

车联雾计算中的异构接入与资源分配算法研究

熊凯¹, 冷甦鹏¹, 张可², 刘浩³

(1. 电子科技大学信息与通信工程学院, 四川 成都 611731; 2. 北京市交通运行监测调度中心, 北京 100161; 3. 北京市交通信息中心, 北京 100161)

摘要: 随着智能交通的发展, 自动驾驶、智能车载交互、安全预警等新型车载应用不断涌现, 独立车辆依靠自身有限的计算资源难以运行这些种类繁多且具有大量计算需求和时延需求的应用。雾计算通过将计算任务分布在网络边缘的设备中, 运用虚拟化、分布式计算和并行计算技术, 使用户能够按需动态地获取计算能力、存储空间等服务。将雾计算架构应用于车联网能够有效缓解计算量大、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。从分析车-车通信、车-基础设施通信以及车辆时延容忍网络通信的信道容量入手, 建立车联网异构接入的多业务资源优化模型, 通过联合调度各类车联雾资源, 实现智能交通应用的高效处理。仿真结果表明, 所提出的强化学习算法能够有效地应对异构车联雾架构下的资源优化。

关键词: 车联网; 车联雾; 车辆时延容忍网络; Q 学习算法; 资源分配

中图分类号: TN929

文献标识码: A

doi: 10.11959/j.issn.2096-3750.2019.00108

Research on heterogeneous radio access and resource allocation algorithm in vehicular fog computing

XIONG Kai¹, LENG Supeng¹, ZHANG Ke², LIU Hao³

1. School of Information and Communication Engineering, University of Electronic Science and Technology of China, Chengdu 611731, China;

2. Beijing Municipal Transport Operation Coordinate Center, Beijing 100161, China;

3. Beijing Transportation Information Center, Beijing 100161, China

Abstract: With the development of intelligent transportation and the constant emergence of new vehicular on-board applications, such as automatic driving, intelligent vehicular interaction and safety driving. It is difficult for an independent vehicle to run a wide variety of applications with a large number of computing needs and time delay needs relying on its own limited computing resources. By distributing computing tasks in devices on the edge of the network, fog computing applies virtualization technology, distributed computing technology and parallel computing technology to enable users to dynamically obtain computing power, storage space and other services on demand. Applying fog computing architecture to Internet of vehicles can effectively alleviate the contradiction between the large computing-low delay demands and limited vehicular resources. By analyzing the channel capacity of vehicle-to-vehicle communication, vehicle-infrastructure communication and vehicle-time-delay tolerant network communication, an optimization model of heterogeneous access to multi-service resources for the Internet of vehicles was established, and various vehicle-to-fog resources were jointly dispatched to realize efficient processing of intelligent transportation applications. The simulation results show that the proposed reinforcement learning algorithm can effectively deal with the resource allocation in the heterogeneous vehicular fog architecture.

Key words: Internet of vehicles (IoV), vehicular fog, vehicular delay tolerant network (VDTN), Q -learning algorithm, resource allocation

收稿日期: 2019-03-16; 修回日期: 2019-04-20

基金项目: 国家重点研发项目 (No.2018YFC0807101); 国家自然科学基金重点资助项目 (No.61731006); 四川省科技计划项目 (No.2019YFH0007); 欧盟地平线 2020 计划项目 COSAFE (No. MSCA-RISE-2018-824019)

Foundation Items: The National Key R&D Program of China (No.2018YFC0807101), The State Key Program of National Natural Science Foundation of China (No.61731006), Sichuan Province Science and Technology Program (No.2019YFH0007), The European Union's Horizon 2020 Research (No.MSCA-RISE-2018-824019)

1 引言

随着智能交通应用的发展, 为车辆间信息传输提供通信支撑的车联网技术正日益受到人们的关注。车联网是物联网技术在智能交通领域的具体应用, 利用高效的车联网信息协同通信平台, 可以改善交通运行效率, 有效提升车辆行驶的安全性。近年来, 随着车辆安全预警、自动驾驶、车载多媒体等应用的发展, 对车辆的计算、存储能力提出了更高要求, 同时, 车辆本身有限的资源和车辆间不均的资源分布给大量车载应用的普及增加了难度。

雾无线接入网 (F-RAN, fog radio access network) 作为 5G 无线通信系统云无线接入网 (C-RAN, cloud radio access network) 架构的一种延伸, 在 F-RAN 下利用边缘网络的分布式计算能够降低无线前传和基带处理单元 (BBU, baseband processing unit) 的负载。F-RAN 不仅能在保证高效通信的同时提升频谱效率, 还能有效降低网络边缘业务的时延。当前对 F-RAN 的研究主要集中在对 5G 中 F-RAN 架构的性能分析^[1]、计算通信资源的联合分配^[2]、F-RAN 的内容缓存和投递技术^[3]以及 F-RAN 架构下的移动管理和干扰消除分析^[4]。F-RAN 低时延、高可靠的特性符合 5G 车联网的业务需求, 然而现有文献^[5-6]对车联雾计算 (VFC, vehicular fog computing) 架构的探讨仅局限于考虑一些应用场景下 VFC 架构存在的问题, 没有系统地描述 VFC 架构下的异构接入方式。在参考文献[5]中, 作者提出了将车辆视为通信/计算基础设施的想法, 更好地利用每个车辆的个体通信和计算资源, 协同多个车辆组成车队或协同附近的边缘基础设施来满足业务通信和计算需求。参考文献[7]探讨了从机会时延容忍网络 (opportunistic delay tolerant network) 到车辆时延容忍网络 (VDTN, vehicular delay tolerant network) 的演变过程, 介绍了 VDTN 适用的场景, 并评估了 VDTN 对不同车联雾场景的适用性。参考文献[8]给出了基于用户大数据的存储—转发方式下的通信资源分配算法。参考文献[9]提出了 3P3B-DTN 多跳广播协议在频繁中断的车载网络中具有低信令开销。

多样化和定制化的智能交通业务需要更多的通信、计算资源以及更高的时延和可靠性保证。在异构车联雾场景中, 不同范围、不同处理单元 (车

辆、路旁基础设施) 可能存在通信、计算能力的差异性, 当某一部分的业务实体出现资源短缺时, 可以利用 V2X (vehicle-to-everything, 包括 V2V 和 V2I) 与 VDTN 等多种接入方式, 实现不同局部范围内实体间的资源共享^[9]。资源雾的引入使得车联雾环境中的实体 (拥有一定的通信/计算资源的车辆与基础设施) 间的资源优化调度策略变得更加灵活和复杂, 如何进行通信、计算资源的合理分配, 实现不同局部范围内实体间的资源高效利用, 也是 F-RAN 在车联雾中部署应用的关键问题^[10]。参考文献[11]针对移动边缘计算 (MEC, mobile edge computing) 所带来的高带宽、低时延优势, 结合 LTE 免授权频谱 (LTE-U) 技术, 研究了车辆异构网络中基于 MEC 的任务卸载模式决策和资源分配问题。在目前的车联雾资源分配方案中, 很少有将 VDTN 作为车联雾的一种通信资源。

本研究借鉴了将车辆当作基础设施的思想, 将 VDTN 视为车联雾场景的一种特殊接入方式, 系统性地对异构车联雾中的车—车通信 (V2V, vehicles-to-vehicles)、车—路旁基础设施通信 (V2I, vehicles-to-infrastructures) 以及 VDTN 通信进行了信道容量分析。在 V2X 与 VDTN 的异构场景下, 提出了针对满足多业务时延与计算需求的优化模型, 在此模型基础上, 提出了 Q-learning 强化学习^[12-13]的解决方案。通过对比数值仿真结果验证了 Q-learning 算法的有效性, 其性能比贪婪算法和随机算法有较大提升, 时间复杂度也远小于 CE based MCTS。

2 系统模型

2.1 雾化车联雾模型

雾化车联雾 (VF-RAN, vehicular fog-RAN) 接入架构与资源协同如图 1 所示, VF-RAN 接入架构主要分为资源雾层与决策层, 其中, 资源雾层主要负责资源的雾化过程与资源共享。VF-RAN 接入架构中, 雾的形成是基于 5G 网络切片的资源划分, 结合一个切片下所划分的通信、计算和存储资源, VF-RAN 的 SDN 管理器能够根据不同的业务需求分配天线、功率、计算资源到基础设施和车辆, 实现雾资源的高效构建。本研究中资源雾层的车联雾包含由路旁接入设施 (RSU、gNB) 组成的边缘雾和由车队形成的车队雾。决策层则对应 VF-RAN 中的接入策略定制和相应的资源分配管理, 此部分的

功能可由 SDN 控制器管理实现。决策层完成了计算卸载、接入选择以及后续的资源分配过程。

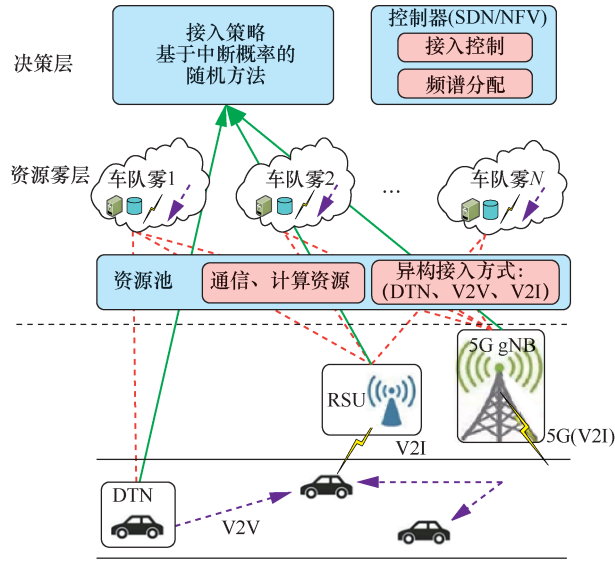


图1 VF-RAN 接入架构与资源协同

2.2 车联网业务模型

为不失一般性，车联网业务需要一定的计算资源和相应的时延要求。使用 $\mathbf{D} = \{d_1, d_2, \dots, d_m\}$ 表示不同业务所需的计算资源的向量。其中， d_i 表示业务 I 的计算频率需求。使用 $\boldsymbol{\tau} = \{t_1^{\max}, t_2^{\max}, \dots, t_m^{\max}\}$ 表示业务的最大时延要求。其中， t_1^{\max} 为业务 I 所能容忍的最大时延。由此，业务 $\Psi = \{\psi_1, \psi_2, \dots, \psi_m\}$ 可表示为 $\psi_\zeta = \{d_\zeta, t_\zeta^{\max}\}$ ， ψ_ζ 为第 ζ 类业务。考虑车联网特有业务对时延、计算的需求，也将对通信产生相应的约束。例如，车辆间的 V2V 通信形成雾时，安全告警类业务的传输可能需要多跳通信，但跳数的增加会引起时延增大，导致可靠性降低。因此，需要将不同车联网业务的需求映射为对通信接入方式和计算资源的选择。

2.3 车联网接入模型

车联网通常是异构接入网络，能够高效地利用有限的通信计算资源以保证多样化的服务质量 (QoS, quality of service) 需求。如图 1 所示，本研究提出将携带信息的车辆在道路上的行驶过程视为一种时延容忍网络 (DTN, delay tolerant network)。配合传统的 V2X 接入，能够更好地应对复杂时变的车联网环境，实现车联网资源的最优分配。

2.3.1 V2X 接入方式

为不失一般性，本研究假设一共有 L 个路旁接

入设施 (RSU 或 gNB)。同时，每一个路旁接入设施都配置相应的边缘服务器， $L = \{1, 2, \dots, L\}$ ， L 为全体路旁设施的集合。各个路旁接入设施都有相应的覆盖范围，如果车辆已经进入路旁接入设施 i 的范围内，则可以直接进行 V2I 通信。而对于 V2V 通信，多车辆间可通过 V2V 方式形成车队雾，可在车队雾中进行任务分解与处理，不需要再上传至边缘服务器，在多车资源协同中，完成相应的车联网业务。本研究中，V2V 通信共有 j 对， $J = \{1, 2, \dots, j\}$ ，其中， J 为 V2V 通信对的集合。

同时，V2V 与 V2I 共享频谱资源。其中，可用频段共有 q 个， $\kappa = \{\varrho_1, \varrho_2, \dots, \varrho_q\}$ ， ϱ_l 为第 l 个可用频段。对于进行 V2V 通信的车辆 j 与车辆 i 而言，车辆 j 的 SINR 可表示为

$$\Xi_{j,V2V}^\varrho = \frac{\sqrt{P_{i,V2V}^\varrho d_{ij}^{-\alpha} h_{ij,V2V}^\varrho}}{I_{j,V2V} + n} \quad (1)$$

其中， $P_{i,V2V}^\varrho$ 为车辆 i 在频段 ϱ 上进行 V2V 通信的发送功率。 n 为均值为 0 的高斯白噪声。 d_{ij} 为车辆 i 与车辆 j 的间距，一般而言，由于车辆 i 与车辆 j 在同一车队中，因此 i 与 j 的间距在时间间隔 ΔT 内，可认为近似不变。 α 为路径损耗指数。 $h_{ij,V2V}^\varrho$ 为在频段 ϱ 下的 i 与 j 之间的 V2V 信道增益。 $I_{j,V2V}$ 为车辆 j 在 V2V 通信时的干扰项，可表示为

$$I_{j,V2V} = \sum_{l \neq i,j}^{N^\varrho} \sqrt{P_{l,V2V}^\varrho d_{lj}^{-\alpha} h_{lj,V2V}^\varrho} + \sum_{r=1}^{\varpi L^\varrho} \sqrt{P_{r,V2I}^\varrho (d_{rj} + \frac{\Delta T v}{2})^{-\alpha} h_{rj,V2I}^\varrho} + \sum_{r=\varpi L^\varrho}^{L^\varrho} \sqrt{P_{r,V2I}^\varrho (d_{rj} - \frac{\Delta T v}{2})^{-\alpha} h_{rj,V2I}^\varrho} \quad (2)$$

其中， N^ϱ 为在车队中处于频段 ϱ 的车辆数目，本研究假设只有同一车队的车辆间会相互干扰。车辆 j 在时间间隔 ΔT 内，向 $(1-\varpi)L^\varrho$ 个路旁设施平均靠近了 $\frac{\Delta T v}{2}$ ，向 ϖL^ϱ 个路旁设施平均远离了 $\frac{\Delta T v}{2}$ 。 v 为车辆平均速度。 ϖ 为远离的路旁设施所占总路旁设施的比例。则 V2V 的信道容量为

$$\mathfrak{R}_{V2V} = W \log(1 + \Xi_{j,V2V}^\varrho) \quad (3)$$

其中， W 为频段 ϱ 的带宽，本研究假设各个频段带宽均为 W 。

对于 V2I 通信而言, 路旁接入设施 l 与车辆 j 通信时的 SINR 可表示为

$$\Xi_{l,v2i}^e = \frac{\sqrt{P_{j,v2i}^e \left(d_{lj} \pm \frac{\Delta T v}{2} \right)^{-\alpha}} h_{lj,v2i}^e}{I_{l,v2i} + n} \quad (4)$$

$P_{j,v2i}^e$ 为车辆 j 在频段 ρ 上进行 V2I 通信的发送功率。 d_{lj} 为路旁接入设施 l 与车辆 j 间的间距, 由于车辆 j 处于运动状态, 因此在时间间隔 ΔT 内, 与路旁接入设施 l 的平均距离为 $(d_{lj} \pm \frac{\Delta T v}{2})$, 其中, \pm 表示靠近或远离路旁接入设施。 $h_{lj,v2i}^e$ 为在频段 ρ 下的 l 与 j 之间的 V2I 信道增益。 $I_{l,v2i}$ 为路旁接入设施 l 在 V2I 通信时的干扰项, 可表示为

$$I_{l,v2i} = \sum_{i \neq j}^{N^e} \sqrt{P_{i,v2i}^e \left(d_{ij} \pm \frac{\Delta T v}{2} \right)^{-\alpha}} h_{ij,v2i}^e + \sum_{r=1, \neq i}^{L^e} \sqrt{P_r^e (d_{ri})^{-\alpha}} h_{ri}^e \quad (5)$$

其中, N^e 为在车队中处于频段 ρ 的车辆数目。处在频段 ρ 的路旁接入设施数目为 L^e , 而这些路旁设施 (RSU/gNB) 均会影响路旁接入设施 i 。 h_{ri}^e 为路旁接入设施 r 到路旁接入设施 i 的信道增益。 P_r^e 为路旁接入设施 r 的发射功率。因此, V2I 的信道容量为

$$\mathfrak{R}_{v2i} = W \log(1 + \Xi_{l,v2i}^e) \quad (6)$$

2.3.2 存储—转发接入方式

本研究将道路上具有一定计算、存储资源的车辆视为 DTN。这些车辆可采用存储—转发机制, 相应的数据分组由源节点附近的车辆接收, 行驶到目的节点附近再进行报文投递。此种方式的优点是节约了大量的信道带宽, 尤其是在大规模接入场景中能够有效地实现数据分组的投递。然而, 此种方式的缺点也十分明显, 其时延一般较 V2X 更长, 适合时延不敏感类型业务。在本研究中, 将这种车辆的 DTN 称为 VDTN。基于宏观车流模型^[14], 车流满足连续状态方程

$$\frac{\partial \rho(a,t)}{\partial t} + \nabla \cdot f = 0 \quad (7)$$

其中, $\rho(a,t)$ 代表在时间 t 区域 a 中的车辆密度。 $f = \rho(a,t)v$ 为方向朝外的车流量, v 为道路上车辆的平均速度, ∇ 为梯度算子。本研究中, 每个车辆

自身会携带一定的计算资源和相应的业务需求。在此, 定义 $[t_0, t_0 + \Delta T]$ 时段的剩余计算资源

$$w(a,t) = \rho(a,t)k - B(\rho(a,t)) + K_c(a,t) \quad (8)$$

其中, k 是一个车辆自身能够消化的业务计算量。 $\rho(a,t)k$ 代表地域 a 在时段 t 的计算资源总量。 $B(\rho(a,t))$ 代表地域 a 在时段 t 的业务需求, 与车辆密度 $\rho(a,t)$ 相关。 $K_c(a,t)$ 是通过通信带走的计算量, 与地域 a 和时段 t 相关。在式(8)等号两边对时间 t 求偏导, 得到

$$\frac{\partial w}{\partial t} = \frac{\partial K_c}{\partial t} + \left(k - \frac{dB}{d\rho} \right) \frac{\partial \rho(a,t)}{\partial t} = \frac{\partial K_c}{\partial t} + \left(\frac{dB}{d\rho} - k \right) \nabla f \quad (9)$$

为了在各个区域达到计算资源均衡, 在剩余计算资源 $w(a,t)$ 多的区域, 其计算资源有向剩余计算资源少的区域流动的趋势。即如果 $w(a,t) < w(b,t)$, 则 w 有从 a 流向 b 的趋势。然而, w 在时段 ΔT 内近似为守恒量。同理, 可针对 w 运用连续状态方程得到

$$\frac{\partial \rho_w(a,t)}{\partial t} + \nabla \cdot f_w = 0 \quad (10)$$

其中, $\rho_w(a,t)$ 为 w 在时间 t 区域 a 中的密度。 f_w 为方向朝外的 w 流量。为不失一般性, 本研究中区域 a 的面积设为 1。在此前提下, $w(a,t) = \rho_w(a,t)$ 。于是式(10)可变形为

$$\frac{\partial K_c}{\partial t} + \left(\frac{dB}{d\rho} - k \right) \nabla f = -\nabla f_w \quad (11)$$

据流体热力学^[15]可知, 流量 f_w 近似正比于 w 对于位置的变化率。由扩散方程可得

$$f_w(a,t) = -J \nabla w(a,t) \quad (12)$$

其中, J 为传导系数。将式(12)代入式(11)得

$$\nabla^2 w + \left(k - \frac{dB}{d\rho} \right) \nabla f = \frac{\partial K_c}{\partial t} \quad (13)$$

式(13)中 $\frac{dB}{d\rho}$ 代表业务需求随着密度 ρ 的变化率。 K_c 为通过通信资源等效换取的计算资源, 即将自身产生的业务卸载到远端。那么, $\frac{\partial K_c}{\partial t}$ 即单位时间内所传输的计算业务量。其中, \mathfrak{R}_{DTN} 为 VDTN 的信道容量。此外, $\nabla^2 w$ 有相应的物理解释: 表示剩余计算资源 $w(a,t)$ 在地域 a 是向外扩散计算资源

或是汇聚周围的计算资源。 $\nabla^2 w = 0$ 表示封闭区域中的任一部分具有相同的剩余计算量 $w(a, t)$ ，当满足 $\nabla^2 w = 0$ 时，称该区域处在均衡状态。当处于均衡状态时，车辆的移动会引起业务 B 和相应车流密度变化，而这些变化所造成的计算资源变动将被由通信换取的计算资源所抵消。但在此情况下，车辆只能携带一转发数据分组，这表明 $\frac{\partial K_c}{\partial t}$ 即 VDTN 所传输的业务量，可认为其是 VDTN 的信道传输速率，有

$$\mathfrak{R}_{\text{DTN}} = -\frac{dB}{d\rho} \nabla f \quad (14)$$

其中， $\nabla f = \nabla(\rho v)$ ，这里 ∇f 取决于具体的道路拓扑形态。为简化起见，本研究针对一维高速公路进行建模，在一维场景中如下关系

$$\nabla(\rho v) = \frac{v \partial \rho}{\partial x} + \frac{\rho \partial v}{\partial x} \quad (15)$$

式(15)中 x 为车流在一维道路上的位移距离。由于本研究假设各个车辆的速度 v 在道路上是近似恒定的，于是有 $\frac{\partial v}{\partial x} = 0$ 。式(14)可简化为

$$\mathfrak{R}_{\text{DTN}} = -\frac{dB}{d\rho} \cdot \frac{v \partial \rho}{\partial x} = -\frac{dB}{dx} v \quad (16)$$

即 VDTN 的通信容量在数值上等于业务在空间上的分布乘以车辆在道路上的平均速度。

2.4 计算卸载模型

对于车联网业务 $\Psi = (\psi_1, \psi_2, \dots, \psi_M)$ ， $\psi_\xi = \{d_\xi, t_\xi^{\max}\}$ ，为了将业务卸载到相应的其他计算单元进行处理，势必会产生相应的时延开销，其时延主要产生于以下几个阶段。

1) 上传时延阶段

$$\tau_\xi^{\text{up}} = \frac{d_\xi}{\mathfrak{R}_{\text{xxx}}} \quad (17)$$

其中， $\mathfrak{R}_{\text{xxx}} = \{\mathfrak{R}_{\text{V2V}}, \mathfrak{R}_{\text{V2I}}, \mathfrak{R}_{\text{DTN}}\}$ 。

2) 处理时延阶段

$$\tau_\xi^{\text{cal}} = \frac{\eta_\xi d_\xi}{y_\xi} \quad (18)$$

其中， η_ξ 为计算复杂度，与相应的业务类型 ξ 相关， y_ξ 为卸载处理单元的处理频率。

对于计算卸载而言，计算结果的回传时延一般忽略不计。于是计算卸载时延不应超过相应业务的时延需求，即

$$t_\xi^{\max} \geq \tau_\xi^{\text{up}} + \tau_\xi^{\text{cal}} \quad (19)$$

2.5 优化模型

由于车联网环境自身所具有的高动态性与业务突发性，式(19)其实很难得到保证，公式一旦不满足，即发生业务中断。本研究将最小化业务中断概率作为目标函数设计相应的优化模型。

$$\text{P1: } \min_{\lambda_{\text{V2V}}, \lambda_{\text{V2I}}} \text{Pr}[\tau_\xi^{\text{up}} + \tau_\xi^{\text{cal}} \leq t_\xi^{\max}]$$

$$\text{s. t. C1: } 0 \leq \lambda_{\text{V2V}} \leq 1$$

$$\text{C2: } 0 \leq \lambda_{\text{V2I}} \leq 1$$

$$\text{C3: } 0 \leq 1 - \lambda_{\text{V2V}} - \lambda_{\text{V2I}} \leq 1$$

$$\text{C4: } \tau_\xi^{\text{up}} =$$

$$\frac{d_\xi}{\lambda_{\text{V2V}} \mathfrak{R}_{\text{V2V}} + \lambda_{\text{V2I}} \mathfrak{R}_{\text{V2I}} + (1 - \lambda_{\text{V2V}} - \lambda_{\text{V2I}}) \mathfrak{R}_{\text{DTN}}}$$

$$\text{C5: } \tau_\xi^{\text{cal}} = \frac{\eta_\xi d_\xi}{\lambda_{\text{V2V}} y_{\text{platoon}} + \lambda_{\text{V2I}} y_{\text{infrastructure}} + (1 - \lambda_{\text{V2V}} - \lambda_{\text{V2I}}) y_{\text{mix}}} \quad (20)$$

其中，优化变量为 λ_{V2V} 和 λ_{V2I} 。 λ_{V2V} 为采用 V2V 卸载业务的比例； λ_{V2I} 为采用 V2I 卸载业务的比例； $1 - \lambda_{\text{V2V}} - \lambda_{\text{V2I}}$ 为采用 VDTN 卸载业务的比例。由于采用的传输方式不同，上传时延可写为约束 C4 所示。在约束 C5 中，采用 V2V 通信时，业务将被传输到车队中进行处理，因此，其计算能力为车队的计算能力 y_{platoon} 。同理， $y_{\text{infrastructure}}$ 是边缘服务器的处理能力。 y_{mix} 是车队与边缘服务器协同计算后的混合处理能力。对于 VDTN 而言，由于车辆携带了业务一段时间（通过存储一转发机制），因此，可在这段时间处理部分业务计算量，之后到达目的节点，卸载剩余业务到相应的边缘服务器进行处理。

3 模型求解

优化问题 P1 为复杂的 NP-hard 问题，传统的优化方法难以有效求解。直观上来说，可以通过穷举法等暴力搜索方法求解。但由于车联网的时变特性和业务的突发不确定性，此类暴力求解或传统优化方法难以实现实时应对处理。基于此原因，本研究采用强化学习方法对优化问题 P1 进行分析求解。为了应用强化学习方法，首先要将优化问题 P1 转化为马尔可夫决策过程 (MDP, Markov decision process)。

3.1 MDP 建模

MDP 模型由元组 $\{S, A, P, R\}$ 构成。其中， S 代表

系统的状态集合; A 为智能体具有的动作集合; P 为状态转移矩阵, $P(s_g | s_{g-1}, a_{g-1})$ 表示状态 s_{g-1} 采取动作 a_{g-1} 后进入状态 s_g 。 R 表示回报函数, $R(s_g, a_g)$ 为在状态 s_g 下采取行动 a_g 后所有的回报。

1) 状态: 本研究将 (M_s, F_s, B_g) 作为系统的状态描述。 $M_s = \{(\mathfrak{R}_{V2V}, y_{\text{platoon}}), (\mathfrak{R}_{V2I}, y_{\text{infrastructure}}), (\mathfrak{R}_{DTN}, y_{\text{mix}})\}$ 给出了所有的卸载方案; $F_s = \{(C_{1s}, Z_{1s}), (C_{2s}, Z_{2s}), \dots, (C_{1n}, Z_{1n})\}$ 为在状态 s 下所形成的 n 个资源雾, 其中, C_{1s} 代表在状态 t 下, 资源雾中共享的通信资源, 而 Z_{2s} 是资源雾中共享的计算资源。 $B_g = \{(z_{1g}, d_{1g}), (z_{2g}, d_{2g}), \dots, (z_{mg}, d_{mg})\}$ 为业务在时刻 g 时所需的通信与计算资源, 其中, 通信资源 z_{1g} 与计算资源 d_{1g} 可由业务的描述 $\psi_\xi = \{d_\xi, t_\xi^{\max}\}$ 求解得到。

2) 动作: 一个动作为一次资源分配过程, 即随机选择一个资源雾将自己的通信/计算资源分配给当前需要处理的一个业务。 $a_g = \{1, 2, \dots, m\}$, m 为业务的种类数。

3) 转移概率: 在每个状态下, 如果该状态中的资源雾中的通信/计算资源被耗尽, 则 $P(s_g | s_{g-1}, a_{g-1}) = 0$ 。

此外, $P = \frac{1}{\Omega}$, Ω 为该状态中所有的通信/计算资源总和。

4) 回报函数: 本研究中的回报函数采用经典的数据分组接受率作为回报值

$$\text{Re} = \sum_{\xi=1}^m \frac{\zeta_\xi \Pi_\xi^{\text{accept}}}{\Pi_\xi^{\text{total}}} \quad (21)$$

其中, Π_ξ^{total} 为总到达的业务 ξ 的数目。 Π_ξ^{accept} 为接受处理的业务 ξ 数目。 这里的接受处理是指满足业务的通信/计算需求, 在最大时延 t_ξ^{\max} 内满足业务需求。 ζ_i 为业务 ξ 的权重系数, 不同的业务有不同的权重, 通常而言, 安全告警类业务比娱乐性业务更为重要, 因此, 相应的权重也就越大。

3.2 强化学习

本研究采用 Q -learning 方法进行问题求解。 在此, 构建一个 Q 值表 Q_{table} 。 Q_{table} 是一个二维矩阵, 由状态与动作构成

$$Q_{\text{table}}(s_g, a_g) = (1 - \alpha) Q_{\text{table}}(s_g, a_g) + \alpha (\text{Re}_s + \zeta \max_a Q_{\text{table}}(s_{g+1}, a)) \quad (22)$$

其中, $\zeta < 1$ 代表折扣因子; α 为学习速率; 一个动

作 a 代表对资源雾中单位通信/计算资源的一次分配, 即单位通信资源被分配 $C_{gs} - 1$ 或单位计算资源被分配 $Z_{gs} - 1$ 。 Q 为动作效用函数 (action-utility function), 用于评价在特定状态下采取某个动作的优劣。

该系统从一个资源未分配的起始状态出发 $(M_s, 0, B_g)$, 按照 Q_{table} 更新策略去探索环境, 生成一个从起始状态到终止状态的状态—动作—奖励序列。 终止状态为当前资源都分配到每个资源雾中 $(0, F_s, B_g)$ 。

4 仿真结果与分析

本研究在 MATLAB 环境下对车联网在 V2V、V2I 以及 VDTN 3 种接入方式下的传输速率进行数值仿真, 对比了在不同车辆行驶速度下的 3 种接入方式的传输速率 \mathfrak{R}_{V2V} 、 \mathfrak{R}_{V2I} 和 \mathfrak{R}_{DTN} 。 本仿真实验一共有 9 个路旁接入设施, 其中 5 个接入设施随车辆的移动而逐渐远离车辆, 在初始时刻 t_0 , 5 个接入设施与车辆 i 的距离为 [23, 22, 10, 25, 36], 其信道增益分别为 [1, 1, 2, 2, 1]; 剩余 6 个接入设施随车辆的移动而逐渐靠近车辆, 初始距离为 [21, 36, 25, 24], 其信道增益为 [1, 1, 1, 1]。 路段中一共有 7 辆车, 其中, 4 辆车驶离接入设施 j , 初始距离为 [21, 36, 25, 24], 信道增益为 [1, 1, 1, 1]; 3 辆车靠近接入设施 j , 初始距离为 [17, 25, 26], 信道增益为 [1, 1, 2]。

车联网异构接入的传输速率与车辆平均行驶速率关系如图 2 所示。 从图 2 可以看出, V2V 与 V2I 的传输速率都随车辆速度的增加而降低, 表明传统车联网 V2X 接入方式的传输性能在高速行驶下难以保证较好的服务质量。 车辆速度的加快使得车辆连入路旁接入设施的有效传输时间大幅度缩短, 因此, 代表 V2I 接入的曲线随车辆平均速度的提升在一开始就大幅下降, 在车辆速度为 3~20 m/s 时, 急剧下降。 然而, 对于 V2V 而言, 在车辆速度为 3~30 m/s 时, 并没有太大变化, 其原因是 V2V 主要针对车队内部的 V2V 直连通信, 车队内部的车辆由于彼此的相对速度可以认为近似为 0, 且不会受车辆道路平均速度的影响。 但是, 当速度达 30 m/s 以上时, 车队将十分频繁地接触来自路旁接入设施的影响, 如在 5 min 内, 车辆低速行驶只会通过一个 RSU/gNB, 但在高速行驶时可能连续通过多个 RSU/gNB。 因此, 通信质量也会出现大幅度降低。




图2 车联网异构接入的传输速率与车辆平均行驶速率关系

对于 VDTN 通信而言, 车辆的高速行驶意味着携带—转发的效率大大提高。为了简化, 本数值仿真中假设 $\frac{dB}{dx} = -0.01$ 。因此, 随着车辆行驶速度的提升, VDTN 的传输性能将呈线性增加。因此, 在高速行驶的环境下, VDTN 接入方式可能会成为比传统车联网 V2X 接入方式更好的选择。

Q-learning 算法、贪婪算法、随机算法和 CE based MCTS 算法在车联雾架构中的资源分配效率对比如图 3 所示。其中, CE based MCTS 算法在参考文献[16]中有介绍。在异构接入的车联雾场景中, 有 6 个资源雾 (车队雾与边缘雾) 和 10 类不同需求的业务, 本研究在此环境下进行边缘雾的计算与通信资源分配, 并在不同业务到达率的设定下进行不同算法的对比。

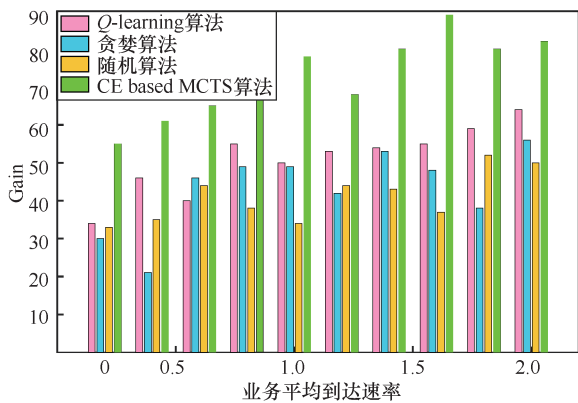


图3 Q-learning 算法、贪婪算法、随机算法和 CE based MCTS 算法在车联雾架构中的资源分配效率对比

图 3 中的纵坐标 Gain 定义为实际所处理的业务的通信与计算需求

$$Gain = N^{\text{processed}} \times (cm_i^p + cp_i^p) \quad (23)$$

其中, $N^{\text{processed}}$ 为实际接收处理的业务数目。如果边

缘雾中所分配的资源无法满足通信与计算业务需求, 业务将会被拒绝。图 3 中横坐标为业务平均到达速率。仿真中的业务服从均值为 $arriveRate+x$ 的泊松过程, $arriveRate$ 设定为 $arriveRate = \{2, 2, 3, 2, 3, 2.4, 1.3, 1.7, 1.4, 1.5\}$, 这里每一项对应不同业务的到达率。

由图 3 可知, 一般而言, 在不同的业务到达率下, Q-learning 算法的业务处理效率优于贪婪算法, 而贪婪算法优于随机算法。贪婪算法是在每一次资源分配过程中, 都选取使上一次分配过程的业务处理效率最大的方案; 随机算法则是在每一次分配过程中随机分配资源。但 CE based MCTS 算法的性能最好, 这是因为 CE based MCTS 算法在执行过程中会采取蒙特卡洛采样的步骤, 探索尽可能多的解空间, 同时也会拥有更大的计算与时间复杂度。在仿真实验中, CE based MCTS 算法平均运行时间约为 2.126 s, 而 Q-learning 算法平均运行时间仅为 0.047 s。Q-learning 算法之所以比贪婪算法更好, 且在保证时间复杂度的前提下效率更高, 是因为 Q-learning 算法能学习历史上的分配经验, 而贪婪算法则不具备学习的能力, 仅对当前做出最优选择, 难以实现整体最优。此外, 图 3 还对不同业务到达率下的业务处理效率进行了对比, 随着业务到达率 x 的增加, 各个算法的 Gain 值也会相应增大。

Q-learning 算法、贪婪算法和随机算法在不同仿真次数下的时间复杂度对比如图 4 所示。随机算法的时间复杂度最低, 而贪婪算法优于 Q-learning 算法。这里的时间复杂度为统计算法运行的时间。尽管 Q-learning 的时间复杂度最差, 但其与贪婪算法和随机算法的差距并不大, 均在同一数量级内。本仿真实验中, CPU 为七代 i5 低压版, ROM 为 8 GB, 仿真平台为 Mathematica。

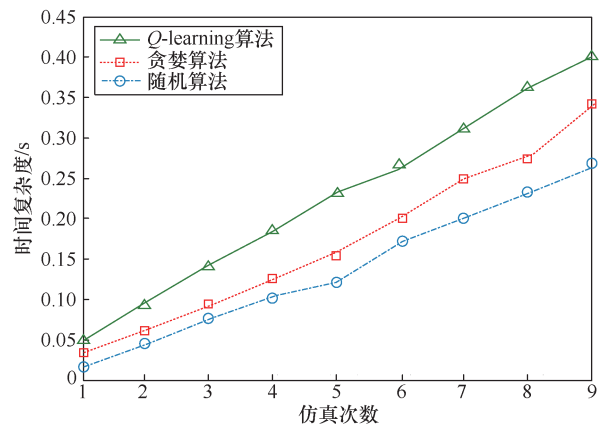


图4 Q-learning 算法、贪婪算法和随机算法在不同仿真次数下的时间复杂度对比

5 结束语

本文旨在分析异构车联网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V2V、V2I和VDTN接入方式的信道容量。从仿真分析结果可以看出, 在低速行驶场景中, 传统的V2X接入具有较好的通信性能; 而在高速行驶的场景中, VDTN接入则具有较好的通信性能。

同时, 本研究给出了车联网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。在仿真过程中, 比较了Q-learning算法、贪婪算法、随机算法以及CE based MCTS算法的性能。仿真结果表明, Q-learning算法在多业务动态到达的场景下具有低复杂度、资源分配效果较好等优点。但是, 本研究的仿真环境基于软件仿真和参数假设, 与实际的车联网场景可能存在区别, 需要在未来结合实际车联网环境进行验证。

参考文献:

- [1] PENG M, ZHANG K. Recent advances in fog radio access networks: performance analysis and radio resource allocation[J]. IEEE Access, 2016, 4(99): 1.
- [2] ZHANG H, QIU Y, LONG K, et al. Resource allocation in NOMA-based fog radio access networks[J]. IEEE Wireless Communications, 2018, 25(3): 110-115.
- [3] PARK S H, SIMEONE O, SHAMAI S. Joint optimization of cloud and edge processing for fog radio access networks[J]. IEEE Transactions on Wireless Communications, 2016, 15(11): 7621-7632.
- [4] ZHANG H, QIU Y, CHU X, et al. Fog radio access networks: mobility management, interference mitigation, and resource optimization[J]. IEEE Wireless Communications, 2017, 24(6): 120-127.
- [5] QIAO G, LENG S, ZHANG K, et al. Collaborative task offloading in vehicular edge multi-access networks[J]. IEEE Communications, 2018, 56(8): 48-54.
- [6] NI J, ZHANG A, LIN X, et al. Security, privacy, and fairness in fog-based vehicular crowdsensing[J]. IEEE Communications Magazine, 2017, 55(6): 146-152.
- [7] TORNELL S M, CALAFATE C T, CANO J C, et al. DTN protocols for vehicular networks: an application oriented overview[J]. IEEE Communications Surveys & Tutorials, 2017, 17(2): 868-887.
- [8] FAN B, LENG S, YANG K. A dynamic bandwidth allocation algorithm in mobile networks with big data of users and networks[J]. IEEE Network, 2016, 30(1): 6-10.
- [9] CHAKKAPHONG S, SUN Z. Multi-hop broadcast protocol in intermittently connected vehicular networks[J]. IEEE Transactions on Aerospace & Electronic Systems, 2018 (99): 1.
- [10] KUI X, SUN Y, ZHANG S, et al. Characterizing the capability of

vehicular fog computing in large-scale urban environment[J]. Mobile Networks and Applications, 2018, 23(4): 1050-1067.

- [11] 张海波, 栾秋季, 朱江, 等. 车辆异构网中基于移动边缘计算的任务卸载与资源分配[J]. 物联网学报, 2018, 2(3): 36-43.
ZHANG H B, LUAN Q J, ZHU J, et al. Task offloading and resource allocation in vehicle heterogeneous networks with MEC[J]. Chinese Journal on Internet of Things, 2018, 2(3): 36-43.
- [12] O'DONOGHUE B, MUNOS R, KAVUKCUOGLU K, et al. Combining policy gradient and Q-learning[C]//International Conference on Learning Representations(ICLR), 2017.
- [13] 张德干, 葛辉, 刘晓欢, 等. 一种基于Q-Learning策略的自适应移动物联网路由新算法[J]. 电子学报, 2018, 46(10): 2325-2332.
ZHANG D G, GE H, LIU X H, et al. A new adaptive mobile Internet of things routing algorithm based on Q-learning strategy[J]. Acta Electronica Sinica, 2018, 46(10): 2325-2332.
- [14] PICCOLI B, TOSIN A. Vehicular traffic: a review of continuum mathematical models[M]. New York: Springer, 2009.
- [15] MACISAAC D. Feynman lectures on physics three-volume text now completely freely available online[J]. Physics Teacher, 2014, 52(2): 126-126.
- [16] XIONG K, LENG S P, HU J, et al. Smart network slicing for vehicular fog-RAN[J]. IEEE Transactions on Vehicular Technology, 2019, 68(4): 3075-3085.

[作者简介]



熊凯 (1991-), 男, 四川巴中人, 电子科技大学博士生, 主要研究方向为车联网资源分配、移动边缘计算和机器学习。



冷甦鹏 (1973-), 男, 四川资中人, 电子科技大学教授、博士生导师, 主要研究方向为物联网、车联网、新一代宽带无线网络、无线自组织网、智能交通信息系统的资源管理、介质访问控制、路由、组网与互联、智能算法理论及技术应用等。



张可 (1974-), 男, 河南新乡人, 博士、研究员, 北京市交通运行监测调度中心副主任, 主要研究方向为智能交通技术研究与应用、北京市综合交通运行监测服务和运行分析。

刘浩 (1977-), 男, 四川资中人, 博士, 北京市交通信息中心副主任, 主要研究方向为智能交通技术交通建模和交通仿真等。