

车联网中整合移动边缘计算与内容分发网络的移动性管理策略

张海波^① 程妍^{*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: 由于车载应用的普及和车辆数量的增加, 路边基础设施的物理资源有限, 当大量车辆接入车联网时能耗与时延同时增加, 通过整合内容分发网络(CDN)和移动边缘计算(MEC)的框架可以降低时延与能耗。在车联网中, 车辆移动性对云服务的连续性提出了重大挑战。因此, 该文提出了移动性管理(MM)来处理该问题。采用开销选择的动态信道分配(ODCA)算法避免乒乓效应且减少车辆在小区间的切换时间。采用基于路边单元(RSU)调度的合作博弈算法进行虚拟机迁移并开发基于学习的价格控制机制, 以有效地处理MEC的计算资源。仿真结果表明, 所提算法相比于现有的算法能够提高资源利用率且减少开销。

关键词: 车联网; 移动边缘计算; 内容分发网络; 小区间的切换; 虚拟机迁移

中图分类号: TN929.5

文献标识码: A

文章编号: 1009-5896(2020)06-1444-08

DOI: [10.11999/JEIT190571](https://doi.org/10.11999/JEIT190571)

The Mobility Management Strategies by Integrating Mobile Edge Computing and CDN in Vehicular Networks

ZHANG Haibo^① CHENG Yan^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: Due to the popularity of vehicle applications and the increase of the number of vehicles, the physical resources of roadside infrastructure are limited. When a large number of vehicles are connected to the vehicle networks, the energy consumption and latency are simultaneously increased. The framework for integrating the Content Delivery Network (CDN) and Mobile Edge Computing (MEC) can reduce the latency and energy consumption. In vehicle network, vehicle mobility poses a major challenge to the continuity of cloud services. Therefore, Mobility Management (MM) is proposed to deal with this problem. The Dynamic Channel Allocation algorithm with Overhead selection (ODCA) is used to avoid the ping-pong effect and reduces the handover time of vehicles between cells. The cooperative game algorithm based on RoadSide Unit (RSU) is used for virtual machine migration and a learning-based price control mechanism is developed to process vehicular computation resources efficiently. The simulation results show that the proposed algorithm can improve resource utilization and reduce overhead compared with the existing algorithms.

Key words: Vehicular networks; Mobile Edge Computing (MEC); Content Delivery Network (CDN); Cell handover; Virtual machine migration

收稿日期: 2019-07-29; 改回日期: 2020-02-21; 网络出版: 2020-03-20

*通信作者: 程妍 2311837009@qq.com

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项目(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

在过去的十年,物联网(Internet of Things, IoT)引起了学术界和工业界的极大关注,而车联网(Internet of Vehicle, IoV)作为物联网的关键分支已成为智能交通系统不可或缺的组成部分。随着先进车载应用的出现,高速计算和快速通信的需求日益突出。如自动驾驶技术,需要高水平的数据通信和计算。作为车载应用,自动驾驶正处于前所未有的发展阶段。但自动驾驶对计算和时延十分敏感,而当前车载网络系统无法满足日益增长的车载应用对时延的要求^[1-3]。基于移动边缘计算(Mobile Edge Computing, MEC)的车载网络被设想为一个潜在的满足应用需求的解决方案^[4]。与此同时,网络功能虚拟化(Network Function Virtualization, NFV)和软件定义网络(Software Define Network, SDN)技术的发展为移动网络运营商(Mobile Network Operator, MNO)提供了将内容分发网络(Content Delivery Network, CDN)的功能深入部署到移动网络基础设施中的机会^[5]。且CDN减轻了核心网络的流量负担,降低了MNO的传输成本。最近,欧洲电信标准协会(European Telecommunications Standards Institute, ETSI)通过在移动网络边缘提供存储和计算能力来支持CDN的实施,例如,将车载云服务部署在CDN上^[6]。调度系统(Traffic Control System, TCS)是CDN网络的重要组成部分,接收终端侧发起的访问请求,监测全网节点的健康状态、负载情况及内容分布情况,根据调度策略将终端调度到最佳的边缘节点的路边单元(RoadSide Unit, RSU)。

MEC通过提供车载网络边缘用户所需的处理能力,即加速车载网络中的应用和数据流,来支撑以消费者为中心的物联网应用和实时服务。然而,目前关于CDN和MEC的研究大多是独立的。尽管CDN和MEC集成可以带来潜在的好处,但集成后面面临着移动性管理(Mobility Management, MM)等挑战。MM将移动设备与移动设备相关联,可以实现连续移动服务(即无线电接入和计算)。当车辆用户(Vehicle Users, V-UEs)处于移动状态时,小区间的切换和虚拟机迁移(Virtual Machine Migration, VMM)是重要研究对象,也是衡量系统性能的重要标准。在保证服务连续性的同时充分利用系统资源是MM实现的关键。文献^[7-10]调查了管理虚拟机(Virtual Machine, VM)性能开销的最新研究并介绍了云计算和VM迁移的方法,但是,这些方案没有考虑车辆移动性和VM迁移之间的关系。会导致服务中断或者迁移过程中服务迁移失败。

本文目标是整合CDN与MEC形成一个合理的架构来组织云资源,包括中心云、边缘云和车载云资源,允许车辆弹性地选择他们的云服务。中心云有足够的资源但是端到端的时延太高,边缘云和车辆云的资源有限但时延低。本文使用开销选择的动态信道分配(Dynamic Channel Allocation algorithm with Overhead selection, ODCA)算法和基于RSU调度的合作博弈算法实现了CDN与MEC的有效整合,解决了MM中服务连续性问题,且合理利用了中心云、边缘云、车载云的资源。

2 系统模型

2.1 系统分析

有 L 个服从泊松分布的任务车辆 $V = \{v_1, v_2, \dots, v_L\}$,需要多个VM来处理在线车辆任务,假设有 K 个VM,表示为 $vm = \{vm_1, vm_2, \dots, vm_k\}$ 。 M 个路边单元(RSU),即 M 个边缘节点(Edge Node, EN),每个RSU部署1个MEC服务器。为了频谱复用,假定多个RSU共用1个频谱资源,那么小区间存在干扰。带宽 W 被分为 N 个信道,V-UE采用正交频分多址接入(Orthogonal Frequency Division Multiple Access, OFDMA)与基站相连^[11]。其系统模型如图1所示,将MEC服务器部署到CDN边缘节点,利用CDN的全局调度系统,将用户请求根据调度策略调度至全局最优的边缘节点,可以解决MEC资源有限、分布不均匀、可能存在高并发压力等问题。同时,侧链(sidelink)通信是5G通信的一种新范式,可以增强车联网性能并支持车辆到一切(Vehicle to Everything, V2X)通信,使车辆能够与其他车辆、设备和基础设施进行协作^[12]。整合MEC与CDN的架构包括3层:

(1) 车载云:在一组合作的车辆中,在sidelink模式下,可以直接建立车辆到车辆(Vehicle to Vehicle, V2V)通信的本地云,以共享车辆信息;

(2) 路边单元云:在一组相邻的RSU之间建立的本地云,车辆将通过车辆到基础设施(Vehicle to Infrastructure, V2I)通信访问路边云;

(3) 中心云:主要做调度服务,海量数据存储和数据同步。路边云数据通过消息中间件实时传输数据至中心云,当用户请求被调度至另一个没有此车辆信息的路边云时,此路边云会从中心云获取数据。

当车辆移动时,会出现以下4种情况:

(1) 当车辆 v_1 启动时,进入RSU-1覆盖范围时, v_1 向TCS发送请求, v_1 被调度距离该车辆最近的RSU,即RSU-1,此时不进行数据迁移也不进行RSU间切换;

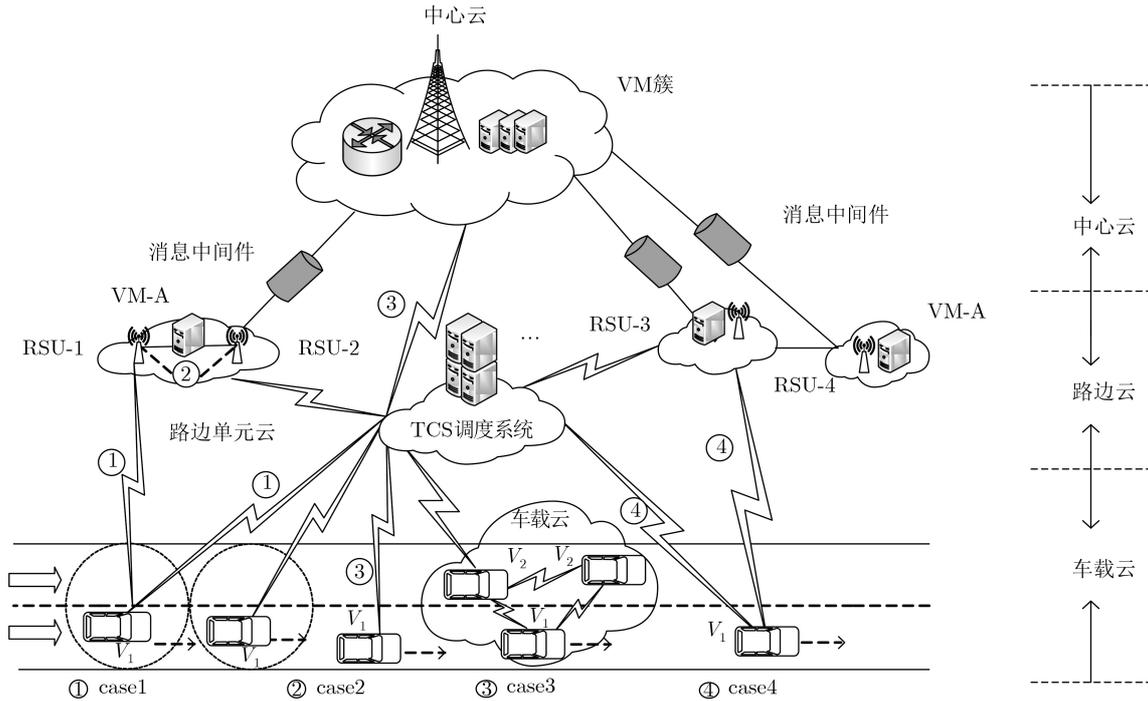


图1 系统模型图

(2) 车辆 v_1 从RSU-1的覆盖范围驶入RSU-2的覆盖范围时, 由于处于同一个路边单元云, 共用VM-A, 因此不进行数据迁移只会进行RSU间的切换;

(3) 当车辆 v_1 驶出RSU-2的覆盖范围时, 由于数据已经通过消息中间件上传到中心云, 因此中心云直接给车辆 v_1 提供服务, 此时不进行数据迁移也不进行RSU间的切换;

(4) 当车辆 v_1 驶入RSU-3的覆盖范围时, RSU-3没有车辆信息, 此时从中心云迁移数据。

2.2 计算与通信模型

计算任务 $A_{i,j} = \{d_{i,j}, c_{i,j}, T^{\text{th}}\}$ 由3个参数组成, $d_{i,j}$ 是输入数据的大小, $c_{i,j}$ 是任务执行时所需的CPU周期数, T^{th} 是最大的延迟容限。当输入数据通过RSU被传输到MEC服务器时, 在RSU与MEC之间的费用可忽略^[13]。当V-UEs通过信道 l 接入到RSU时, 其上行传输速率为 $R_{i,j,l} = w \lg \left(1 + \frac{p_{i,j,l} L_{i,j,l}}{\sigma^2 + I} \right)$ 。 $w = \frac{W}{N}$ 是带宽, $p_{i,j,l}$ 和 $L_{i,j,l}$ 分别是V-UE i 在信道 l 上接入RSU j 的传输功率和路径损耗。 σ^2 是噪声功率, I 是在RSU覆盖范围中的V-UE受到来自相邻小区的其他V-UEs的干扰, I 为常量。

因此, V-UE的总上行传输速率为

$$R_{i,j} = \sum_{l=1}^L a_{i,j,l} R_{i,j,l} \quad (1)$$

其中, $a_{i,j,l} \in \{0, 1\}$, $a_{i,j,l} = 1$ 表示信道 l 被分配给RSU j 中的V-UE i 去卸载任务, 否则, $a_{i,j,l} = 0$ 。 f^C 是

MEC服务器的CPU周期频率。任务在边缘计算的总时间包括传输时间和在MEC上的计算时间, 表示为

$$t_{i,j}^C = \frac{d_{i,j}}{R_{i,j}} + \frac{c_{i,j}}{f^C} \quad (2)$$

相应的能耗为

$$e_{i,j}^C = \sum_{l=1}^L a_{i,j,l} p_{i,j,l} \frac{d_{i,j}}{R_{i,j}} \quad (3)$$

2.3 切换模型

(1) 估算V-UE i 接收信号信噪比SNR。 f 是载波的中心频率, 以MHz为单位, 在3GPP标准中一般取2 GHz。 h_i 和 h_j 分别是V-UE i 和RSU j 的天线高度。若 f , h_i 和 h_j 均已知时, 路径损耗 $L_{i,j,l}$ 只与RSU j 和V-UE i 之间的距离 d 有关。可表示为

$$\begin{aligned} L_{i,j,l} = & 69.55 + 26.16 \lg f - 13.821 \lg(h_j) \\ & - 3.2[\lg(11.75 \times h_i)]^2 - 4.97 \\ & - [44.9 - 6.55 \lg(h_j)] \lg d \end{aligned} \quad (4)$$

(2) 切换位置 $(\mathbf{X}_{i,j}, \mathbf{Y}_{i,j})$ 的确定。根据V-UE i 在当前发送的信号分别到达相邻RSU的SNR $= \frac{p_{i,j,l} L_{i,j,l}}{\sigma^2 + I}$ 来确定切换位置 $(\mathbf{X}_{h1}, \mathbf{Y}_{h1})$ 。若找不到SNR刚好相等的位置, 则要考虑到达的质量指标, 即预设一个功率损耗门限 P^{th} , 计算出V-UE i 的切换参考位置 $(\mathbf{X}_{h2}, \mathbf{Y}_{h2})$ 。RSU j_1 和RSU j_2 坐标分别为 $(\mathbf{X}_{j1}, \mathbf{Y}_{j1})$, $(\mathbf{X}_{j2}, \mathbf{Y}_{j2})$ 。因此, V-UE i 在RSU j 覆盖范围内的切换位置 $(\mathbf{X}_{i,j}, \mathbf{Y}_{i,j})$ 应满足

$$\left. \begin{aligned} & \sqrt{(\mathbf{X}_{h1} - \mathbf{X}_{j1})^2 + (\mathbf{Y}_{h1} - \mathbf{Y}_{j1})^2} \\ & = \sqrt{(\mathbf{X}_{h1} - \mathbf{X}_{j2})^2 + (\mathbf{Y}_{h1} - \mathbf{Y}_{j2})^2} \\ & P^{\text{th}} = k \lg \left(\sqrt{(\mathbf{X}_{h2} - \mathbf{X}_{j1})^2 + (\mathbf{Y}_{h2} - \mathbf{Y}_{j1})^2} \right) \\ & \cdot (\mathbf{X}_{i,j}, \mathbf{Y}_{i,j}) = \min [(\mathbf{X}_{h1}, \mathbf{Y}_{h1}), (\mathbf{X}_{h2}, \mathbf{Y}_{h2})] \end{aligned} \right\} (5)$$

(3) V-UE i 当前位置 (\mathbf{X}, \mathbf{Y}) : 根据V-UE发送信号到达两个RSU的时间差来确定。其中, $c = 3 \times 10^8$

$$\Delta T = \frac{\sqrt{(\mathbf{X}_{i,j1} - \mathbf{X})^2 + (\mathbf{Y}_{i,j1} - \mathbf{Y})^2} - \sqrt{(\mathbf{X}_{i,j2} - \mathbf{X})^2 + (\mathbf{Y}_{i,j2} - \mathbf{Y})^2}}{c} (6)$$

(4) 切换时间 $t_{i,j}^h$: 是V-UE i 从当前位置到达切换位置的时间

$$t_{i,j}^h = \frac{\sqrt{(\mathbf{X} - \mathbf{X}_{i,j})^2 + (\mathbf{Y} - \mathbf{Y}_{i,j})^2}}{v} (7)$$

2.4 迁移模型

若虚拟机 vm_k 占用存储的大小为 v_k^{mem} , 迁移期间的内存脏页率为 D_k^{mem} , 虚拟机 vm_k 所处的数据中心的网络带宽是 W_k , 迁移过程的迭代次数设置为 n 。令 $\alpha = D_k^{\text{mem}}/W_k$, 在CDN网络下, 由于在边缘云和中心云之间部署了消息中间件, 当V-UE向边缘服务器发送请求时, 边缘服务器会通过消息中间件将服务请求同步到中心服务器。相比于传统的迁移, 只需迁移最后1次, 而不是 n 次。其迁移时间为

$$t_k^{\text{vm}} = \frac{v_{i,k}^{\text{vm}}}{W_k} (8)$$

相应的迁移能耗为

$$e_k^{\text{vm}} = \sum_{k=1}^K (\beta v_{i,k}^{\text{vm}} + \gamma) (9)$$

其中, β 和 γ 是模型需要训练的参数, $v_{i,k}^{\text{vm}}$ 是迁移数据量。其计算公式为 $v_{i,k}^{\text{vm}} = v_k^{\text{mem}} \cdot \frac{1 - \alpha^{n+1}}{1 - \alpha}$ 。

因此, 总时延 $t_{i,j,k}^{\text{total}} = t_{i,j}^C + t_{i,j}^h + t_k^{\text{vm}}$ 包括传输时延、在MEC服务器上的计算时延、切换时延和迁移时延。总能耗 $e_{i,j,k}^{\text{total}} = e_{i,j}^C + e_k^{\text{vm}}$ 包括传输能耗和迁移能耗。由于从MEC回传到V-UEs的数据大小远小于输入数据的大小, 故忽略了回传的时延和能耗^[13]。 $w_{i,j}$ 是权重因子, 可以得到总开销 $G_{i,j,k}^{\text{total}} = w_{i,j} t_{i,j,k}^{\text{total}} + (1 - w_{i,j}) e_{i,j,k}^{\text{total}}$ 。

令 $w_{i,j}^t = w_{i,j}$, $w_{i,j}^e = 1 - w_{i,j}$, 总开销(时延与能耗的加权和)可化简为

$$G_{i,j,k}^{\text{total}} = w_{i,j}^t t_{i,j,k}^{\text{total}} + w_{i,j}^e e_{i,j,k}^{\text{total}} (10)$$

3 开销选择的动态信道分配方案

制定一个多RSU多V-UE的场景, 由于车辆高速行驶, 需要同时考虑小区切换和虚拟机迁移

$$\left. \begin{aligned} & P1: \min_{p, \alpha} \sum_{i=1}^L \sum_{j=1}^M \sum_{k=1}^K w_{i,j}^t \left(\frac{d_{i,j}}{R_{i,j}} + \frac{c_{i,j}}{f_{i,j}^C} + t_{i,j}^h + \frac{v_{i,k}^{\text{vm}}}{W_k} \right) \\ & + \sum_{i=1}^{U_j} \sum_{j=1}^M \sum_{k=1}^K w_{i,j}^e \left(\sum_{l=1}^L a_{i,j,l} p_{i,j,l} \frac{d_{i,j}}{R_{i,j}} + \beta v_{i,k}^{\text{vm}} + \gamma \right) \\ & C1: \frac{d_{i,j}}{R_{i,j}} + \frac{c_{i,j}}{f_{i,j}^C} + t_{i,j}^h + \frac{v_{i,k}^{\text{vm}}}{W_k} \leq T^{\text{th}}, \sum_{l=1}^L a_{i,j,l} p_{i,j,l} \frac{d_{i,j}}{R_{i,j}} \\ & + \beta v_{i,k}^{\text{vm}} + \gamma \leq E^{\text{max}} \\ & C2: 0 \leq p_{i,j,l} \leq p^{\text{max}} \\ & C3: \sum_{l=1}^L a_{i,j,l} \leq 1, \forall i, j \\ & C4: a_{i,j,l} \in \{0, 1\}, \forall i, j, l \end{aligned} \right\} (11)$$

约束条件C1分别是对总时延和总能耗的约束。C2对传输功率进行了限制。C3确保最多只能分配1个信道给V-UE。C4表示信道分配是一个二进制变量。由于存在二进制变量和其它变量, 故P1问题是一个混合整数非线性规划问题。因此, 先采用开销选择的动态信道分配算法计算切换时间, 然后使用基于RSU调度的合作博弈算法解决VM迁移机制问题。表1是对V-UE与RSU*的选择。

表1 开销选择的动态信道分配(ODCA)

- (1) 输入: $I_{\text{dd}}, h_i, h_j, v, c, (\mathbf{X}, \mathbf{Y})$
- (2) 输出: $(\mathbf{X}_{i,j}, \mathbf{Y}_{i,j}), t_{i,j}^h, \text{RSU}^*$
- (3) 初始化权值矩阵 (\mathbf{X}, \mathbf{Y})
- (4) $m \leftarrow 0$
- (5) while $m \leq I_{\text{dd}}$
- (6) for $j = 1 : M$
- (7) L 辆车同时进行分布式计算, 每个连接到RSU的V-UE仅报告未定期使用信道的开销
- (8) 如果许多用户同时改变其信道, 可能导致乒乓效应, RSU可通过 $a_{i,j,l}^{\wedge} = 1 | \hat{l} = \max \frac{p_{i,j,l} L_{i,j,l}}{\sigma^2 + I}$ 改变信道
- (9) 根据式(10)计算开销, 根据开销最小来选择最优、次优、次优的3个RSU
- (10) V-UE实时上报其位置信息 (\mathbf{X}, \mathbf{Y}) 和功率损耗门限 P^{th} , TCS根据式(5)计算切换位置 $(\mathbf{X}_{i,j}, \mathbf{Y}_{i,j})$
- (11) 根据 $(\mathbf{X}_{i,j}, \mathbf{Y}_{i,j})$ 和式(7)分别计算切换到3个RSU的时间, 如果能使 $t_{i,j}^C$ 和 $t_{i,j}^h$ 最小, 此RSU*性能最优, 且最优切换时间为 $t_{i,j}^h$
- (12) endfor
- (13) endwhile

4 基于RSU调度的合作博弈算法

4.1 博弈的第1阶段(竞争)

TCS计算得到RSU*, 当RSU*不是V-UE最先连接的RSU所在的路边单元云时需要做VM迁移。通常VM迁移可分解成3个过程: 是否迁移, 分配了多少MEC资源, 这些资源的最佳价格。

在第1阶段EN通过联合计算和通信资源来决定是否迁移特定的VM, 对于VM迁移过程, 其中一个决策标准是时延。当V-UE从EN_j移动到EN_s时, 时延间隔ΔT为

$$\Delta T = N - M \quad (12)$$

$$N = \frac{d_{i,j}(t_1)}{R_{i,j}(t_1)} + \frac{d_{i,j}(t_2)}{R_{i,j}(t_2)}, M = \frac{d_{i,j}(t_1)}{R_{i,j}(t_1)} + \frac{d_{i,j}(t_2)}{R_{i,s}(t_2)} + t_{i,k}^{vm} \quad (13)$$

$$\text{s.t. } \Delta T > \delta (\delta > 0) \quad (14)$$

其中, N 和 M 分别是没进行迁移时与迁移时程序运行的总时间。 $d_{i,j}(t_1)$ 和 $d_{i,j}(t_2)$ 分别是V-UE i 在 t_1 和 t_2 时刻EN_j覆盖内的数据量。 $R_{i,j}(t_1)$ 与 $R_{i,s}(t_2)$ 分别是V-UE i 在 t_1 和 t_2 时刻EN_j覆盖内的传输速率。 δ 是安全迁移的时间缓冲间隙, 满足式(14)的条件时, EN_j可将 vm_k 从源物理机迁移到目标物理机。

4.2 博弈的第2阶段(合作)

在第2阶段, 根据EN的报价计算迁移与未迁移的收益 $U_{pro} = U_{in} - U_{cost}$

$$\left. \begin{array}{l} \text{未迁移} \left\{ \begin{array}{l} U_{in} = x^\omega / N \\ \omega = \max((\tau - N), 0) \times (d_{i,j}(t_1) + d_{i,j}(t_2)) \\ U_{cost} = \left(\theta_i^{EN_j}(t) \times d_{i,j}(t_1) \right. \\ \quad \left. + \theta_i^{EN_j}(t) \times d_{i,j}(t_2) \times \varphi^{EN_j} \right) / N \end{array} \right\} \\ \text{迁移} \left\{ \begin{array}{l} U_{in} = x^\omega / N \\ \omega = \max((\tau - M), 0) \times (d_{i,j}(t_1) + d_{i,j}(t_2)) \\ U_{cost} = \left(\theta_i^{EN_j}(t) \times (d_{i,j}(t_1) + d_{i,j}(t_2) + v_{i,k}^{vm}) \right) \\ \quad / N \end{array} \right\} \end{array} \right\} \quad (15)$$

在合作过程中, 每个EN_j都是提议者, V-UE i 是响应者, 它们相互交互以进行VM迁移。此时, 提议者提供价格为 vm_k 迁移。 $\theta_i^{EN_j}(t)$ 是EN_j在 t 时刻的报价, x 为V-UE收到效益的控制因子, τ 为程序超时时间, φ^{EN_j} 是额外的延迟因子。V-UE的收入与程序运行时间成反比, 成本与输入数据的大小成正比, 而无迁移时会有额外的延迟。

4.3 博弈第3阶段(用Deep Q-learning Network来调整价格)

第3阶段, EN学习V-UE的行为和以在线的方式调整其价格策略。价格决策问题被认为是在线学

习问题之一, 通过观察V-UE的反应, 每个EN都可以了解他们的倾向。当前合同的输出是EN价格决策过程的输入, 这种互动合同反馈的动态有助于决定实时价格。

DQN包括3个关键因素, 分别是状态, 行为和奖励函数。状态空间 $\mathbf{S} = \{v_{i,k}^{vm}, d_{i,j}\}$ 由迁移数据量 $v_{i,k}^{vm}$ 和输入数据的大小 $d_{i,j}$ 组成。行为空间是价格策略数, 表示为 $\mathbf{A} = \{(a_0, \dots, a_x, \dots, a_H) | a_x \in (0, 1, \dots, a_{max})\}$ 。其中, a_0 是不进行迁移的价格策略数, a_x 是迁移时的价格策略数, a_{max} 是不迁移或迁移时的最大价格策略数。

奖励函数 $R_{re} = \mathbf{A}_{in} - \mathbf{B}_{co}$ 是V-UE接收EN提供价格的收益。其效用函数 \mathbf{A}_{in} 和成本函数 \mathbf{B}_{co} 的表达式分别为

$$\mathbf{A}_{in} = \sum_{x=1}^H a_x \left(\frac{x^\omega}{M} \right) + a_0 \left(\frac{x^\omega}{N} \right) \quad (16)$$

$$\begin{aligned} \mathbf{B}_{co} = & a_0 \left(\theta_i^{EN_j}(t) \times (d_{i,j}(t_1) + d_{i,j}(t_2) \times \varphi^{EN_j}) \right) / N \\ & + \sum_{x=1}^H a_x \left(\theta_i^{EN_j}(t) \times (d_{i,j}(t_1) + d_{i,j}(t_2) + v_{i,k}^{vm}) \right) \\ & / N \end{aligned} \quad (17)$$

$Q^*(s, a)$ 是在时间步长 t 处的状态 s 下做出行为 a 后采取价格策略 π 的最小奖励 r_t , $E[\cdot]$ 是期望函数

$$Q^*(s, a) = -\max_{\pi} E \left[r_t + \sum_{k=1}^{\infty} \epsilon^k r_{t+k} | s_t = s, a_t = a, \pi \right] \quad (18)$$

表2给出了基于RSU调度的合作博弈的迁移过程。

表2 基于RSU调度的合作博弈算法

- | |
|---|
| (1) 输入: $\mathbf{S}, \alpha, \beta, d_{i,j}, c_{i,j}, \text{RSU}^*, I_{dd}$ |
| (2) 输出: \mathbf{A} |
| (3) 初始化权值矩阵 \mathbf{A}, \mathbf{S} |
| (4) $m \leftarrow 0$ |
| (5) while $m \leq I_{dd}$ |
| (6) for $j = 1 : M$ |
| (7) L 辆车同时进行分布式计算, 利用梯度下降算法求出最优功率分配值 $p_{i,j,l}^*$ |
| (8) 根据式(14)判断是否迁移 |
| (9) 根据博弈论第2阶段计算出未迁移与迁移的收益 |
| (10) 根据行为 a_t 观察下一时刻的状态 s_{t+1} |
| (11) 根据式(16)–式(18)出奖励函数, 通过不断地学习, 找到使奖励函数最大的策略 |
| (12) endfor |
| (13) endwhile |

5 仿真分析

在本节中, 将利用MATLAB仿真平台对小区

间切换和虚拟机迁移进行分析。高速公路参数遵循3GPP TR 36.885中的设置，并且系统模型按照MEC白皮书中的规定建立。其中，RSU部署在高速公路一侧，MEC服务器部署在RSU上，车辆速度为100 km/h，通信半径为250 m。详细模拟参数如表3所示。

图2显示了基站数目会影响V-UEs的切换时间，基站数目越多，V-UEs的切换时间就越小。本文将提出的ODCA与FCA(固定信道分配)、DCA(动态信道分配)^[14]和EMM-LSI(能量感知移动性管理-本地状态信息)算法^[15]作对比。由于TCS能够根据ODCA算法将用户请求调度至全局最优边缘节点的RSU且ODCA算法解决了乒乓效应，选出最优的RSU，不需要反复进行切换，故切换时间最小。由于用户在进行切换的过程中需要频繁的改变信道，FCA不能适应不断变化的交通状况和用户分布，以静态的方式进行统一的信道分配，不能根据负载来动态分配信道。会因为信道的使用率和资源分布不均衡导致时延过高，故切换时延最高。DCA的所有信道可用于整个网络，根据每个RSU的负载需求进行动态分配选择切换的信道。相对于FCA而言，其切换时间较低。EMM-LSI通过不断地学习来得到最佳的RSU信息，但是该算法需要很多学习的次数，才能获取到准确的信息，导致学习时间很长，最终切换时间会比ODCA长。

表3 模拟参数表

参数	数值
输入数据的大小 $d_{i,j}$	300~1600 kB
噪声功率 σ^2	0.1~1.0 GHz
MEC服务器CPU周期频率 f^C	6 GHz
最大延迟容限 T^{th}	6 s
迭代次数 I_{dd}	600
最大传输功 P^{max}	23 dBm
传输带宽 W	20 MHz
任务执行时所需的CPU周期数 $c_{i,j}$	0.1~1.0 GHz

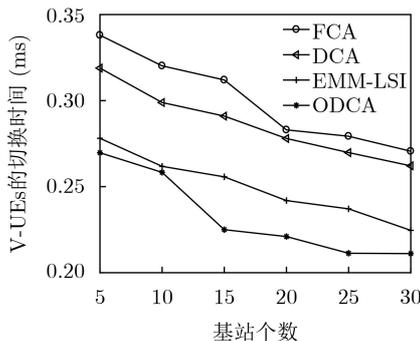


图2 基站数目对切换时间的影响

图3显示了随着车辆用户密度的增加，平均时延开始快速增加然后缓慢下降。这是因为随着V-UE密度的增加，V-UE在基站的覆盖区域下的概率增加。但当V-UE的密度增加到特定值时，用户可以实现等效的均匀分布，并且V-UE在覆盖区域下的概率将是恒定的，V-UE与RSU之间的最小距离将减小，又因为MEC服务器放在RSU侧，RSU到MEC服务器之间的距离比RSU到云端之间的距离短，因此平均时延最后会下降。同时，也反映了输入数据越大，平均时延越高。

图4对比了在不同负载量的情况下迁移前后的时延变化，图4显示了不管负载量的大小，迁移后的总时延总是小于迁移前的总时延，由此可说明迁移可以降低时延。同时迁移前后的降低率呈下降趋势正好也反映了迁移后总时延降低。当负载量增加时，由于MEC服务器的资源和处理能力有限，同时处理的请求数增加了，需要对任务进行迁移，并且迁移的时间会增加。

图5显示了在不同虚拟机个数的条件下资源利用率方面的比较。本文将基于RSU调度下的合作博弈算法与移动预测算法^[16]、虚拟机自动部署算法^[17]和马尔科夫链^[18]比较。随着虚拟机个数的增加，所有方案的资源利用率都在增加，从图5中可看出本文的方案可获得比其他方案更高的资源利用率。该方案采用TCS的RSU调度机制，并通过合作博弈算法实现资源利用的增益。尤其是基于Q学习的方法可

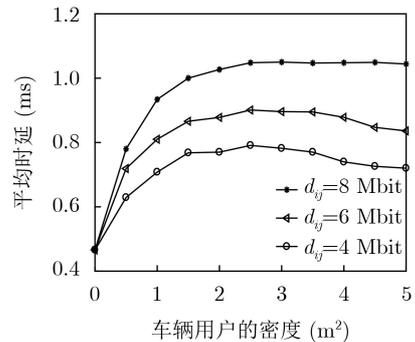


图3 车辆用户的密度对平均时延的影响

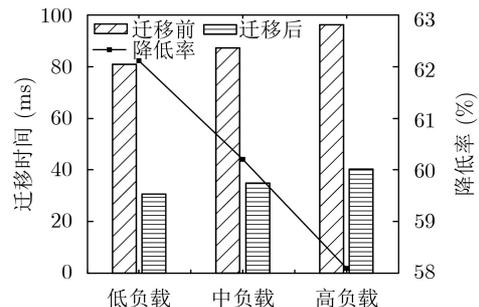


图4 不同负载大小下总时延的变化情况

以监控当前的状态并适应高度动态的环境。因此，ENs从环境中获取信息和知识，并以自适应的方式做出明智的决策。

图6显示了需要迁移的虚拟机个数与服务失败率之间的关系。服务失败率就是MEC系统中虚拟机迁移时服务失败的概率。通常，随着虚拟机数量的增加，意味着迁移请求量的增加，服务失败概率也增加。从图6中可看出，基于RSU调度的合作博弈算法相比其他两个算法而言，服务失败率更低。由于基于RSU调度的合作博弈算法在Q学习过程运行之后，动态选择价格策略，同时了解V-UEs的倾向。因此，本文可以自适应地决定价格策略，通过反复的学习可以保持较低的服务失败概率。

6 结论

车联网中车载单元的快速移动性，使网络拓扑动态变化，可能导致服务中断。为了解决服务连续性的问题，提高服务质量和用户体验，本文整合了CDN与MEC框架，通过TCS调度车辆用户至最优边缘节点的RSU。在TCS调度系统中设计了开销选择的动态信道分配算法来减少切换时间，采用基于RSU调度的合作博弈算法来解决VM迁移问题。根据VM迁移决策、边缘节点和V-UEs之间的合作和基于学习的价格调整来减少时延与能耗的加权和，并且提高了资源利用率。

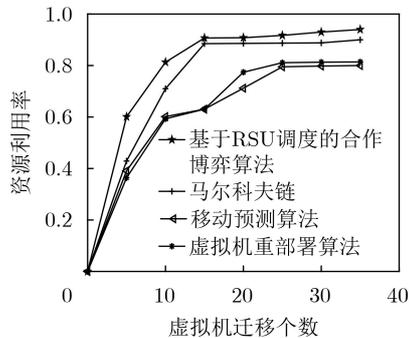


图5 迁移虚拟机的个数和资源利用率之间的关系

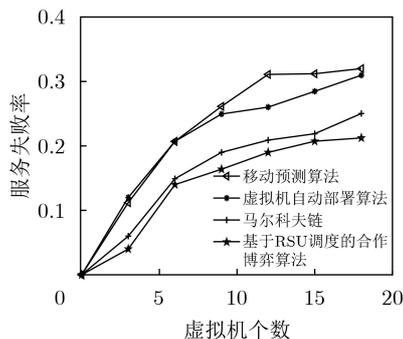


图6 虚拟机个数与服务失败率之间的关系

参考文献

- [1] ZHOU Siyu, NETALKAR P P, CHANG Yanan, *et al.* The MEC-based architecture design for low-latency and fast hand-off vehicular networking[C]. The 88th Vehicular Technology Conference, Chicago, USA, 2018: 1–7. doi: [10.1109/VTCFall.2018.8690790](https://doi.org/10.1109/VTCFall.2018.8690790).
- [2] BASTUG E, BENNIS M, MEDARD M, *et al.* Toward interconnected virtual reality: Opportunities, challenges, and enablers[J]. *IEEE Communications Magazine*, 2017, 55(6): 110–117. doi: [10.1109/MCOM.2017.1601089](https://doi.org/10.1109/MCOM.2017.1601089).
- [3] LIN Mengdan and ZHAO Xuelin. Application research of neural network in vehicle target recognition and classification[C]. 2019 International Conference on Intelligent Transportation, Big Data & Smart City, Changsha, China, 2019: 5–8. doi: [10.1109/ICITBS.2019.00010](https://doi.org/10.1109/ICITBS.2019.00010).
- [4] CICIRELLI F, GUERRIERI A, SPEZZANO G, *et al.* Edge computing and social internet of things for large-scale smart environments development[J]. *IEEE Internet of Things Journal*, 2018, 5(4): 2557–2571. doi: [10.1109/JIOT.2017.2775739](https://doi.org/10.1109/JIOT.2017.2775739).
- [5] YALA L, FRANGOUDIS P A, and KSENTINI A. QoE-aware computing resource allocation for CDN-as-a-service provision[C]. 2016 IEEE Global Communications Conference, Washington, USA, 2016: 1–6. doi: [10.1109/GLOCOM.2016.7842182](https://doi.org/10.1109/GLOCOM.2016.7842182).
- [6] LIU Jiayi, YANG Qinghai, and SIMON G. Congestion avoidance and load balancing in content placement and request redirection for mobile CDN[J]. *IEEE/ACM Transactions on Networking*, 2018, 26(2): 851–863. doi: [10.1109/TNET.2018.2804979](https://doi.org/10.1109/TNET.2018.2804979).
- [7] XU Jie, SUN Yuxuan, CHEN Lixing, *et al.* E2M2: Energy efficient mobility management in dense small cells with mobile edge computing[C]. 2017 IEEE International Conference on Communications, Paris, France, 2017: 1–6. doi: [10.1109/ICC.2017.7996855](https://doi.org/10.1109/ICC.2017.7996855).
- [8] PENG Han, RAZI A, AFGHAH F, *et al.* A unified framework for joint mobility prediction and object profiling of drones in UAV networks[J]. *Journal of Communications and Networks*, 2018, 20(5): 434–442. doi: [10.1109/JCN.2018.000068](https://doi.org/10.1109/JCN.2018.000068).
- [9] LIU Fangming, SHU Peng, and LUI J C S. AppATP: An energy conserving adaptive mobile-cloud transmission protocol[J]. *IEEE Transactions on Computers*, 2015, 64(11): 3051–3063. doi: [10.1109/TC.2015.2401032](https://doi.org/10.1109/TC.2015.2401032).
- [10] XU Fei, LIU Fangming, LIU Linghui, *et al.* iAware: Making live migration of virtual machines interference-aware in the cloud[J]. *IEEE Transactions on Computers*, 2014, 63(12): 3012–3025. doi: [10.1109/TC.2013.185](https://doi.org/10.1109/TC.2013.185).

- [11] CHEN Hongyang, WU Jianming, and SHIMOMURA T. New reference signal design for URLLC and eMBB multiplexing in new radio wireless communications[C]. 2018 IEEE 29th Annual International Symposium on Personal, Indoor and Mobile Radio Communications, Bologna, Italy, 2018: 1220–1225. doi: [10.1109/PIMRC.2018.8580882](https://doi.org/10.1109/PIMRC.2018.8580882).
- [12] KHAN Z, FAN Pingzhi, ABBAS F, *et al.* Two-level cluster based routing scheme for 5G V2X communication[J]. *IEEE Access*, 2019, 7: 16194–16205. doi: [10.1109/ACCESS.2019.2892180](https://doi.org/10.1109/ACCESS.2019.2892180).
- [13] WANG Chenmeng, YU F R, LIANG Chengchao, *et al.* Joint computation offloading and interference management in wireless cellular networks with mobile edge computing[J]. *IEEE Transactions on Vehicular Technology*, 2017, 66(8): 7432–7445. doi: [10.1109/TVT.2017.2672701](https://doi.org/10.1109/TVT.2017.2672701).
- [14] JOSHI G, VIG R, and SINGH S. DCA-based unimodal feature-level fusion of orthogonal moments for Indian sign language dataset[J]. *IET Computer Vision*, 2018, 12(5): 570–577. doi: [10.1049/iet-cvi.2017.0394](https://doi.org/10.1049/iet-cvi.2017.0394).
- [15] SUN Yuxuan, ZHOU Sheng, and XU Jie. EMM: Energy-aware mobility management for mobile edge computing in ultra dense networks[J]. *IEEE Journal on Selected Areas in Communications*, 2017, 35(11): 2637–2646. doi: [10.1109/JSAC.2017.2760160](https://doi.org/10.1109/JSAC.2017.2760160).
- [16] PLACHY J, BECVAR Z, and STRINATI E C. Dynamic resource allocation exploiting mobility prediction in mobile edge computing[C]. 2016 IEEE 27th Annual International Symposium on Personal, Indoor, and Mobile Radio Communications, Valencia, Spain, 2016: 1–6. doi: [10.1109/PIMRC.2016.7794955](https://doi.org/10.1109/PIMRC.2016.7794955).
- [17] CHEN Xiaojing, NI Wei, COLLINGS I B, *et al.* Automated function placement and online optimization of network functions virtualization[J]. *IEEE Transactions on Communications*, 2019, 67(2): 1225–1237. doi: [10.1109/TCOMM.2018.2877336](https://doi.org/10.1109/TCOMM.2018.2877336).
- [18] FRANGOUDIS P A and KSENTINI A. Service migration versus service replication in Multi-access Edge Computing[C]. 2018 14th International Wireless Communications & Mobile Computing Conference, Limassol, Cyprus, 2018: 124–129. doi: [10.1109/IWCMC.2018.8450284](https://doi.org/10.1109/IWCMC.2018.8450284).
- 张海波：男，1979年生，副教授，研究方向为无线资源管理。
程妍：女，1994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。