Q 学习算法相比减少了 64 ms，与 DQN 相比减少了 24 ms。比较图 4 与图 5 可以看出，在计算任务差异度越大的应用场景中，本文算法优势越明显。随着计算复杂度的上升，不同车辆终端的计算任务差异度越大，MEC 服务器计算资源的分配权重也随之变化。与 Q 学习算法和 DQN 不同的是，本文算法对所有车辆终端的计算任务做了自适应优先级预处理，给优先级更高的计算任务分配了更多的计算资源，使计算任务执行成功概率更高，从而提高卸载决策正确率，有效减小了计算任务执行时延。




图 5 任务平均时延与计算任务复杂度的关系

5 结束语


面向车联网环境中车辆终端受最大容忍时延及最大能耗约束的情况，本文提出了一种基于深度

Q 网络的计算任务分发卸载算法。车辆终端首先根据自身计算任务大小、计算复杂度及最大容忍时延等因素对计算任务优先级进行合理划分,并根据车辆终端实时信道增益进行自主卸载决策部署,以找到最优策略。通过对该算法的大量仿真分析及数值验证,本文提出的 AHP-DQN 任务分发卸载算法在不同的系统参数下都具有较好的性能。今后的研究将会考虑对 DQN 的训练算法及神经网络结构进行持续优化改进,同时对无线电干扰等复杂环境因素也会加以考虑。

参考文献:

- [1] NING Z, FENG Y F, COLLOTTA M, et al. Deep learning in edge of vehicles: exploring trirelationship for data transmission[J]. IEEE Transactions on Industrial Informatics, 2019, 15(10): 5737-5746.
- [2] ZHOU H, XU W, CHEN J. Evolutionary V2X technologies toward the Internet of vehicles: challenges and opportunities[J]. Proceedings of the IEEE, 2020, 108(2): 308-323.
- [3] POPLI S, JHA R K, JAIN S. A survey on energy efficient narrowband Internet of things (NB-IoT): architecture, application and challenges[J]. IEEE Access, 2019(7): 16739-16776.
- [4] 谢人超, 廉晓飞, 贾庆民, 等. 移动边缘计算卸载技术综述[J]. 通信学报, 2018, 39(11): 138-155.
XIE R C, LIAN X F, JIA Q M, et al. Overview of mobile edge computing offload technology[J]. Journal on Communications, 2018, 39(11): 138-155.
- [5] XIE J, JIA Y, CHEN Z, et al. Efficient task completion for parallel offloading in vehicular fog computing[J]. China Communications, 2019, 16(11):42-45.
- [6] HUANG K B, ZHU G X, YOU C S, et al. Communication, computing, and learning on the edge[C]//2018 IEEE International Conference on Communication Systems. Piscataway: IEEE Press, 2018: 268-273.
- [7] MAO Y, YOU C, ZHANG J, et al. A survey on mobile edge computing: the communication perspective[J]. IEEE Communications Surveys & Tutorials, 2017, 19(4): 2322-2358.
- [8] ZHANG J, LETAIEF K B. Mobile edge intelligence and computing for the Internet of vehicles[J]. Proceedings of the IEEE, 2020, 108(2): 246-261.
- [9] KETYKO I, KECSKES L, NEMES C, et al. Multi-user computation offloading as multiple knapsack problem for 5G mobile edge computing[C]//2016 European Conference on Networks and Communications. Piscataway: IEEE Press, 2016: 225-229.
- [10] ZHAO J, LI Q, GONG Y, et al. Computation offloading and resource allocation for cloud assisted mobile edge computing in vehicular networks[J]. IEEE Transactions on Vehicular Technology, 2019, 68(8): 7944-7956.
- [11] MENG X, WANG W, WANG Y, et al. Closed-form delay-optimal computation offloading[J]. Mobile Edge Computing Systems, 2019, 18(10): 4653-4667.
- [12] DU J, ZHAO L, FENG J, et al. Computation offloading and resource allocation in mixed fog/cloud computing systems with min-max fairness guarantee[J]. IEEE Transactions on Communications, 2017, 66(4): 1-3.
- [13] 郭辉, 芮兰兰, 高志鹏. 车辆终端边缘网络中基于多参数 MDP 模型的动态服务迁移策略[J]. 通信学报, 2020, 41(1): 1-14.
GUO H, RUI L L, GAO Z P. Dynamic service migration strategy based on multi-parameter MDP model in vehicle edge network[J]. Journal on Communications, 2020, 41(1): 1-14.
- [14] LI J, GAO H, LYU T, et al. Deep reinforcement learning based computation offloading and resource allocation for MEC[C]// 2018 IEEE Wireless Communications and Networking Conference. Piscataway: IEEE Press, 2018:1-6.
- [15] ARULKUMARAN K, DEISENROTH M P, BRUNDAGE M, et al. Deep reinforcement learning: a brief survey[J]. IEEE Signal Processing Magazine, 2017, 34(6): 26-38.
- [16] MAO Q, FEI H, QI H. Deep learning for intelligent wireless networks: a comprehensive survey[J]. IEEE Communications Surveys & Tutorials, 2018, 20(4): 2595-2621.
- [17] HUANG Y L, SUN W L. An AHP-based risk assessment for an industrial IoT cloud[C]//2018 IEEE International Conference on Software Quality, Reliability and Security Companion. Piscataway: IEEE Press, 2018: 637-638.
- [18] 余翔, 刘一勋, 石雪琴, 等. 车联网场景下的移动边缘计算卸载策略[J]. 计算机工程, 2020, doi: 10.19678/j.issn.1000-3428.0056850.
YU X, LIU Y X, SHI X Q, et al. Offloading strategy for mobile edge computing in Vehicle Network[J]. Computer Engineering, 2020, doi: 10.19678/j.issn.1000-3428.0056850.
- [19] 陈山枝, 胡金玲, 时岩. LTE-V2X 车联网技术、标准与应用[J]. 电信科学, 2018, 34(4): 1-11.
CHEN S Z, HU J L, SHI Y. LTE-V2X car networking technology, standards and applications[J]. Telecommunications Science, 2018, 34(4): 1-11.
- [20] 王寒松. 车联网中基于 MEC 的计算任务卸载策略研究[D]. 北京: 北京邮电大学, 2019.
WANG H S. Research of computing offloading scheme for MEC-enabled vehicular networks[D]. Beijing: Beijing University of Posts and Telecommunications, 2019.

[作者简介]



赵海涛 (1983-), 男, 江苏南京人, 博士, 南京邮电大学教授、硕士生导师, 主要研究方向为无线多媒体建模、容量预测和无线网络编码等。

张唐伟 (1994-), 男, 安徽安庆人, 南京邮电大学硕士生, 主要研究方向为移动边缘计算、无线系统资源分配等。

陈跃 (1996-), 男, 安徽宿州人, 南京邮电大学硕士生, 主要研究方向为物联网路由优化和边缘计算等。

赵厚麟 (1950-), 男, 江苏高邮人, 博士, 南京邮电大学兼职教授、博士生导师, 主要研究方向为 IPv6 技术标准实现及其在下一代信息网络中的应用、下一代网络 (NGN) 关键技术及标准化研究等。

朱洪波 (1956-), 男, 江苏扬州人, 博士, 南京邮电大学教授、博士生导师, 主要研究方向为无线通信与电磁兼容、移动通信、宽带无线技术等。