

面向软件定义多模态车联网的双时间尺度 RAN 切片资源分配

齐伟敬, 宋清洋, 郭磊

(重庆邮电大学通信与信息工程学院智能通信与网络安全研究院, 重庆 400065)

摘要: 为了有效满足不同车载应用的差异化服务质量需求, 针对软件定义多模态车联网提出了一种双时间尺度的无线接入网切片资源分配算法。考虑增强型移动宽带切片用户最小速率约束、车到车链路可靠性约束、节点最大功率约束、RB 约束等, 以最小化超可靠低时延切片用户的平均时延为目标, 建立缓存、频谱、功率联合资源分配模型。基于匈牙利算法、线性整数规划方法和 DDQN 算法, 将原 NP-hard 问题在双时间尺度内求解。仿真结果表明, 所提算法在保证不同切片用户服务质量需求和提高频谱利用率方面优于传统算法。

关键词: 软件定义多模态; 车联网; 无线接入网切片; 双时间尺度; 资源分配

中图分类号: TN92

文献标志码: A

DOI: 10.11959/j.issn.1000-436x.2022067

Dual time scale resource allocation for RAN slicing in software-defined oriented polymorphic IoV

QI Weijing, SONG Qingyang, GUO Lei

Institute of Intelligent Communication and Network Security, School of Communication and Information Engineering,
Chongqing University of Posts and Telecommunications, Chongqing 400065, China

Abstract: To effectively meet the differentiated quality of service (QoS) requirements of various vehicular applications, a dual time scale resource allocation algorithm for radio access network (RAN) slicing in software-defined polymorphic Internet of vehicles (IoV) was proposed. Considering the constraints of the minimum rate requirement of enhanced mobile broadband (eMBB) slice users, vehicle-to-vehicle (V2V) link reliability, the maximum power of nodes, the maximum number of RBs, a joint optimization problem of caching, spectrum, power allocation was formulated, with the aim of minimizing the average delay of ultra-reliable and low-latency communication (URLLC) slice users. By using the Hungarian algorithm, linear integer programming method and the double deep Q-Learning network (DDQN) algorithm, the original NP-hard problem was solved in dual time scales. The simulation results show that the proposed algorithm is superior to the traditional algorithm in ensuring the QoS requirements of different slice users and improving the spectrum utilization.

Keywords: software-defined polymorphic, IoV, RAN slicing, dual time scale, resource allocation

0 引言

5G 低时延特点为车联网发展提供了先决条件, 车联网从车载信息服务阶段逐渐迈向基于智能网联的驾驶辅助阶段和自动驾驶阶段。近年来, 具有不同的用户体验质量 (QoE, quality of experience)、

服务质量 (QoS, quality of service) 等级需求的新型车载应用不断涌现, 对车联网功能、系统性能、安全性等也提出了不同的要求^[1]。多媒体、在线会议和增强现实/虚拟现实等信息娱乐服务通常占用大网络带宽, 以保证较高的网络吞吐量。相反, 支撑智能驾驶的安全信息服务通常需要通过协作感知

收稿日期: 2021-12-29; 修回日期: 2022-02-21

通信作者: 宋清洋, songqy@cqupt.edu.cn

基金项目: 国家杰出青年科学基金资助项目 (No.62025105); 重庆市自然科学基金资助项目 (No.cstc2020jcyj-msxmX0918)

Foundation Items: The National Science Fund for Distinguished Young Scholars (No.62025105), The Chongqing Natural Science Foundation (No.cstc2020jcyj-msxmX0918)

消息 (CAM, cooperative awareness message)、分散环境通知消息 (DENM, decentralized environment notification message) 等承载驾驶环境状态, 由于环境状态信息的高动态性, 在这些情况下应保证低时延且高可靠性的网络连接。为每项业务提供专用网络可以满足其相应的需求, 但绝大多数服务提供商无法承担专用网络建设和维护成本。软件定义网络 (SDN, software defined network) 技术将网络设备的控制面与数据面分离, 从而摆脱硬件对网络架构的限制, 对网络流量进行灵活控制。SDN 是构建全维可定义开放网络架构、实现多模态网络的基础^[2]。文献[3]明确提出城市交通是全维可定义多模态智慧网络的一个典型垂直应用, 近年来, 针对软件定义多模态车联网的研究也在不断开展^[4-5]。网络切片可以通过网络功能虚拟化 (NFV, network function virtualization) 将网络资源虚拟化并聚合为资源池, 并由支持 SDN 的切片管理控制器集中管理, 实现更细粒度的资源编排, 在通用物理基础设施上按需定制虚拟网络, 实现软件定义的多模态网络, 为不同类型的车联网业务提供差异化 QoS 保障。例如, 增强型移动宽带 (eMBB, enhanced mobile broadband) 切片可以承载信息娱乐等大带宽业务, 超可靠低时延通信 (URLLC, ultra-reliable and low-latency communication) 切片可以承载实时路况监测、实时路况更新、导航准确度提升、安全自动驾驶等低时延、高可靠业务^[6]。在车联网这样的高动态网络中, 网络切片在无线接入网 (RAN, radio access network) 侧的功能实现简称为 RAN 切片, 其可以显著提高网络的灵活性和资源的利用效率, 从而提高网络在连接性、端到端时延、数据传输速率等方面的性能。

在实际的 RAN 切片实现和部署中, 其资源分配根据对资源使用的动态性和弹性程度, 可划分为以下三大类: 静态预留、半静态预留、动态共享^[7]。其中, 动态共享方式基于用户 QoS 在每个时隙灵活为切片分配资源, 相应资源就会通过网络下层信令的方式进行动态调整, 实现资源快速回收或增配。RAN 切片资源动态共享方式具有较高的资源利用率, 因此被广泛采用。然而, 车联网拓扑和数据流量的高动态性对 RAN 切片资源分配提出了巨大挑战。如何有效利用网络的动态异构资源以满足不同服务的多维 QoS 需求成为发挥 RAN 切片潜在优势的关键。因此, 从用户 QoS 和网络资源利用的角度来看, 开发高效的 RAN

切片资源分配方案势在必行。

近年来, 针对车联网环境中的 RAN 切片资源分配已有很多成果, 主要解决车联网中用户的 QoS 需求保证问题。文献[8]中较早提出了支持各种车载服务的 RAN 切片概念。文献[9]针对车联网场景提出了一种动态 RAN 切片框架, 通过均衡网络负载和分配网络资源, 实现在任务卸载最大时延和排队稳定性约束下的系统通信、计算成本最小化。文献[10]描述了一个针对 RAN 切片的资源分配和计算卸载联合优化问题, 以实现通信、计算资源利用率最大化为目标。考虑到 2 个优化问题之间的耦合作用, 文献[10]提出分层优化框架, 基于协作多智能体 DDQN (double deep Q-learning network) 框架来学习卸载策略, 基于凸优化实现 RAN 切片资源分配。文献[11]基于深度强化学习提出了适用于智能车联网和智慧城市系统的切片方案, 智能体可以通过与环境的密切交互来自适应地学习最佳网络切片策略。针对车联网中的关键任务和非关键任务需求, 文献[12]通过端到端切片对整体带宽资源进行隔离, 研究表明, 基于人工智能 (AI, artificial intelligence) 的切片管理系统可以智能调配 RAN 切片资源, 解决业务需求高动态对服务质量带来的影响。文献[13]提出了基于交叉熵的蒙特卡罗树搜索-快速动作价值估计算法来设计智能切片资源分配方案, 此方案不需要任何动态数据流相关的先验知识。为权衡车联网中视频流传输质量与资源消耗代价, 文献[14]提出了一种新颖的 RAN 切片资源分配和视频质量选择联合优化算法。文献[15]设计了一种基于深度确定性策略梯度的动态 RAN 切片方案, 其奖励由车到车 (V2V, vehicle-to-vehicle) 用户的效用总和与 QoS 度量组成。综上所述, 现有工作大多侧重于 RAN 切片分配通信和计算资源, 很少考虑将缓存策略视为切片资源分配的一个因素, 由于无线资源分配和缓存放置之间的密切关系, 将缓存策略和资源分配联合考虑至关重要。但是由于缓存内容更新产生的高传输代价导致缓存决策不可能频繁执行, 这与无线资源分配需要在每个时隙内快速决策的特点不同, 因此需要考虑两类决策时间尺度的差异。此外, 车联网运行在高动态环境中, 车载服务请求在时空域随机到达, 未来网络状态难以预测, 这使长期稳定的系统性能尤为重要。本文工作旨在对现有研究的上述缺陷进行一定程度的弥补。

本文考虑软件定义车联网中同时存在 eMBB 和

URLLC 两类 RAN 切片, 提出一种双时间尺度的 RAN 切片资源分配算法, 本文主要贡献如下。

1) 建立了软件定义车联网中 URLLC 和 eMBB 的 RAN 切片缓存、频谱、功率资源分配优化问题。最大化长期累积时间下的 URLLC 切片用户的平均时延, 并满足 eMBB 切片用户最小速率约束、V2V 链路可靠性约束、节点最大功率约束、资源块 (RB, resource block) 约束等。该问题是一个非凸、非线性、多变量耦合的 NP-hard 问题, 很难直接获得解析解。

2) 提出了一种双时间尺度求解算法。将原 NP-hard 问题转换为 2 个子问题: 大时间尺度内用户关联和缓存放置子问题、小时间尺度内 RB 分配和复用子问题。针对第一个子问题, 基于拉格朗日对偶原理将其分解, 并基于匈牙利算法、线性整数规划方法获得最优解; 针对第二个子问题, 基于 DDQN 算法求解。

3) 开展了广泛的仿真验证。仿真结果表明, 所提资源分配算法在保证不同切片用户 QoS 需求和提高频谱利用率方面优于传统算法, 验证了本文算法的有效性。

1 系统模型

1.1 场景描述

本文考虑一个基站 (BS, base station) 覆盖的道路区域, 其中部署了若干个路边单元 (RSU, road side unit), RSU 功率较低, 覆盖范围有限。在此区域内的车辆用户根据业务需求连接到 BS 或 RSU, 组成如图 1 所示的基于网络切片的车联网。其包含三类链路: BS 到车辆 (B2V, BS-to-vehicle) 下行链

路、RSU 到车辆 (R2V, RSU-to-vehicle) 下行链路以及 V2V 链路。

设该车联网架构中具有 N 个 RSU, 其集合表示为 $\mathcal{N} = \{1, 2, \dots, N\}$, K 个具有 eMBB 切片需求的车辆用户 B2V-eUE 通过高容量的 B2V 链路传输数据, U 个具有 URLLC 切片需求的车辆用户 R2V-uUE 通过低时延的 R2V 链路传输数据, M 对具有 URLLC 切片需求的车辆用户 V2V-uUE 通过 V2V 链路交换数据。 $\mathcal{K} = \{1, 2, \dots, K\}$ 、 $\mathcal{U} = \{K + 1, K + 2, \dots, K + U\}$ 、 $\mathcal{M} = \{1, 2, \dots, M\}$ 分别表示 B2V-eUE、R2V-uUE 和 V2V-uUE 三类用户的集合。需要注意的是, 对于 V2V-uUE 成对计入, 即集合 \mathcal{M} 中的第 m 个元素表示第 m 个 V2V-uUE 用户对。B2V-eUE 和 R2V-uUE 下行用户集合表示为 $\mathcal{Q} = \mathcal{K} \cup \mathcal{U} = \{1, 2, \dots, Q\}$, $Q = K + U$ 。假设内容服务器中共有 F 个用户感兴趣的内容文件, 其集合表示为 $\mathcal{F} = \{1, 2, \dots, F\}$, 第 f 个文件的大小为 C_f 。如果某个 R2V-uUE 用户请求的文件缓存在某个 RSU 中, 则直接从该 RSU 获取其请求的文件, 否则需要向 BS 请求该文件。在时分双工 (TDD, time division duplexing) - 正交频分复用 (OFDM, orthogonal frequency-division multiplexing) 技术支持下的 5G 网络通信系统中, 在频域中以 12 个子载波为一组进行调度, 子载波组称为新空口 (NR, new radio) RB。RB 带宽取决于子载波间隔。假设系统只能将一个 RB 分配给集合 \mathcal{Q} 中的一个下行用户 B2V-eUE 或者 R2V-uUE, $\mathcal{S} = \{1, 2, \dots, S\}$ 表示系统中的 RB 集合。为了提高频谱利用效率, V2V-uUE 用户对复用了正交分配给 B2V-eUE 或者 R2V-uUE 的下行频谱。

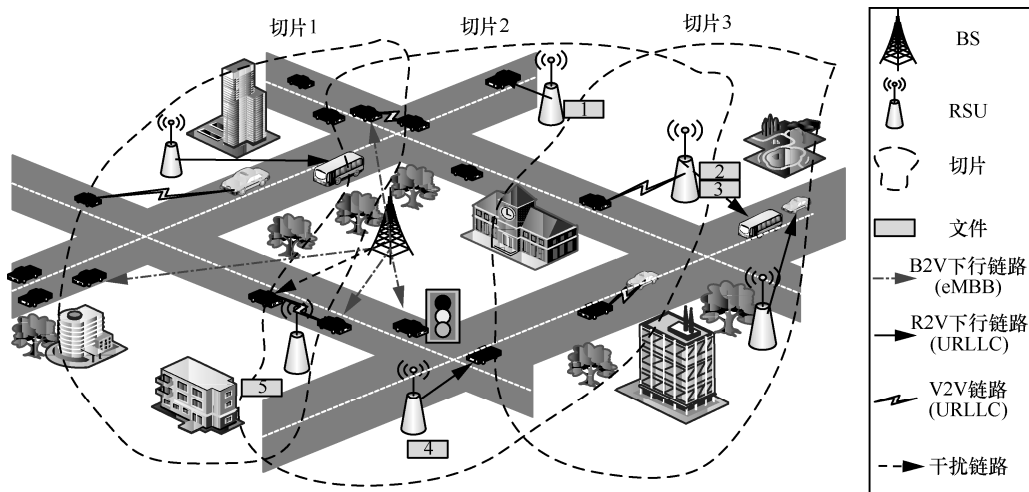


图 1 基于网络切片的车联网架构

1.2 系统模型

1.2.1 通信模型

考虑信道衰落，当占用第 s 个 RB 时，BS 到第 k 个 B2V-eUE 的信道增益为

$$g_{k,s} = |h_{k,s}|^2 \alpha_{k,s} \quad (1)$$

其中， $h_{k,s}$ 是快速衰落分量， $\alpha_{k,s}$ 是路径损耗和阴影衰落分量。

类似地，占用第 s 个 RB 时，第 n 个 RSU 到第 u 个 R2V-uUE 的信道增益为 $g_{n,u,s}$ 。对于第 m 个 V2V-uUE 用户对，当其复用第 q 个下行用户 (B2V-eUE 或者 R2V-uUE) 占用的 RB 时，其信道增益为 $g_{m,q}$ ，且其对第 q 个用户带来的干扰为 $\tilde{g}_{m,q}$ ，第 q 个 B2V-eUE 对第 m 个 V2V-uUE 带来的干扰为 $\tilde{g}_{q,m}$ 。假设基站作为该系统的决策控制器可以实时获得所有链路的信道状态信息。

定义 $\rho_{m,q} \in \{0,1\}$ 为一个二进制变量，表示第 m 个 V2V-uUE 对是 ($\rho_{m,q}=1$) 否 ($\rho_{m,q}=0$) 复用第 q 个用户的频谱。因此频谱复用配对策略矩阵可以表示为

$$\rho = \{\rho_{m,q} : m \in \mathcal{M}, q \in \mathcal{Q}\} \in \mathbb{C}^{\mathcal{M} \times \mathcal{Q}} \quad (2)$$

假设无复用频谱的用户之间不产生干扰，即当 $\rho_{m,q}=0$ 时， $\tilde{g}_{m,q}=\tilde{g}_{q,m}=0$ 。定义 BS 和 RSU 以固定的发射功率 p_n^1 (其中 $n \in \{0\} \cup \mathcal{N}$) 传输数据，第 m 个 V2V-uUE 发射端以发射功率 p_m 传输数据，V2V-uUE 发射功率控制策略矩阵可以表示为

$$p = \{p_m : m \in \mathcal{M}\} \in \mathbb{C}^{\mathcal{M}} \quad (3)$$

第 k 个 B2V-eUE 占用第 s 个 RB 时接收的瞬时信噪比 (SINR, signal noise ratio) 为

$$\gamma_{k,s} = \frac{p_0^1 g_{k,s}}{\sum_{m=1}^M \rho_{m,k} p_m \tilde{g}_{m,k} + N_0 B} \quad (4)$$

其中， p_0^1 表示基站功率， N_0 表示具有零均值和 σ^2 方差的加性白高斯噪声的功率谱密度。每个 RB 的带宽为 B 。

第 k 个 B2V-eUE 占用第 s 个 RB 时可达到的传输数据速率由香农方程计算，即

$$R_{k,s} = B \log(1 + \gamma_{k,s}) \quad (5)$$

定义 $\delta_{q,s} \in \{0,1\}$ 为二进制变量，表示是 ($\delta_{q,s}=1$) 否 ($\delta_{q,s}=0$) 将第 s 个 RB 分配给第 q 个用户。因此，频谱分配策略集合可表示为

$$\delta = \{\delta_{q,s} : q \in \mathcal{Q}, s \in \mathcal{S}\} \in \mathbb{C}^{\mathcal{Q} \times \mathcal{S}} \quad (6)$$

第 k 个 B2V-eUE 可达到的传输数据速率为

$$R_k = \sum_{s=1}^S \delta_{k,s} R_{k,s} \quad (7)$$

第 u 个 R2V-uUE 与第 n 个 RSU 连接所接收到的瞬时下行 SINR 为

$$\gamma_{n,u} = \frac{\sum_{s=1}^S \delta_{K+u,s} p_n^1 g_{n,u,s}}{\sum_{m=1}^M \rho_{m,K+u} p_m \tilde{g}_{m,K+u} + N_0 B} \quad (8)$$

第 u 个 R2V-uUE 与第 n 个 RSU 连接可达到的传输数据速率为

$$R_{n,u} = B \log(1 + \gamma_{n,u}) \quad (9)$$

定义 $\alpha_{n,u} \in \{0,1\}$ 为一个二进制变量，表示第 u 个 R2V-uUE 是 ($\alpha_{n,u}=1$) 否 ($\alpha_{n,u}=0$) 与第 n 个 RSU 建立连接。因此，R2V-uUE 与 RSU 的关联策略矩阵为

$$\alpha = \{\alpha_{n,u} : n \in \mathcal{N}, u \in \mathcal{U}\} \in \mathbb{C}^{\mathcal{N} \times \mathcal{U}} \quad (10)$$

第 u 个 R2V-uUE 可达到的传输数据速率为

$$R_u = \sum_{n=1}^N \alpha_{n,u} R_{n,u} \quad (11)$$

当第 m 个 V2V-uUE 对共享第 q 个下行用户的 RB 时，第 m 个 V2V-uUE 的 SINR 为

$$\gamma_{m,q} = \frac{p_m g_{m,q}}{\sum_{s=1}^S \delta_{k,s} p_q \tilde{g}_{q,m} + N_0 B} \quad (12)$$

第 m 个 V2V-uUE 对共享第 q 个下行用户的 RB 可达到的传输数据速率为

$$R_{m,q} = B \log(1 + \gamma_{m,q}) \quad (13)$$

第 m 个 V2V-uUE 的传输数据速率为

$$R_m = \sum_{q=1}^Q \rho_{m,q} R_{m,q} \quad (14)$$

1.2.2 缓存模型

定义 $\beta_{f,n} \in \{0,1\}$ 为一个二进制变量，表示第 f 个文件是 ($\beta_{f,n}=1$) 否 ($\beta_{f,n}=0$) 缓存在第 n 个 RSU 中。因此，缓存放置策略矩阵为

$$\beta = \{\beta_{f,n} : f \in \mathcal{F}, n \in \mathcal{N}\} \in \mathbb{C}^{\mathcal{F} \times \mathcal{N}} \quad (15)$$

同时，第 u 个 R2V-uUE 用户的文件请求偏好用请求概率 $P_{u,f}$ 来表示，且满足 $\sum_f P_{u,f} = 1$ 。如果关联第 n 个 RSU 的第 u 个 R2V-uUE 请求的第 f 个文件

缓存在此 RSU 中, 则第 u 个 R2V-uUE 直接从该 RSU 获取其请求的文件, 其无线传输时延部分为

$$L_{n,u,f}^W = \frac{C_f}{R_{n,u}} \quad (16)$$

其中, C_f 是第 f 个文件的大小。

如果文件未缓存在用户关联的 RSU 中, 则通过光纤链路从云服务器中获取文件。除了无线传输时延 $L_{n,u,f}^W$, 还需要考虑增加的光纤传输时延。为简化起见, 假设光纤传输时延为固定值 L^F , 那么总时延为 $\frac{C_f}{R_{n,u}} + L^F$ 。

因此, 关联第 n 个 RSU 的第 u 个 R2V-uUE 请求的第 f 个文件的时延为

$$L_{n,u,f} = \beta_{f,n} \frac{C_f}{R_{n,u}} + (1 - \beta_{f,n}) \left(\frac{C_f}{R_{n,u}} + L^F \right) = \frac{C_f}{R_{n,u}} + (1 - \beta_{f,n}) L^F \quad (17)$$

2 问题描述

2.1 切片 QoS 需求

利用 eMBB 切片承载的车载应用需要高数据传输速率, 因此 B2V 链路的数据传输速率需要满足阈值, BS 到第 k 个 B2V-eUE 的数据传输速率满足

$$R_k \geq R_e^{\text{Thr}} \quad (18)$$

对于 R2V-uUE 来说, 其向 RSU 或者云服务器请求的文件利用 URLLC 切片承载, 从系统最优的角度来考虑, 需要保证所有 R2V-uUE 的平均时延最小化, R2V-uUE 平均时延为

$$L_u^{\text{Ave}} = \frac{1}{U} \sum_{u=1}^U \sum_{f=1}^F \sum_{n=1}^N \alpha_{n,u} P_{u,f} L_{n,u,f} = \frac{1}{U} \sum_{u=1}^U \sum_{f=1}^F \sum_{n=1}^N \alpha_{n,u} P_{u,f} \left[\frac{C_f}{R_{n,u}} + (1 - \beta_{f,n}) L^F \right] \quad (19)$$

对于 V2V-uUE 来说, 假设车辆之间交换短消息, 一旦建立可靠链路, 其传输时延可以保证。但是在车辆高速运动的过程中, 需要保证 V2V 链路的可靠性, 即 V2V 链路中断概率小于阈值, 第 m 个 V2V-uUE 的中断概率满足

$$\Pr\{\gamma_m \geq \gamma_0\} \leq \Pr_0 \quad (20)$$

2.2 联合优化问题描述

为了优化两类切片中用户不同的性能指标, 一种

常见的方法是将多个指标组合成一个统一的优化目标, 例如定义系统数据传输速率与能耗比率为能量效率^[6], 定义系统数据传输速率与通信信道带宽比率为频谱效率^[17]。但是, 目前速率与时延的比率尚未定义, 没有实际意义。因此, 本文优化 R2V-uUE 的 URLLC 切片的时延性能, 同时保证 B2V-mUE 的 eMBB 切片传输速率需求和 V2V-uUE 的 URLLC 切片链路可靠性需求。本文提出了一个联合频谱资源分配及复用、缓存内容放置及 R2V-uUE 用户关联的优化问题, 以最小化在 URLLC 切片中 R2V-uUE 的长期累积平均时延, 同时 OFDMA 载波正交性、载波允许复用数量、用户接入容量、用户最大发射功率、缓存容量以及不同用户 QoS 需求 (即 B2V-mUE 的数据传输速率和 V2V-uUE 的链路可靠性) 被视为约束。令 $\rho = \{\rho_{m,q} : m \in \mathcal{M}, q \in \mathcal{Q}\} \in \mathbb{C}^{\mathcal{M} \times \mathcal{Q}}$ 、 $\delta = \{\delta_{q,s} : q \in \mathcal{Q}, s \in \mathcal{S}\} \in \mathbb{C}^{\mathcal{Q} \times \mathcal{S}}$ 、 $\alpha = \{\alpha_{n,u} : n \in \mathcal{N}, u \in \mathcal{U}\} \in \mathbb{C}^{\mathcal{N} \times \mathcal{U}}$ 、 $\beta = \{\beta_{f,n} : f \in \mathcal{F}, n \in \mathcal{N}\} \in \mathbb{C}^{\mathcal{F} \times \mathcal{N}}$ 、 $p = \{p_m : m \in \mathcal{M}\} \in \mathbb{C}^{\mathcal{M}}$ 为频谱复用关联矩阵、RB 分配矩阵、R2V-uUE 与 RSU 关联矩阵、RSU 中文件缓存状态矩阵和 V2V-uUE 发射功率矩阵。该问题可以表示为

$$\text{P1: } \min_{\{\rho, \delta, \alpha, \beta, p\}} \frac{1}{T} \sum_{t=0}^{T-1} L_u^{\text{Ave}}(t) \quad (21)$$

$$\text{s.t. } R_k(t) \geq R_e^{\text{Thr}}, \forall k \in \mathcal{K}, \forall t \in \mathcal{T} \quad (21a)$$

$$\Pr\{\gamma_m(t) \geq \gamma_0\} \leq \Pr_0, \forall m \in \mathcal{M}, \forall t \in \mathcal{T} \quad (21b)$$

$$\sum_{f=1}^F \beta_{f,n} C_f \leq C_n, \forall n \in \mathcal{N} \quad (21c)$$

$$\sum_{q=1}^Q \rho_{m,q}(t) = 1, \forall m \in \mathcal{M}, \forall t \in \mathcal{T} \quad (21d)$$

$$\sum_{m=1}^M \rho_{m,q}(t) \leq 1, \forall q \in \mathcal{Q}, \forall t \in \mathcal{T} \quad (21e)$$

$$\sum_{s=1}^S \delta_{q,s}(t) = 1, \forall q \in \mathcal{Q}, \forall t \in \mathcal{T} \quad (21f)$$

$$\sum_{q=1}^Q \delta_{q,s}(t) \leq 1, \forall s \in \mathcal{S}, \forall t \in \mathcal{T} \quad (21g)$$

$$\sum_{n=1}^N \alpha_{n,u} = 1, \forall u \in \mathcal{U} \quad (21h)$$

$$\sum_{u=1}^U \alpha_{n,u} \leq A_n, \forall n \in \mathcal{N} \quad (21i)$$

$$p_m \leq P^V, \forall m \in \mathcal{M} \quad (21j)$$

$$\rho_{m,q}(t) \in \{0, 1\}, \forall m \in \mathcal{M}, \forall q \in \mathcal{Q}, \forall t \in \mathcal{T} \quad (21k)$$

$$\delta_{q,s}(t) \in \{0,1\}, \forall q \in \mathcal{Q}, \forall s \in \mathcal{S}, \forall t \in \mathcal{T} \quad (21l)$$

$$\alpha_{n,u} \in \{0,1\}, \forall n \in \mathcal{N}, \forall u \in \mathcal{U} \quad (21m)$$

$$\beta_{f,n} \in \{0,1\}, \forall f \in \mathcal{F}, \forall n \in \mathcal{N} \quad (21n)$$

其中, 优化目标是 minimized URLLC 切片中 R2V-uUE 的平均时延。约束式(21a)限制 eMBB 切片中 B2V-eUE 的数据传输速率不低于阈值; 约束式(21b)限制 URLLC 切片中 V2V-uUE 的链路中断概率不大于阈值; 约束式(21c)限制 RSU 中缓存的所有文件大小不超过其缓存空间; 约束式(21d)限制每个 V2V-uUE 必须且只能复用一个 B2V-eUE 或者 R2V-uUE 的 RB; 约束式(21e)限制一个 B2V-eUE 或者 R2V-uUE 的 RB 最多提供给一个 V2V-uUE 复用; 约束式(21f)限制必须且只能给每个 B2V-eUE 和 R2V-uUE 分配一个 RB; 约束式(21g)限制每个 RB 最多分配给一个 B2V-eUE 或者 R2V-uUE; 约束式(21h)限制每个 R2V-uUE 必须且只能关联一个 RSU; 约束式(21i)限制每个 RSU 最多接入的 R2V-uUE 数量; 约束式(21j)限制 V2V-uUE 的最大功率不超过阈值 P^V ; 约束式(21k)~式(21n)为二进制变量约束。

优化问题 P1 是一个混合整数非线性组合优化问题, 是典型的 NP-hard 问题。由于该网络中有大量的内容文件、车辆和 RB, 因此 P1 无法在多项式时间内解决。获得最优解的直接方法是将问题分解为多个子问题并进行穷举搜索。然而, 在这样一个高度动态的车载网络中, 应该实时做出优化决策。

3 双时间尺度资源分配算法

为了解决 P1 的计算复杂性, 本节提出了一种有效的双时间尺度资源分配算法来优化网络切片的子载波分配、用户关联和缓存放置。假设网络系统在一个时间窗口上工作, 该时间窗口被划分为由 $t \in \mathcal{T} = \{1, 2, \dots, T\}$ 表示的离散时隙。假设基站作为该系统的决策控制器, 其在每个时间窗开始进行用户关联和缓存放置决策, 在每个时隙开始时为发送数据传输请求的车辆用户分配 (包括复用匹配) RB 和功率。

3.1 大时间尺度内用户关联和缓存放置决策

基于给定的 RB 分配和复用策略, P1 目标函数中的传输速率 $R_{n,u}$ 变为已知, 记作 $R_{n,u}^*$, P1 简化为只包含用户关联和缓存放置策略的优化问题 P2, 即

$$P2: \min_{\{\alpha, \beta\}} \frac{1}{U} \sum_{u=1}^U \sum_{f=1}^F \sum_{n=1}^N \alpha_{n,u} P_{u,f} \left[\frac{C_f}{R_{n,u}^*} + (1 - \beta_{f,n}) \right] L^F$$

$$\text{s.t. 式(21c), 式(21h), 式(21i), 式(21l), 式(21m) (22)}$$

由于存在 $\alpha_{n,u}$ 与 $\beta_{f,n}$ 这 2 个变量相乘项, P2 为整数非线性规划问题, 利用 McCormick 包络将该问题松弛。定义 $\chi_{f,n,u} = \alpha_{n,u} \beta_{f,n}$ 并引入上述目标函数, 可将 P2 转化为 P3。

$$P3: \min_{\{\alpha, \beta, \chi\}} \frac{1}{U} \sum_{u=1}^U \sum_{f=1}^F \sum_{n=1}^N \left[\alpha_{n,u} P_{u,f} \left(\frac{C_f}{R_{n,u}^*} + L^F \right) - \chi_{f,n,u} P_{u,f} L^F \right]$$

$$\text{s.t. 式(21c), 式(21h), 式(21i) (23)}$$

$$\chi_{f,n,u} \geq \alpha_{n,u} + \beta_{f,n} - 1, \forall f \in \mathcal{F}, \forall n \in \mathcal{N}, \forall u \in \mathcal{U} \quad (23a)$$

$$\chi_{f,n,u} \leq \alpha_{n,u}, \forall f \in \mathcal{F}, \forall n \in \mathcal{N}, \forall u \in \mathcal{U} \quad (23b)$$

$$\chi_{f,n,u} \leq \beta_{f,n}, \forall f \in \mathcal{F}, \forall n \in \mathcal{N}, \forall u \in \mathcal{U} \quad (23c)$$

$$0 \leq \alpha_{n,u}, \beta_{f,n}, \chi_{f,n,u} \leq 1, \forall f \in \mathcal{F}, \forall n \in \mathcal{N}, \forall u \in \mathcal{U} \quad (23d)$$

为了简化 P3 的约束, 本文利用拉格朗日松弛乘子法转换该问题。定义拉格朗日乘子 $\varphi_{f,n,u}, \gamma_{f,n,u}, \eta_{f,n,u} \geq 0$, 拉格朗日函数表示为

$$\begin{aligned} L(\alpha, \beta, \chi, \varphi, \gamma, \eta) = & \frac{1}{U} \sum_{u=1}^U \sum_{f=1}^F \sum_{n=1}^N \left[\alpha_{n,u} P_{u,f} \left(\frac{C_f}{R_{n,u}^*} + L^F \right) - \right. \\ & \chi_{f,n,u} P_{u,f} L^F + \varphi_{f,n,u} (\alpha_{n,u} + \beta_{f,n} - \chi_{f,n,u} - 1) + \\ & \left. \gamma_{f,n,u} (\chi_{f,n,u} - \alpha_{n,u}) + \eta_{f,n,u} (\chi_{f,n,u} - \beta_{f,n}) \right] = \\ & \frac{1}{U} \sum_{u=1}^U \sum_{f=1}^F \sum_{n=1}^N \left[\alpha_{n,u} \left(P_{u,f} \frac{C_f}{R_{n,u}^*} + P_{u,f} L^F + \varphi_{f,n,u} - \gamma_{f,n,u} \right) + \right. \\ & \left. \beta_{f,n} (\varphi_{f,n,u} - \eta_{f,n,u}) + \right. \\ & \left. \chi_{f,n,u} (-P_{u,f} L^F - \varphi_{f,n,u} + \gamma_{f,n,u} + \eta_{f,n,u}) - \varphi_{f,n,u} \right] \quad (24) \end{aligned}$$

因此, P3 可以转化为 P4。

$$P4: \max_{\{\varphi, \gamma, \eta\}} \min_{\{\alpha, \beta, \chi\}} L(\alpha, \beta, \chi, \varphi, \gamma, \eta)$$

$$\text{s.t. 式(21c), 式(21h), 式(21i), 式(23d) (25)}$$

P4 可以转化为如下 3 个子问题。

$$P4_1: \min_{\{\alpha\}} \frac{1}{U} \sum_{u=1}^U \sum_{f=1}^F \sum_{n=1}^N \cdot$$

$$\alpha_{n,u} \left(P_{u,f} \frac{C_f}{R_{n,u}^*} + P_{u,f} L^F + \varphi_{f,n,u} - \gamma_{f,n,u} \right)$$

$$\text{s.t. 式(21h), 式(21i) (26)}$$

$$P4_2: \min_{\{\beta\}} \frac{1}{U} \sum_{u=1}^U \sum_{f=1}^F \sum_{n=1}^N \beta_{f,n} (\varphi_{f,n,u} - \eta_{f,n,u}) - \varphi_{f,n,u}$$

s.t. 式(21c) (27)

$$\begin{aligned}
 \text{P4_3: } \min_{\{z\}} & \frac{1}{U} \sum_{u=1}^U \sum_{f=1}^F \sum_{n=1}^N \chi_{f,n,u} \cdot \\
 & \left(-P_{u,f} L^F - \varphi_{f,n,u} + \gamma_{f,n,u} + \eta_{f,n,u} \right) \\
 \text{s.t. } & \text{式(23d)} \quad (28)
 \end{aligned}$$

分解后, 联合优化问题变成了单独的优化问题。子问题 P4_1 是一个典型的赋值问题, 可以用匈牙利算法解决。子问题 P4_2 和 P4_3 都是线性整数优化问题, 可以用线性整数规划方法求解。

3.2 小时间尺度内 RB 分配和功率控制决策

在大时间尺度内进行用户关联和缓存放置决策后, 优化问题 P1 可以简化为 RB 分配和功率控制问题, 在每个小时间尺度-时隙内求解。优化问题为

$$\begin{aligned}
 \text{P5: } \min_{\{\rho, \delta, p\}} & \frac{1}{T} \frac{1}{U} \sum_{t=0}^{T-1} \sum_{u=1}^U \sum_{f=1}^F \sum_{n=1}^N \alpha_{n,u}^* \cdot \\
 & P_{u,f} \left[\frac{C_f}{R_u} + (1 - \beta_{f,n}^*) L^F \right]
 \end{aligned}$$

s.t. 式 (21a), 式 (21b), 式 (21d) ~ 式 (21g), 式(21j), 式(21k) (29)

不考虑上述优化问题目标函数中的固定值, P5 等价于

$$\text{P6: } \max_{\{\rho, \delta, p\}} \frac{1}{T} \frac{1}{U} \sum_{t=0}^{T-1} \sum_{u=1}^U \sum_{f=1}^F \sum_{n=1}^N R_u$$

s.t. 式 (21a), 式 (21b), 式 (21d) ~ 式 (21g), 式(21j), 式(21k) (30)

本文提出了一种基于多智能体 DDQN 的 RB 分配和功率控制算法, 并对算法在训练阶段和推理阶段的执行流程和工作方式分别进行了介绍。该算法能够学习用户所处的状态, 做出最佳的决策, 使一个时间窗内所有 R2V-uUE 的累积传输速率和最高, 同时保证 B2V-eUE 和 V2V-uUE 的 QoS 需求。由于时间相关特性, 决策被建模为马尔可夫决策过程。

3.2.1 马尔可夫决策过程

一个马尔可夫决策过程由一个三元组 $(\hat{\mathcal{S}}, \hat{\mathcal{A}}, \hat{\mathcal{R}})$ 构成, 其中 $\hat{\mathcal{S}}$ 是智能体所有状态组成的环境状态空间, $\hat{\mathcal{A}}$ 是智能体所有可能选择的动作集合, $\hat{\mathcal{R}}$ 是奖励函数。

在马尔可夫决策过程中, 在每个时隙 t , 智能体通过识别当前状态 $\hat{s}_t \in \hat{\mathcal{S}}$ 来感知环境, 然后选择一个动作 $a_t \in \hat{\mathcal{A}}$ 并在环境中执行。随后环境回应智能体的动作 a_t , 反馈回奖励 $r_t = r(\hat{s}_t, a_t)$, 同时以概

率 $P(\hat{s}_t, a_t, \hat{s}_{t+1})$ 过渡到下一个状态 $\hat{s}_{t+1} = \pi(\hat{s}_t, a_t)$ 。

1) 状态空间

定义第 k 个 B2V-eUE、第 u 个 R2V-uUE 和第 m 个 V2V-uUE 在第 t 个时隙的信道状态分别为 $\hat{s}_k(t) = \{G_k(t), I_k(t)\}$ 、 $\hat{s}_u(t) = \{G_u(t), I_u(t)\}$ 和 $\hat{s}_m(t) = \{G_m(t), I_m(t)\}$, 其中 G 和 I 分别表示信道功率增益和干扰增益。

因此, 第 t 个时隙网络状态集合可表示为 $\hat{s}(t) = \{\hat{s}_k(t)\} \cup \{\hat{s}_u(t)\} \cup \{\hat{s}_m(t)\}, \forall k \in \mathcal{K}, \forall u \in \mathcal{U}, \forall m \in \mathcal{M}$ (31)

因此, 网络状态集合为 $\hat{\mathcal{S}} = \{\hat{s}(t)\}, \forall t \in \mathcal{T}$ 。

2) 动作空间

车联网切片资源调度归结为频谱 RB 选择和传输功率控制。系统中频谱被分为 S 个不相交的 RB, 每个 RB 都由一个 B2V 或者 R2V 链路占据, 同时每个 V2V 链路采用一定的发射功率复用 B2V 或者 R2V 链路的 RB。定义网络中每个用户为一个智能体, 每个 B2V-eUE 和 R2V-uUE 在每个时隙采取的动作作为 RB 选择, 其动作空间维度为 S 。

V2V-uUE 在每个时隙采取的动作作为 RB 复用配对及发射功率选择。为了简化动作空间, 本文将功率控制选项限制为 4 个级别, 即 [23, 10, 5, -100] dBm。需要注意的是, -100 dBm 意味着发射功率为 0。因此, 动作空间的维度为 $4 \times S$, 每个动作对应于 RB 分配选择和功率选择组合。

3) 奖励

智能体通过未来一段时间内奖励的期望值来表示对当前状态下执行该动作的满意程度。考虑到 P5 的优化目标为最大化 R2V-uUE 的平均传输速率, 定义奖励 $r_t = r(\hat{s}_t, a_t)$ 为用户在状态 \hat{s}_t 下采取行动 a_t 时所获得的 R2V-uUE 的平均传输速率, 这有利于实现优化目标。本文使那些导致更高能源效率的行动获得更高的相应奖励。此外, 还需要考虑约束条件式(21a)和式(21b)。为了保证用户的公平性, 对不能满足 B2V-eUE 最低通信速率和 B2V-uUE 最低链路可靠性要求的动作进行惩罚。因此, 设定奖励函数包含两部分, 一是对 R2V-uUE 平均传输速率的贡献, 二是当传输速率和链路可靠性不能满足用户需求时的惩罚。用户在第 t 个时隙获得的奖励为

$$\begin{aligned}
 r_t = & w_1 R_u^{\text{AVE}} - w_2 \sum_{k=1}^K \xi(R_k \leq R_e^{\text{Thr}}) - \\
 & w_3 \sum_{k=1}^K \xi(\Pr\{\gamma_m(t) \geq \gamma_0\} \geq \Pr_0) \quad (32)
 \end{aligned}$$

其中, w_1 为贡献对应的权重, w_2 和 w_3 为 2 个惩罚对应的权重; $\xi(\cdot)$ 为一个函数, 且当 \cdot 为真时, $\xi(\cdot)=1$ 。

3.2.2 基于 DDQN 的 RB 分配和功率控制

根据上述定义, 便可基于多智能体 DDQN 实现车辆用户分配 RB 和功率的决策。在多智能体 DDQN 算法中, 智能体将每一步的状态、功率分配决策、网络能量效率奖励和下一状态作为经验存储到经验重放器。在每次的迭代训练中, 神经网络从经验重放器中随机选择一部分样本来训练。多智能体 DDQN 使用损失函数评估其性能, 并采用反向传播算法实现目标 Q 网络 and 原 Q 网络权值的更新。

多智能体 DDQN 算法通过值函数来评价当前资源分配策略的好坏, 其中, 值函数表示智能体在某个状态下执行某个分配决策获得的长期回报。在策略 π 下, 智能体的动作值函数为

$$Q(\hat{s}, a; \theta) = E_{\pi}[R_t | \hat{s}(t) = \hat{s}, a(t) = a] \quad (33)$$

其中, θ 为 DDQN 网络参数, $E[\cdot]$ 为期望运算。

首先, 在当前 Q 网络中找到最大 Q 值对应的动作, 表示为 a^{\max} , 如式(34)所示。

$$a^{\max} = \arg \max_a Q(\hat{s}(t+1), a; \theta) \quad (34)$$

然后, 利用 a^{\max} 计算目标 Q 网络的 Q 值, 如式(35)所示。

$$y^t = r^t + \gamma Q'(\hat{s}(t+1), a^{\max}; \theta') \quad (35)$$

其中, y^t 是目标网络的 Q 值。

将式(34)代入式(35), 结果如式(36)所示。

$$y^t = r^t + \gamma Q'(\hat{s}(t+1), \arg \max_a Q(\hat{s}(t+1), a; \theta); \theta') \quad (36)$$

DDQN 的损失函数为

$$L(\theta) = E[(y^t - Q(\hat{s}(t), a(t); \theta))^2] \quad (37)$$

DDQN 采用随机梯度下降法训练 θ , 最终得到最优的 θ , 以逼近动作价值函数。其中, 参数 θ 的更新式为

$$\theta^{t+1} = \theta^t + \eta(y^t - Q(\hat{s}(t), a(t); \theta(t))) \nabla Q(\hat{s}(t), a(t); \theta(t)) \quad (38)$$

其中, η 是学习率。

综上所述, 本文所提的双时间尺度智能资源分配算法流程如算法 1 所示。

算法 1 双时间尺度智能资源分配算法

输入 $N, K, U, M, B, F, T, TW, \sigma^2, P_n^l,$

w_1, w_2

输出 R2V-uUE 与 RSU 关联决策、文件缓存

放置决策、用户 RB 分配决策、RB 复用决策和 V2V-uUE 功率分配决策

1) 全局初始化: 重放存储器 DE 容量 ND, 随机生成 $\theta, \theta' = \theta$

2) for 时间窗口 tw in TW

3) 本地初始化

4) 匈牙利算法找到子问题 P4_1 最优解 α

5) 线性整数规划方法找到子问题 P4_2 和 P4_3 最优解 β, χ

6) for episode in M

7) 初始化初始状态 s_1

8) for t in T

9) 使用 ϵ -贪婪策略生成功率分配动作 a_t

10) 执行动作 a_t , 得到奖励 r_t 及新的状态 s_{t+1}

11) 将样本 (s_t, a_t, r_t, s_{t+1}) 存入重放记忆库中

12) 随机抽取样本集 (s_j, a_j, r_j, s_{j+1})

13) 如果 $j+1$ 步未终止, 令 $y_j = r_j + \gamma Q'(\hat{s}_{j+1}, \arg \max_a Q(\hat{s}_{j+1}, a; \theta); \theta')$; 否则, 令 $y_j = r_j$

14) 根据目标函数 $(y_j - Q(s_j, a_j; \theta))^2$ 进行梯度下降法求解

15) 每隔 CQ 步更新 $\theta' = \theta$

16) end for

17) end for

18)end for

4 仿真与结果分析

4.1 仿真场景

本文设计了双时间尺度 RAN 切片资源智能分配算法, 该算法融合匈牙利算法、线性整数规划方法和 DDQN 算法, 在满足 eMBB 切片用户最小传输速率需求和 V2V 链路可靠性的前提下, 最小化 URLLC 切片用户的平均传输速率。本节使用 Python 语言基于开源深度学习平台 TensorFlow 对本文算法进行仿真和性能验证。

默认情况下, 本文考虑一个包含一个基站、5 个 B2V-eUE、5 个 RSU、12 个 R2V-uUE 和 2 个 V2V-uUE 的车联网系统, 系统中可分配的 RB 数量为 20, 每个 RB 的带宽为 15 kHz。为了验证算法性能, 本文调节网络规模、网络中各节点和 RB 数量。实验中共传输 10 个文件, 每个文件的大小为 1 kbit。每

个 RSU 可以缓存 3 个文件。前传时延为 0.5 s。智能体 DDQN 由 3 个完全连接的隐藏层组成, 分别包含 500、250、120 个神经元。采用 ReLU 为激活函数, RMSProp 优化器以 0.01 的学习率更新网络参数。训练探索率从 0.4 下降到 0.001, 然后保持不变。具体参数设置如表 1 所示。

变量	符号	默认设置
B2V-eUE 数量	N	5
RSU 数量	K	5
R2V-uUE 数量	U	12
V2V-uUE 数量	M	2
RB 数量	B	20
噪声功率/dBm	σ^2	-114
V2V 传输功率/dBm	P_m^V	[23, 10, 5, -100]
基站最大发射功率/dBm	P_n^1	23
文件数量	F	10
单个 RSU 缓存容量/个	C	3
贡献与惩罚对应的权重	w_1, w_2	0.8, 0.2
重放存储器容量	ND	100 000
初始探索率	ϵ_i	0.4
最终探索率	ϵ_f	0.001
学习率	α	0.01

为验证本文所提的双时间尺度资源分配算法的性能, 将其与以下 3 种算法进行对比。

- 1) 随机算法, 在满足约束的情况下随机进行缓存、频谱和功率资源分配。
- 2) 贪婪算法, 当前状态下最好或最优 (即最有利) 的选择。
- 3) 基于 Q-Learning 的双时间尺度算法, 即在大时间尺度内与本文所提算法相同, 采用基于匈牙利算法、线性整数规划方法求解; 在小时间尺度内则基于 Q-Learning 算法进行频谱和功率资源的分配。

4.2 仿真结果与分析

损失函数值随训练迭代次数的变化如图 2 所示, 展现了本文所提的小时间尺度下基于 DDQN 通信资源分配算法的收敛过程。从图 2 中可以看出, 随着训练迭代次数的增加, 损失函数值不断减小, 当训练迭代次数达到 400 时, 损失函数值已经收敛到 0.5 左右; 当训练迭代次数达到 2 000 时, 损失函数值已经达到 0.17。基于此, 在接下来评估算法性能时, 本文将 DDQN 模型训练了 2 000 次, 以保障其收敛性。




图 2 损失函数值随训练迭代次数的变化

图 3 为 4 种不同的切片资源分配算法下 R2V-uUE 平均时延随 R2V-uUE 数量的变化曲线。从图 3 可以看出, 4 种分配算法的 R2V-uUE 平均时延都随 R2V-uUE 数量的增加而增加。其中, 随机算法曲线具有更大的波动性, 网络性能不稳定。贪婪算法和基于 Q-Learning 的双时间尺度算法在网络规模较小 (即网络中 R2V-uUE 数量较少) 时与本文所提算法表现相当。但是, 随着网络中 R2V-uUE 数量的增加, 本文所提算法的平均时延低于其他 3 种算法。基于 DDQN 的算法解决了 Q-Learning 中的维数灾难问题并克服了 DQN 中 Q 值过估计的缺点, 可以通过学习得到适用于环境的资源分配策略, 实现最小化 R2V-uUE 平均时延的目标。




图 3 R2V-uUE 平均时延随 R2V-uUE 数量的变化

图 4 为 4 种不同的切片资源分配算法下 R2V-uUE 平均时延随 V2V-uUE 对数的变化曲线。从图 4 可以看出, 4 种分配算法的 R2V-uUE 平均时延都随 V2V-uUE 对数的增加而增加。这是由于过多的 V2V-uUE 用户对复用 R2V-uUE 的频谱对其

R2V 链路的传输速率产生了影响。但是本文所提算法最大限度地克服了这种影响。




图4 R2V-uUE 平均时延随 V2V-uUE 对数的变化

不同 RSU 缓存容量下 R2V-uUE 平均时延随系统文件数量的变化如图 5 所示。从图 5 可以看出, 平均时延会随着 RSU 缓存容量的增加而减少。但当文件总数远大于容量时, 下降趋势不明显。由于 RSU 具有缓存能力, R2V-uUE 可以直接从关联的 RSU 获取缓存文件, 而没有前传时延。




图5 R2V-uUE 平均时延随系统文件数量的变化

本文所提算法下用户满意度随 RB 数量的变化如图 6 所示。从图 6 可以看出, 系统采用相同 RB 数量的前提下, 允许频谱共享具有更高的用户满意度, 从而容纳更多用户, 提高了频谱资源利用率。

5 结束语

针对软件定义多模态车联网, 本文设计了双时间尺度 RAN 切片资源缓存、频谱、功率智能分配算法。该算法在大时间尺度内基于匈牙利算法、线性整数规划方法解决用户关联和缓存放置决策子

问题, 在小时间尺度内基于 DDQN 算法解决 RB 分配和功率控制子问题。在满足 eMBB 切片用户最小传输速率需求和 V2V 链路可靠性的前提下, 算法通过不断学习车辆用户信道状态变化, 最终最小化 URLLC 切片用户的平均传输速率。仿真结果表明, 本文所提算法在保证不同切片用户 QoS 需求和提高频谱利用率方面优于传统算法。




图6 用户满意度随 RB 数量的变化

参考文献:

- [1] 张彦, 张科, 曹佳钰. 边缘智能驱动的车联网[J]. 物联网学报, 2018, 2(4): 40-48.
ZHANG Y, ZHANG K, CAO J Y. Internet of vehicles empowered by edge intelligence[J]. Chinese Journal on Internet of Things, 2018, 2(4): 40-48.
- [2] 胡宇翔, 伊鹏, 孙鹏浩, 等. 全维可定义的多模态智慧网络体系研究[J]. 通信学报, 2019, 40(8): 1-12.
HU Y X, YI P, SUN P H, et al. Research on the full-dimensional defined polymorphic smart network[J]. Journal on Communications, 2019, 40(8): 1-12.
- [3] 李军飞, 胡宇翔, 伊鹏, 等. 面向 2035 的多模态智慧网络技术发展路线图[J]. 中国工程科学, 2020, 22(3): 141-147.
LI J F, HU Y X, YI P, et al. Development roadmap of polymorphic intelligence network technology toward 2035[J]. Strategic Study of CAE, 2020, 22(3): 141-147.
- [4] BOUKERCHE A, ALJERI N. Design guidelines for topology management in software-defined vehicular networks[J]. IEEE Network, 2021, 35(2): 120-126.
- [5] ZHAO L, HAN G, LI Z, et al. Intelligent digital twin-based software-defined vehicular networks[J]. IEEE Network, 2020, 34(5): 178-184.
- [6] SARAIVA T D V, CAMPOS C A V, FONTES R D R, et al. An application-driven framework for intelligent transportation systems using 5G network slicing[J]. IEEE Transactions on Intelligent Transportation Systems, 2021, 22(8): 5247-5260.
- [7] 杨立, 李大鹏. 网络切片在 5G 无线接入侧的动态实现和发展趋势[J].

- 中兴通讯技术, 2019, 25(6): 8-18.
- YANG L, LI D P. Realization and trend of network slicing in 5G NG-RAN[J]. ZTE Communications, 2019, 25(6): 8-18.
- [8] CAMPOLO C, MOLINARO A, IERA A, et al. 5G network slicing for vehicle-to-everything services[J]. IEEE Wireless Communications, 2017, 24(6): 38-45.
- [9] WU W, CHEN N, ZHOU C H, et al. Dynamic RAN slicing for service-oriented vehicular networks via constrained learning[J]. IEEE Journal on Selected Areas in Communications, 2021, 39(7): 2076-2089.
- [10] YE Q, SHI W S, QU K G, et al. Joint RAN slicing and computation offloading for autonomous vehicular networks: a learning-assisted hierarchical approach[J]. IEEE Open Journal of Vehicular Technology, 2021, 2: 272-288.
- [11] NASSAR A, YILMAZ Y. Deep reinforcement learning for adaptive network slicing in 5G for intelligent vehicular systems and smart cities[J]. IEEE Internet of Things Journal, 2022, 9(1): 222-235.
- [12] KHAN A A, ABOLHASAN M, NI W, et al. An end-to-end (E2E) network slicing framework for 5G vehicular ad-hoc networks[J]. IEEE Transactions on Vehicular Technology, 2021, 70(7): 7103-7112.
- [13] XIONG K, LENG S P, HU J, et al. Smart network slicing for vehicular fog-RANs[J]. IEEE Transactions on Vehicular Technology, 2019, 68(4): 3075-3085.
- [14] KHAN H, SAMARAKOON S, BENNIS M. Enhancing video streaming in vehicular networks via resource slicing[J]. IEEE Transactions on Vehicular Technology, 2020, 69(4): 3513-3522.
- [15] YU K, ZHOU H B, QIAN B, et al. A reinforcement learning aided decoupled RAN slicing framework for cellular V2X[C]//Proceedings of 2020 IEEE Global Communications Conference. Piscataway: IEEE Press, 2020: 1-6.
- [16] BOLLA R, BRUSCHI R, DAVOLI F, et al. Energy efficiency in the future Internet: a survey of existing approaches and trends in energy-aware fixed network infrastructures[J]. IEEE Communications Surveys & Tutorials, 2011, 13(2): 223-244.
- [17] WEI L L, HU R Q, QIAN Y, et al. Energy efficiency and spectrum efficiency of multihop device-to-device communications underlying cellular networks[J]. IEEE Transactions on Vehicular Technology, 2016, 65(1): 367-380.

[作者简介]



元伟敬（1991-），女，山东济南人，博士，重庆邮电大学讲师，主要研究方向为车联网、边缘计算、资源分配等。



宋清洋（1976-），女，河北唐山人，博士，重庆邮电大学教授、博士生导师，主要研究方向为协作资源管理、无线携能通信、边缘计算、移动缓存等。



郭磊（1980-），男，四川眉山人，博士，重庆邮电大学教授、博士生导师，主要研究方向为光通信网络、无线通信网络。