

基于行动受限深度强化学习的C-V2X分布式通信拥塞控制研究

朱晓康¹, 欧阳敏^{1,2}, 王颐南³, 王桐^{1,2}, 高山^{1,2}, 肖培⁴

(1. 哈尔滨工程大学, 黑龙江 哈尔滨 150001; 2. 黑龙江省智能感知与群体智能计算创新研究中心, 黑龙江 哈尔滨 150001; 3. 哈尔滨市公安局南岗分局网络安全保卫大队, 黑龙江 哈尔滨 150001; 4. 英国萨里大学通信系统研究所, 英格兰 萨里郡 GU2 7XH)

摘要: 对车联网领域蜂窝车联网 (C-V2X, Cellular Vehicle-to-Everything) 分布式拥塞控制 (DCC, Distributed congestion control) 在动态需求下的适应性问题进行了研究, 提出了基于行动受限深度 Q 网络 (AC-DQN, Action-confined deep Q-network) 的单层和双层架构的自适应 DCC 算法, 实现动态优化车对车 (V2V, Vehicle-to-Vehicle) 通信参数以提高网络数据包传输率 (PDR, Packet Delivery Ratio)。该算法通过在行动域中选定范围限定的子行动域, 并在子行动域中确定具体行动, 实现自主调整通信参数以适应不同环境, 从而缓解信道拥塞。采用集中训练、分布式部署模式, 且适用于高维状态动作空间的深度强化学习 (DRL, Deep reinforcement learning) 算法。仿真结果表明, 与现有 C-V2X DCC 算法相比, 所提算法在 PDR 和吞吐量方面表现更优。

关键词: 强化学习; C-V2X; 双层模型; DCC 算法; V2V 通信

doi: 10.11959/j.issn.2096-3750.XXXX.

Research on Distributed Communication Congestion Control in C-V2X Based on Action-Restricted Deep Reinforcement Learning

ZHU Xiaokang¹, OUYANG Min^{1,2}, WANG Yinan³, WANG Tong^{1,2}, GAO Shan^{1,2}, XIAO Pei⁴

1. Harbin Engineering University, Harbin, Heilongjiang 150001

2. Heilongjiang Provincial Innovation Research Center for Intelligent Perception and Collective Intelligence Computing, Harbin, Heilongjiang 150001

3. Cybersecurity Protection Team, Nangang Branch of Harbin Public Security Bureau, Harbin 150001, Heilongjiang Province

4. Institute of Communication Systems, University of Surrey, GU2 7XH, Surrey County, England

Abstract: This study investigates the adaptability issue of distributed congestion control (DCC) for cellular vehicle-to-everything (C-V2X) in vehicular networks under dynamic demands. It proposes adaptive DCC algorithms based on action-confined deep Q-network (AC-DQN) with single-layer and dual-layer architectures, achieving dynamic optimization of vehicle-to-vehicle (V2V) communication parameters to improve the packet delivery ratio (PDR). The algorithm autonomously adjusts communication parameters to adapt to different environments by selecting a range-limited sub-action domain within the action domain and determining specific actions within the sub-action domain, thereby alleviating channel congestion. It employs a centralized training and distributed deployment mode and is suitable for deep reinforcement learning (DRL) algorithms with high-dimensional state-action spaces. Simulation results show that compared to existing C-V2X DCC algorithms, the proposed algorithm performs better in terms of PDR and throughput.

Key words: reinforcement learning, c-v2x, bi-level model, dcc algorithm, v2v communication

收稿日期: XXXX-XX-XX; 修回日期: XXXX-XX-XX

通信作者: 王桐, wangtong@hrbeu.edu.cn

基金项目: 国家自然科学基金资助项目 (No.62372131); 黑龙江省重点研发计划资助项目 (No.2023ZX01A20)

Foundation Items: The National Natural Science Foundation of China (No.62372131), The Key Research and Development Program of Heilongjiang Province (No.2023ZX01A20)

0 引言

在车联网通信领域,蜂窝车联网(C-V2X, Cellular Vehicle-to-Everything)技术作为未来智能交通系统的关键支撑,正迅速发展并受到广泛关注^[1]。然而,随着车辆数量的不断增加,尤其是在高密度交通场景中,无线信道资源的有限性导致其容易过载,进而引发通信拥塞。这种拥塞不仅会降低通信效率,还可能影响车辆的安全性和交通流畅性^[2]。因此,如何有效管理和优化无线信道资源,避免拥塞的发生,成为当前车联网通信领域亟待解决的重要问题。

分布式拥塞控制(DCC, Distributed Congestion Control)算法被认为是解决这一问题的核心方案^[3],其通过动态调整通信参数来优化资源分配,从而缓解信道拥塞。然而,现有DCC算法在动态适应性和多参数优化方面存在显著不足^[4]。一方面,现有算法缺乏对动态服务质量(QoS, Quality of Service)需求的自适应调节能力,难以在复杂多变的交通和通信环境中精准达成性能目标^[5]。另一方面,现有算法在传输功率、数据包速率^[6]及调制与编码方案(MCS, Modulation and Coding Schemes)等关键参数的协同优化中存在平衡性瓶颈^{[7][8]},无法实现全局最优的资源分配。

鉴于上述挑战,本研究提出了一种基于行动限域深度Q网络(AC-DQN, Action-confined Deep Q-Network)的自适应DCC算法。该算法的核心创新在于通过行动限域技术,将复杂的动作空间划分为多个子行动域,并在子行动域中动态选择最优动作,从而实现多通信参数的高效联合调整。这一方法不仅有效降低了算法的计算复杂度,还显著提升了算法在动态环境下的适应性。此外,本研究首次将行动限域的深度强化学习技术应用于车联网DCC问题,提出了分层控制的多层强化学习架构,包括单层和双层模型。双层模型通过将第一层的输出作为第二层的输入,进一步优化了动作选择的精度和效率,为解决高维状态动作空间问题提供了新的思路。

本研究提出的AC-DQN算法旨在通过创新的行动限域技术和分层强化学习架构,解决现有DCC算法在动态适应性和多参数优化中的不足^{[9][10]},为C-V2X网络的高效通信和拥塞控制提供

一种全新的解决方案。该算法不仅能够有效应对动态交通环境中的复杂需求,还能够显著提升系统的整体性能和可靠性,为未来智能交通系统的安全、高效运行提供支持。

1 相关工作

随着车联网技术的不断发展,通信场景变得更加复杂和动态化。为确保通信过程中的高效性与可靠性,人们越来越关注在车对车(V2V)中开发和实施分布式拥塞控制(DCC)方法。主要目标是管理网络拥塞并增强V2X通信的可靠性^[11-13]。由于不同研究中控制策略和性能指标的多样性,难以比较不同的DCC方法,因此,标准化组织ETSI开发了性能评估标准,并提出了统一的跨层DCC框架。本研究将重点关注优化两个主要指标的DCC方法:每链路吞吐量(PLT, Per-Link Throughput)和数据包接收率(PDR, Packet Delivery Rate)^[3]。

较高的PLT值表明通信吞吐量更高,反映了信道的利用效率更高。PDR是通过将接收到的数据包数量除以发送的数据包数量来计算的^[3],因此它作为网络内成功通信的衡量标准。较高的PDR值意味着更好的信号接收^[14],确保关键的安全和交通信息在车辆之间有效通信。本研究关注这些优化目标及其对网络效率的影响,旨在提供对V2V中DCC的见解,同时指出未来探索和开发的可能方向。

文献[15]中的联合功率和速率算法可以为不同车辆设置不同的优先级,引入了V2V通信中的公平性,并通过多种场景的仿真验证了该算法的性能。在文献[16]中,作者提出了一种基于感知的混合信标算法,该算法以驾驶员状态为参考条件,并将其广播给附近的车辆,然后共同决定调整传输范围和功率,以提高安全性。在文献[17]中,作者提出了一种将实时交通流感知与信道拥塞状态相结合的方法,利用分布式网络效用最大化来提高信道利用率。文献[18]通过“分阶段取消关键消息速率控制”的混合策略,在保证信道不拥塞的前提下,解决了安全关键型机动协调消息在V2X网络拥塞时被延迟或丢弃的难题。文献[19]通过VISSIM与WiLabV2Xsim的跨层协同仿真,定量分析了分布式拥塞控制对协同自适应巡航控制性能的影响。研究[20]首次实现了设施层多信道拥塞控制(MCO-FAC, Facility layer multi-channel congestion con-

trol), 采用自适应 DCC 算法实时计算可用资源并按优先级分配, 通过 Docker 虚拟化环境验证了其能有效控制信道负载并实现服务差异化。

近年来, 深度强化学习 (DRL, Deep Reinforcement Learning) 在无线通信领域展现出强大的潜力, 能够有效提升系统的性能和适应性^[21]。但现有的基于 DRL 的拥塞控制方法大多集中在传统模型上, 这些模型在复杂环境下的表现仍有待提升^{[22][23]}。例如, 一些集中式 DRL 拥塞控制方案虽然提升了 C-V2X 通信的可靠性, 但降低了吞吐量^[10]; 而多智能体 DRL 算法虽然在资源分配方面表现出色, 但通信开销较大且适应性、鲁棒性仍需验证^[24]; 使用双深度 Q 学习网络可以根据每辆车的风险评估自适应地控制消息速率, 但计算复杂度较高^[25]。尽管 DRL 的泛化能力被广泛探讨^{[26][27]}, 针对 DCC 多参数动态调控的智能适配框架仍不完善^[8]。

研究整合了传输间隔控制和功率控制的优点^[28], 改善了拥塞控制。功率控制通过在允许的情况下降低传输功率, 实现了能效通信, 而传输间隔控制在信道质量良好时优化传输速率以最大化吞吐量。该系统提供了能效与网络效率之间的可调平衡。

2 系统模型

在 C-V2X 通信技术中, 其采用了单载波频分多址 (SC-FDMA) 方式, 并且可运用 10 MHz 或 20 MHz 的信道进行数据传输^[29]。每个信道在时间和频率这两个维度上, 被分为子帧以及子信道。其中, 子帧的时长固定为 1 ms, 子信道带宽 180 kHz, 一个包含一个子信道的子帧为一个资源块 (RB, Resource Block)。当车辆用户设备 (VUE, Vehicle User Equipment) 在子帧 s 中传递消息时, 会使用 N 个子信道来完成这一过程, 其中 N 的取值范围为 $\{1, 2, \dots, n\}$, s 表示子帧的索引。值得注意的是, 一个消息所能承载的 RB 数量会受到消息大小以及调制与编码方案 (MCS) 索引的影响, 因而 N 也会随之相应地做出调整。在本研究的设定下, N 会根据 VUE 数量与可用的资源数量取范围内的最大值。在此基础上, VUE 会自主地选择资源, 并使用基于感知的半持续调度策略 (SB-SPS, Sensing-Based Semi-Persistent Scheduling)^[9] 的改进算法即车辆密度驱动的自适应资源预留 (VD-ARR, Vehicle

Density-driven Adaptive Resource Reservation) 引导的双深度 Q 网络 (VG-DDQN, VD-ARR Guided Double Deep Q-Network)^[30] 资源分配方案来进行资源选择。VG-DDQN 将 VD-ARR 理论分析确定的参数调整空间映射为强化学习的动作空间, 通过双深度 Q 网络学习最优的重选计数器与重选概率的参数组合策略, 在高密度场景下实现更优的通信质量。

假设车辆网络由 M 个 VUE 组成, VUE 的集合为 $\{1, 2, \dots, M\}$, 在子帧 s 的第 n 个子信道上计算第 m 个 VUE 到第 d 个 VUE 的信噪比 (SINR) 为:

$$\gamma_{(m,d)}[s,n] = \frac{\delta_m[s,n] C_{(m,d)}[s,n]}{\sigma^2 + I_d[s,n]} \quad (1)$$

其中, $\delta_m[s,n]$ 是二进制指示器, 如果子帧 s 的第 n 个子信道由 VUE m 占用, 则其值为 1, 否则为 0。

其中:

$$C_{m,d}[s,n] = \frac{P_m \cdot G_t \cdot G_r \cdot S}{PL_{(m,d)}} \quad (2)$$

公式表示 VUE d 检测到 VUE m 的功率, 式中 P_m 是第 m 个 VUE 在 RB 上的发射功率, G_r 是接收增益, G_t 是发射增益, S 是阴影系数, $PL_{(m,d)}$ 表示 VUE d 到 VUE m 的包括路径损耗和阴影衰落的衰落效应, 包含 LOS (Line of Sight) 衰落与 NLOS (Non Line of Sight) 衰落。其中 LOS 衰落表达式为:

$$PL_{LOS} = 40.0 \log_{10}(d_{(m,d)}) + 27.0 + 20.0 \log_{10}(f_c) \quad (3)$$

而 NLOS 衰落表达式为:

$$PL_{NLOS} = (44.9 - 6.55 \log_{10}(h_{MS})) \log_{10}(d_{(m,d)}) + 5.83 \log_{10}(h_{MS}) + 18.38 + 23 \log_{10}(f_c) \quad (4)$$

式中, h_{MS} 表示天线高度, $d_{(m,d)}$ 表示 VUE d 到 VUE m 的距离, f_c 表示中心频率, 而 σ^2 则表示 RB 上的噪声功率。

$$I_d[s,n] = \sum_{w \in W, w \neq m} \sum_{g \in N} \delta_w[s,g] K_{IBE}[s,g] C_{(w,d)}[s,g] \quad (5)$$

式 (5) 计算了在相同子帧上进行传输的 VUE 所造成的干扰。在式中, W 是占用同一子帧的 VUE 集合, $K_{IBE}[s,g]$ 是带内发射系数, 使用研究 [31] 中的方法确定; 当 $g=n$ 时其值为 1, 否则具有较低的值。数据包传输率 (PDR) 定义为成功接收的数据包与发送方发送的总数据包数的比值; 因此, 第 m 个 VUE 使用子帧 s 的第 n 个子信道的 PDR 记为 $Q_m[s,n]$, 表达式为:

$$Q_m[s, n] = \frac{\sum_{d \in \zeta} \psi_{(m,d)}[s, n]}{\sum_{d \in \eta} \phi_{(m,d)}[s, n]} \quad (6)$$

其中, $\phi_{(m,d)}[s, n]$ 是 VUE m 发送到 VUE η 的数据包, $\psi_{(m,d)}[s, n]$ 意为 VUE ζ 成功接收的数据包, 而 η 和 ζ 分别构成位于第 m 个 VUE 通信范围内的 VUE 集合以及成功接收数据包的数据包 VUE 集合。

3 模型与算法

3.1 问题模型

随着车辆密度增加, 数据包传输率 (PDR) 下降。本研究旨在高车辆密度和噪声环境中, 通过控制数据包传输间隔和发送功率, 找到最优传输参数以最大化车辆用户设备 (VUEs) 的平均 PDR (记作 ζ_{aver})。问题模型如下:

$$P1: \max \zeta_{aver} = \frac{\sum_{m \in M} \sum_{d \in \zeta} \psi_{m,d}[s, n]}{\sum_{m \in M} \sum_{d \in \eta} \phi_{m,d}[s, n]} \quad (7)$$

$$C1: t_{ITT} \in (t_1, t_2), p_{Tx} \in (p_1, p_2),$$

$$C2: \sum_{n \in N} \delta_m[s, n] \leq \left\lfloor \frac{50t_{ITT} - N_{fe}}{M} \right\rfloor, \delta_m[s, n] \in Z, m \in M,$$

$$C3: \zeta_{aver} \geq \zeta_{target}$$

其中, M 是 VUE 的集合, 是目标 PDR, ψ 是每个 VUE 接收到的数据包, ϕ 代表发送的数据包, t_{ITT} 表示发信时间间隔, p_{Tx} 表示发信功率, δ_m 表示第 m 个 VUE 选择的子信道数。约束条件 C1 限制 VUEs 的传输时间和发射功率, 防止超出实际应用范围, 避免算法性能依赖超出范围的参数增长。C2 规定每个 VUE 选择的子信道小于等于可用资源所能承受的最大值, 这会引发多节点信道选择的组合问题。C3 要求平均 PDR 不低于目标值。由于时间和功率的互补性, 存在多个局部最优解。这些因素使得使用传统方法解决 P1 问题具有挑战性。

3.2 提出的算法

为解决上述拥塞问题, 基于行动受限深度强化学习 (AC-DRL) 本研究提出了单层和双层架构的 DCC 算法。算法基于深度 Q 网络 (DQN), 采用集中训练, 分布式部署模式。由于 DQN 面对高维动作和状态信息时会遇到困难, 故基于简化多个通信参数的思想, 为了实现多参数的联合调控, 提出的算法将行动域划分为多个子行动域, 并通过在不同环境下选择相应的子行动域输出, 来实现通信参数

的动态调整, 以提高通信质量。

在所提出的算法中, 研究人员将传输功率与间隔时间形成的二维有限平面平均划分为大小相同的行动区域。在单层算法架构与双层算法架构的第一层模型中, 划分数设置为 4×4 ; 在双层算法架构的第二层模型中, 划分数设置为 3×3 。

3.2.1 基于单层 AC-DRL 的 DCC 算法架构




图1 基于行动受限的单层 DRL 模型的 DCC 算法架构

图1展示了一种基于行动受限的单层 DRL 模型的 DCC 算法架构, 其中集中控制器作为代理, 耦合一个 DQN 并进行学习。DQN 由主网络、目标网络和回放缓存组成, 主网络使用包含 50 个神经元的三个全连接层构成的深度神经网络近似状态-动作对的 Q 值 $Q(s, a; \theta)$, 并通过最小化损失函数 $L(\theta) = E[(y_i - Q(s, a; \theta))^2]$ 更新网络权重 θ 。目标网络与主网络有着相同的结构, 用于计算目标值 $y_i = r_i + \gamma \max_{a'} \hat{Q}(s', a'; \theta)$, 其中 γ 是折扣因子, $\hat{Q}(s', a'; \theta)$ 表示目标网络的 Q 值, 其权重为 θ 。回放缓存负责存储经验 (s, a, r, s') , 并在每一步随机抽取小批量经验来确定目标值 y_i 。行动域被划分为多个子行动域, 每次行动网络会选择一个子行动域输出, 动作 a_t 是选取的子行动域中的一个点的映射。在 DQN 中, 使用回放缓存和独立的目标网络可以稳定学习并提高性能^[32]。

模型采用含有三层隐藏层的全连接神经网络, 如图2所示, 网络采用后向传播更新参数并采用 ReLU 激活函数。后向传播通过自动求导机制计算损失函数关于网络参数的梯度, 所求得的梯度数据

随后被优化器用于更新网络参数, 整个过程从后层至前层逐层进行。ReLU 激活函数的表达式为




图2 DRL的全连接网络层结构

$y = \max \{0, x\}$ ，它在全连接网络中具有较高的计算效率，并且由于其线性特性，在正区间内不会出现梯度饱和，因此可以有效缓解梯度消失问题。

DRL模型的基本参数如下：**代理**：设置一个可以收集环境中所有VUE节点信息的集中控制器作为代理。**状态**：在时间步 t 时，环境中的平均VUE节点数目与PDR运算得到的向量定义为模型的状态输入，一般来说，环境中的平均VUE节点数目直接影响了当前环境的拥塞水平，而PDR则直接反映了拥塞状况。**动作**：本研究算法采用数据包传输间隔以及发射功率控制。算法的动作域由时间轴和功率轴构成，每个具体动作对应平面上的一个

点。模型在平面上的限域动作集合可表示为域 $A = \{(t, p_{tx}) | t_1 \leq t \leq t_2, p_1 \leq p_{tx} \leq p_2\}$ 的有限子集 $A_1, A_2, A_3 \dots$ 形成的集合，模型选择动作 A_n 时，算法则从其中选择一个点作为动作输出。其中 $\bigcup_{A_i \in A} A_i = A, i = 1, 2, \dots, 16$ 。**奖励**：所提出的DCC旨在提高平均PDR，协议要求PDR不低于0.85。奖励定义为 $r_t = -\alpha(\zeta_{tag} - \zeta) + \beta(t_0 - t) + \lambda(p_0 - p)$ 其中 $-\alpha(\zeta_{tag} - \zeta)$ 表示PDR条件， $\zeta_{tag} = 0.85$ 而 ζ 表示环境反馈的PDR值。如果仅使用PDR作为奖励，VUEs会过度增加发信时间间隔和发送功率以增加PDR。为了解决这个问题，我们在奖励中添加了时间与功率负反馈条件。而 α, β, λ 则表示每一项的权重系数。

3.2.2 基于双层AC-DRL的DCC算法架构

图3展示了所提出的基于行为受限的双层DRL模型的DCC算法的架构。双层模型相当于将两个单层模型复合而来，第一层模型的状态与奖励直接从环境中获取，与单层模型算法相同，但其输出则不直接作用于环境，而是作为第二层模型的状态变量输入到第二层，第二层模型再将第一层所选择的行为域均匀划分为 3×3 个大小相同的子行为域，然




图3 基于行为受限的双层DRL模型的DCC算法架构

后依据第一层模型的动作确定子行为域，并确定具体的行为点，即当第一层模型从行为域 A 中选择动作 A_n 输出时，第二层模型首先将其划分为 3×3 个大小相同的子行为域，再从中选择动作 A_{ni} 输出，其中 $\bigcup_{A_{ni} \subseteq A_n} A_{ni} = A_n, i = 1, 2, \dots, 9$ 。双层架构的两层模型共享同样的奖励，且与单层模型相同。

事实上，AC-DRL 算法并不局限于单双层架构，可以增加网络的复合层数，但高层的网络一般对应着更多的需要优化的参数，故本文只考虑单层与双层的网络架构模型。

表1 基于双层AC-DRL的DCC训练算法流程

算法1 基于双层AC-DRL的DCC训练算法
1: 初始化两个容量为 N 的经验回放池 E
2: 用随机权重 θ_1, θ_2 分别初始化两个 Q 网络
3: 用相同权重初始化两个目标 Q 网络: $\theta_1^- = \theta_1, \theta_2^- = \theta_2$
4: 把第一层模型的“行为域”划分为 4×4 网格
5: for episode = 1, M do
6: for time step = 1, T do
7: if step == 1 then set $t_{ITR} = 100 \text{ ms}, p_{Tx} = 23 \text{ dBm}$
8: end if
9: 以概率 ϵ 随机选择第一层动作 a_1 ;
10: 否则按 $a_1 = \arg \max_{a_1} Q_1(s_1, a_1, \theta_1)$ 贪婪选取动作
11: 依据 a_1 生成第二层模型的“行为域”划分
12: 以概率 ϵ 随机选择第二层动作 a_2 ;
13: 否则按 $a_2 = \arg \max_{a_2} Q_2(s_2, a_2, \theta_2)$ 贪婪选取
14: 由 a_2 对应的子行为域内随机取一个行为 $a_t = (t_{ITR}, p_{Tx})$ 广播数据包
15: 观测下一状态 $s_{1,t+1}$ 和 $s_{2,t+1}$ 及即时奖励 r_t
16: 将经验数据 $(s_1, a_1, r, s_{1,t+1})$ 存入 E_1 ;
17: 将经验数据 $(s_2, a_2, r, s_{2,t+1})$ 存入 E_2 ;
18: 从 E_1 随机选取小批量经验数据
19: 计算目标 $y_{1j} = r_j + \gamma \max_{a_1'} \hat{Q}_1(s_1', a_1'; \theta_1^-)$
20: 从 E_2 随机选取小批量经验数据
21: 计算目标 $y_{2j} = r_j + \gamma \max_{a_2'} \hat{Q}_2(s_2', a_2'; \theta_2^-)$
22: 用 $L_1(\theta_1)$ 优化并更新主网络权重 θ_1
23: 用 $L_2(\theta_2)$ 优化并更新主网络权重 θ_2
24: 每 C 步使用 $\theta_1^- = \theta_1$ 更新目标网络 $\hat{Q}_1$
25: 每 C 步使用 $\theta_2^- = \theta_2$ 更新目标网络 $\hat{Q}_2$
26: end for
27: end for

表1描述了基于行为受限DRL模型的DCC训练算法。首先初始化重放缓存、Q函数和目标Q函数，并设置第一层模型的行为域。每个训练回合中，算法通过双层模型选择动作：第一层模型随机

或基于Q值选择动作，生成第二层模型的动作域；第二层模型同样随机或基于Q值选择动作。选定动作用于广播数据包，算法记录奖励和状态转移。经验存储在缓冲区中，用于训练。算法优化损失函数更新Q函数权重，并定期更新目标网络以稳定学习。研究关注集中式训练与分布式执行方法^[33]。训练阶段，集中控制器利用集中式信息训练DQN；测试阶段，各分布式节点使用训练好的DQN选择动作。仿真结果在测试阶段获得，测试阶段使用在线进行网络环境测试。

3.3 算法复杂度及适应性分析

研究以梯度更新浮点运算次数（FLOPs, Floating Point Operations per Second）衡量算法计算复杂度，以经验回放存储需求衡量空间复杂度。并基于车规级芯片NVIDIA DRIVE AGX Xavier的性能计算算法理论上的训练功耗以及推理时延。研究对比单层与双层AC-DRL网络以及传统DRL的相关性能，各网络均采用相同的行动域。




图4 算法复杂度分析:(a)为空间复杂度(b)为计算复杂度




图5 时延与功耗分析:(a)为算法功耗(b)为算法推理时延

图4与图5展示了两种深度强化学习算法(AC-DQN与传统DQN)在算法复杂度与能效方面的对比分析结果。从算法复杂度看，单层AC-DQN的梯度更新FLOPs仅为322万，经验回放存储仅需30.86 MB，显著低于传统DQN（572万FLOPs，64.72 MB存储），体现出更优的轻量化特性。在运行时性能方面，单层AC-DQN的推理时延仅为8.91

微秒，训练功耗仅为 $5.16 \times 10^{-5} \text{J}$ ，均比传统DQN降低40%以上；双层AC-DQN虽然计算开销加倍（FLOPs 631 万，存储 61.72 MB），但其与传统DQN相比并无太大劣势。综合分析表明，单层AC-DQN在计算效率、内存占用、推理速度与能耗控制方面均显著优于传统DQN，尤其适用于对实时性与能效要求严格的边缘部署场景。而双层AC-DQN适用于资源充足的场景。

数据表明，单层与双层AC-DQN在车规级芯片上具有较低的功耗和延迟，能够满足车载系统对实时性和能效的严格要求，适合应用于自动驾驶和智能交通等场景。

对于AC-DQN的三层及以上的复合架构，其算法复杂度的增加与模型网络结构相关。若一个三层AC-DQN由双层AC-DQN重复第二层模型而来，则由图3分析可得，其计算复杂度较双层架构将增加约3.1MFLOPs，空间复杂度较之将增加约30 MB。同时，由于多层复合架构涉及对子行为域的进一步划分，故一个训练良好的多层模型会较低层模型具有更好的算法稳定性，但受限于其多层网络复合的结构，训练一个良好模型的难度也会增加。故多层复合的AC-DQN架构只适用于需要多参数联合优化或需要较高稳定性，且相应资源充足的场景。

通过对AC-DQN算法复杂度的计算分析可知（图3），在满足通信时延约束的前提下，双层AC-DQN所需计算能力约为15 - 20 TOPS，单层AC-DQN所需算力约为其一半，而三层及以上的AC-DQN则需要超过30 TOPS的算力。鉴于车规级芯片在实际运行中通常不会处于满载状态，其工作负载一般维持在30% - 70%之间，因此双层AC-DQN算法实际所需的等效算力约为30 TOPS。相应地，单层与多层结构在实际部署时所需算力将依据具体负载情况进一步减少或增加。

4 性能评估

在C-V2X通信系统中，系统性能受到多方面因素的共同影响，这些因素包含物理层和通信协议等多个层面。物理层方面主要包括信道衰落、多普勒频移、非视距传播以及各类干扰等^{[1][5]}；通信协议方面则涉及MCS指数选择、数据包发送频率、发射功率控制及资源调度算法等^{[22][28]}。这些因素之

间存在复杂的相互关联与作用，难以同时全面考察所有变量对系统性能的影响。

因此，本研究主要聚焦于数据包发送间隔与发射功率这两个关键参数，探讨它们对系统相关性能的具体影响，并在一定程度上分析讨论收发增益，以及MCS选择对系统的影响。

本研究聚焦于一个由M个VUEs构成的蜂窝车对万物网络，该网络中的VUEs依据密度 p 的一维泊松点过程^{[7][8]}分布在3公里长、三车道的高速公路上，平均时速为60 km/h，抵达终点后会循环返回相反方向，每辆车的感知范围设置为150 m^[34]，通信噪声为20 dB。VUEs通过车对车（V2V）侧链路通信广播协作感知消息（CAMs），采用10 MHz带宽的单载波频分多址（SC-FDMA）技术，依据SB-SPS策略^[8]自主选择无线资源。

研究使用LTEV2Vsim^[35]模拟器对上述场景进行仿真，仿真参数如表2所示。本研究以每链路吞吐量（PLT）作为性能指标来评估拥塞控制性能，PLT是指VUE从邻近VUE接收的数据量与所有V2V对的平均值，它受数据包传输率和碰撞导致的数据包丢失的影响，能反映通信的延迟和可靠性。

表2 车联网仿真参数

参数	参数设置
车辆平均速度	60 km/h
交通密度	200 - 400 veh/km
载波频率	5.9 GHz
信道带宽	10 MHz
传播模型	Winner+B1
数据包大小	300 Byte
发射增益 G_t	3 dB
接收增益 G_r	3 dB
天线高度	1.5 m
LOS 标准差	3 dB
NLOS 标准差	4 dB
调制编码方案	MCS5
RSRP 门限	-128 dBm
车辆速度标准差	10 km/h

4.1 基于AC-DRL模型的DCC性能分析

研究对比了AC-DRL模型Reward的各项组成部分在不同权重下的相应性能，同时与应用ETSI-DCC模型以及无DCC模型的情形进行了对比分析。

如图6和图7所示，双层AC-DRL模型相较于无DCC模型显著提升了PDR性能，而单层AC-

DRL 模型在选取较优的权重参数的前提下, 同样提升了 PDR 性能。在节点密度为 200 veh/km 时, 双层 AC-DRL 模型在最优配置 ($\alpha = 1$ 、 $\beta = 0.5$ 、 $\lambda = 1$) 下将 PDR 提升至 0.95 以上, 为后续密度增加留出充足余地, 而其他配置下模型的 PDR 明显较低。在 300veh/km 的节点密度下, 无 DCC 模型的 PDR 降至 0.80 以下, 而双层 AC-DRL 模型保持 PDR 在 0.90 以上。在 400veh/km 的极端高密度下, 无 DCC 模型的 PDR 降至 0.75 以下, 而双层 AC-DRL 模型的最优配置进一步将 PDR 提升至 0.95, 显著延缓了网络饱和。

同时, 对比单双层 AC-DRL 模型的性能表现可得出, 当环境中的节点密度发生变化时, 相较于单层模型, 双层 AC-DRL 模型在稳定性方面具有更优异的性能。




图6 单层AC-DRL模型的PDR性能




图7 双层AC-DRL模型的PDR性能

就 PLT 性能而言, 如图 8 和图 9 所示, 单层和双层 AC-DRL 模型同样展现出优越性能。在




图8 单层AC-DRL模型的PLT性能




图9 双层AC-DRL模型的PLT性能

200veh/km 时, 双层 AC-DRL 模型在最优配置下保持 PLT 接近 470Byte/s, 而无 DCC 模型的 PLT 较低。在 300veh/km 时, 无 DCC 模型的 PLT 显著降低, 而双层 AC-DRL 模型将 PLT 保持在 420 Byte/s 以上。在 400veh/km 的极端高密度下, 无 DCC 模型的 PLT 降至 360 Byte/s 以下, 而双层 AC-DRL 模型的最优配置保持 PLT 在 460Byte/s 左右。

参数敏感性分析表明, 将 β 从 0.5 增加到 1.0 会使 PDR 降低约 4 个百分点, 而 λ 的变化影响不到 2 个百分点, 表明 β (时间惩罚) 是主要因素。即使在强烈的双重维度惩罚条件下, 双层 AC-DRL 模型的 PDR 性能仍比无 DCC 模型高出 10 个百分点以上, 当密度超过 250 veh/km 时, PLT 性能也更高, 证明分层约束结构本身带来了相当大的增益。

总体而言, 双层 AC-DRL 模型在最优配置 ($\alpha = 1$ 、 $\beta = 0.5$ 、 $\lambda = 1$) 下, 在 200-400 veh/km 的全密度范围内实现了 $PDR \geq 0.9$ 和 PLT 衰减 $< 5\%$, 与

无DCC模型相比实现了10%-20%的提升，为高密度网络环境提供了实用的性能边界和参数基准。

4.2 AC-DRL模型与已有算法性能对比

研究对比了单层与双层AC-DRL模型的最优Reward配置 $\alpha = 1$ 、 $\beta = 0.5$ 、 $\lambda = 1$ 与文献[6]中的算法性能，同时与无DCC模型的情形进行了对比分析。文献[6]使用了传统的DQN网络对包生成时间进行控制，从而实现了PDR性能上的提升。




图10 PDR性能对比




图11 PLT性能对比

如图10所示，单层和双层AC-DRL模型与无DCC模型和文献[6]中的算法对比，显著提升了PDR性能。在节点密度为200 veh/km时，双层AC-DRL模型将PDR提升至0.95以上，而无DCC模型与对比算法的PDR明显较低。在300 veh/km的节点密度下，无DCC模型的PDR降至0.80以下，对比算法将PDR维持在0.85左右，而AC-DRL模型保持PDR在0.90以上。在400 veh/km的极端高密度下，无DCC模型的PDR降至0.75以下，对比算

法将PDR维持在0.80左右，而AC-DRL模型将PDR提升至0.85以上，显著缓和了通信拥塞。

就PLT性能而言，如图11所示，AC-DRL模型同样展现出优越性能。在200veh/km时，AC-DRL模型保持PLT接近470Byte/s，而无DCC模型与对比算法的PLT较低。在300veh/km时，无DCC模型与对比算法的PLT显著降低，而AC-DRL模型将PLT保持在400 Byte/s以上。在400veh/km的极端高密度下，无DCC模型的PLT降至350 Byte/s，而AC-DRL模型保持PLT至少在约400 Byte/s。

总体而言，AC-DRL模型在200-400 veh/km的全密度范围内实现了 $PDR \geq 0.85$ 和PLT衰减 $< 10\%$ ，与对比算法相比实现了10%-15%的同步提升，表明了AC-DRL模型的优异性能。

4.3 收发增益及MCS对系统性能的影响

研究在节点密度为200 veh/km的典型场景下，系统考察了收发增益与调制编码方案(MCS)对系统性能的耦合影响。除所关注的关键参数外，其余仿真参数均与表2保持一致。研究选取分组投递率(PDR)与每链路吞吐量(PLT)作为核心评估指标，以量化分析信道条件与MCS配置对通信性能的影响机理。研究对比分析了最优参数配置下($\alpha = 1$ 、 $\beta = 0.5$ 、 $\lambda = 1$)的双层AC-DRL模型、文献[6]所提DCC算法及无DCC基准的性能差异。




图12 不同发送-接收增益对模型PDR性能影响，(a)为无文献[6]DCC与无DCC情形，(b)为使用双层AC-DRL与无DCC情形。




图13 不同发送-接收增益对模型PLT性能影响，(a)为无文献[6]DCC与无DCC情形，(b)为使用双层AC-DRL与无DCC情形。

图 12 与图 13 分别表征了在不同发射增益与接收增益配置下, 系统分组投递率 (PDR) 与每链路吞吐量 (PLT) 的性能演化规律。其中, 图 12 (a) 与图 13 (a) 对比了基准 DCC 算法与无拥塞控制 (No-DCC) 策略的性能差异, 而图 12 (b) 与图 13 (b) 则评估了所提双层 AC-DRL 策略相对于无 DCC 基准的优化效果。

具体而言, 图 12 (a) 显示, 基准 DCC 算法的 PDR 性能曲面显著高于无 DCC 策略的曲面, 且图像表明 PDR 与收发增益之间呈现非线性正相关关系; 尽管对比算法对收发增益衰减导致的性能劣化具有一定补偿效应, 但其改善幅度有限。反观图 12 (b), 双层 AC-DRL 策略将 PDR 峰值提升至近 0.98, 且在全测试场景下较无 DCC 基准实现超过 30% 的相对增益; 且该策略对收发增益波动表现出强鲁棒性, 可有效抑制增益衰减对 PDR 的负面影响。

图 13 进一步揭示了吞吐量性能的差异化特征。如图 13 (a) 所示, 无 DCC 策略的 PLT 曲面上界高于基准 DCC 算法, 表明后者以牺牲部分吞吐量为代价换取可靠性提升, 且两种策略均呈现随增益递减而性能同步恶化的趋势。与之形成对比的是, 图 13 (b) 中 AC-DRL 策略有效缓解了增益衰减导致的吞吐量下降, 显著提升了 PLT 性能的稳定性, 几乎消除了收发增益变化对链路吞吐量的影响。

综合结果表明, 系统性能与收发增益呈显著正相关, 且发射增益与接收增益对系统性能的贡献度具有对称性。尽管 AC-DRL 策略可有效抑制增益衰减带来的性能劣化, 但在极端低增益条件下仍无法完全消除其负面影响。此外, 该策略通过自适应参数协调机制, 在显著提升分组投递率的同时有效稳定了每链路吞吐量, 全面验证了其在无线通信系统性能优化中的有效性与优越性。

图 14 与图 15 展示了系统性能随 MCS 的变化情况, 随着 MCS 值的增加, 系统的 PDR 性能与 PLT 性能均呈现出下降的趋势, 这表明较高的 MCS 值可能导致更复杂的信号调制, 从而影响信号的检测性能。

然而, 双层 AC-DQN 网络的分布式拥塞控制机制在动态信道环境下展现出优异的性能, 实验结果表明该方案成功突破了车载自组织网络中传统的性能-可靠性权衡范式, 实现了吞吐量与分组投递率的同步提升。




图 14 不同 MCS 对模型 PDR 性能影响




图 15 不同 MCS 对模型 PLT 性能影响

具体而言, 相较于无控制基准, 双层 AC-DQN 在 MCS 4-12 范围内将平均吞吐量提升 12.61% 的同时, 将分组投递率提高 12.66 个百分点, 严格优于其他对比方案。相比之下, 文献[6]所采用的 DCC 策略呈现出典型的过度拥塞控制特征, 虽然通过保守的退避机制将可靠性提升 7.63%, 但却导致吞吐量下降 11.44%, 使得综合数据投递能力反而低于无控制状态, 暴露出信道资源利用率不足的缺陷。

在环境适应性方面, 随着调制编码方案从低阶向高阶演进, 双层 AC-DQN 表现出卓越的鲁棒性, 其吞吐量与可靠性衰减率分别仅为 1.53% 和 1.72% 每 MCS 等级, 显著优于对比方案, 这得益于其通过持续环境交互学习到的风险感知型传输策略; 而文献[6]DCC 在高阶调制场景下性能衰减高达 3.06% 每 MCS 等级, 难以适应链路质量的动态变化。

5 结论

本文围绕蜂窝车联网 (C-V2X) 在高动态交通

环境下分布式拥塞控制（DCC）所面临的适应性不足与多参数耦合优化难题，提出并验证了一种基于动作约束深度Q网络（AC-DQN）的自适应控制框架，通过构建以最大化数据包传输率（PDR）为目标、兼顾功率与频谱资源限制的优化模型，首次将动作空间约束机制引入深度强化学习，以“子域逐层精确”的分层策略有效缓解高维连续空间探索效率低、收敛慢的固有缺陷，并在LTEV2Vsim仿真环境中系统评估了单层与双层架构在典型高速公路场景下的性能表现，结果显示双层AC-DRL模型在PDR上较无DCC情形平均提升约10% - 20%，与对比算法相比实现了10%-15%的同步提升，每链路吞吐量（PLT）在稳定性与持续性方面亦显著优于单层模型与对比算法，从而证实该框架具备优异的环境适应性与可扩展性。

未来工作将进一步结合自适应奖励策略以动态匹配不同交通密度下的QoS需求，探索去中心化多智能体强化学习、图神经网络与联邦学习在降低节点间通信开销的同时实现高协同分布式控制的方法，并拓展至跨层联合优化框架，融合毫米波、非正交多址（NOMA）及智能反射面（RIS）等新兴无线技术，同时在真实车联测试场与城市路网中开展原型部署与实验验证，以全面评估信道衰落、拓扑动态变化及节点失效等复杂因素对算法鲁棒性的影响，从而推动智能通信技术在车联网领域的进一步发展，助力构建安全、高效、可持续的未来智能交通系统。

参考文献：

- [1] LANSFORD J. LTE-V2X technology and standards[C]//Proceedings of the 2023 IEEE Conference on Standards for Communications and Networking (CSCN). Piscataway: IEEE Press, 2023: 73-76.
- [2] KIM S, KIM B J, PARK B B. Environment-adaptive multiple access for distributed V2X network: a reinforcement learning framework[C]//Proceedings of the 2021 IEEE 93rd Vehicular Technology Conference (VTC2021-Spring). Piscataway: IEEE Press, 2021: 1-7.
- [3] MANSOURI A, MARTINEZ V, HÄRRI J. A first investigation of congestion control for LTE-V2X mode 4[C]//Proceedings of the 2019 15th Annual Conference on Wireless On-demand Network Systems and Services (WONS). Piscataway: IEEE Press, 2019: 56-63.
- [4] CHEN S Z, HU J L, ZHAO L, et al. Cellular Vehicle-to-Everything (C-V2X)[M]. Singapore: Springer Nature Singapore, 2023: 1-20.
- [5] WANG J X, YING T, ZHU K L, et al. Large scale LTE-V2X test attempt via real deployment[C]//Proceedings of the 2022 IEEE 25th International Conference on Intelligent Transportation Systems (ITSC). Piscataway: IEEE Press, 2022: 3146-3151.
- [6] YANG W, JEON B, MUN C, et al. Cellular-V2X QoS adaptive distributed congestion control: a deep Q network approach[C]//Proceedings of the 2023 IEEE 20th Consumer Communications & Networking Conference (CCNC). Piscataway: IEEE Press, 2023: 967-968.
- [7] YOON Y, KIM H. Balancing power and rate control for improved congestion control in cellular V2X communication environments[J]. IEEE Access, 2020, 8: 105071-105081.
- [8] MAKSIMOVSKI D, LOBO S, FACCHI C. Prioritization of maneuver coordination messages and the impact of decentralized congestion control[C]//Proceedings of the 2024 IEEE 99th Vehicular Technology Conference (VTC2024-Spring). Piscataway: IEEE Press, 2024: 1-7.
- [9] TOGHI B, SAIFUDDIN M, FALLAH Y P, et al. Analysis of distributed congestion control in cellular vehicle-to-everything networks[C]//Proceedings of the 2019 IEEE 90th Vehicular Technology Conference (VTC2019-Fall). Piscataway: IEEE Press, 2019: 1-7.
- [10] ROSHDI M, BHADAURIA S, HASSAN K, et al. Deep reinforcement learning based congestion control for V2X communication [C]//Proceedings of the 2021 IEEE 32nd Annual International Symposium on Personal, Indoor and Mobile Radio Communications (PIMRC). Piscataway: IEEE Press, 2021: 1-6.
- [11] SHARMA S, PANJETA M. Optimization transmit rate-based decentralized congestion control scheme in vehicular ad hoc networks[J]. Innovations in Computational and Computer Techniques: icacct-2021, 2022, 2555: 030006.
- [12] BALADOR A, BAI C M, SEDIGHI F. A comparison of decentralized congestion control algorithms for multiplatooning communications[C]//Proceedings of the 2019 IEEE International Conference on Pervasive Computing and Communications Workshops (PerCom Workshops). Piscataway: IEEE Press, 2019: 674-680.
- [13] SABEEH S, WESOŁOWSKI K. Congestion control in autonomous resource selection of cellular-V2X[J]. IEEE Access, 2023, 11: 7450-7460.
- [14] ZENG L Q, SA P B, HAN Q W, et al. DRG-DCC: a driving risk gaming based distributed congestion control method for C-V2X technology[J]. Computers, Materials & Continua, 2025, 83(2): 2059-2086.
- [15] EGEA-LOPEZ E, PAVON-MARIÑO P, SANTA J. Optimal joint power and rate adaptation for awareness and congestion control in vehicular networks[J]. IEEE Transactions on Intelligent Transportation Systems, 2022, 23(12): 25033-25046.
- [16] CHHABRA R, KRISHNA C R, VERMA S. Context-aware hybrid

- adaptive beaconing for driver behavior dissemination in VANETs [J]. *IETE Journal of Research*, 2023, 69(7): 4113-4129.
- [17] AZNAR-POVEDA J, EGEA-LOPEZ E, GARCIA-SANCHEZ A J, et al. Time-to-collision-based awareness and congestion control for vehicular communications[J]. *IEEE Access*, 2019, 7: 154192-154208.
- [18] MAKSIMOVSKI D, FACCHI C, FESTAG A. Packet rate control for maneuver coordination in congested V2X communication environments[C]//*Proceedings of the 2024 IEEE 100th Vehicular Technology Conference (VTC2024-Fall)*. Piscataway: IEEE Press, 2024: 1-6.
- [19] JEON Y, YU S, MUN C. Poster: analyzing the impact of DCC on CACC by application and MAC layer co-simulation[C]//*Proceedings of the 2025 IEEE Vehicular Networking Conference (VNC)*. Piscataway: IEEE Press, 2025: 1-2.
- [20] SEPULCRE M, GUADALCAZAR Y, FORNELL M A, et al. V2X congestion control for multi-channel operation: a scalable validation in virtualized environments[C]//*Proceedings of the 2025 IEEE 101st Vehicular Technology Conference (VTC2025-Spring)*. Piscataway: IEEE Press, 2025: 1-5.
- [21] CHOI J Y, JO H S, MUN C, et al. Deep reinforcement learning-based distributed congestion control in cellular V2X networks[J]. *IEEE Wireless Communications Letters*, 2021, 10(11): 2582-2586.
- [22] SEHLA K, NGUYEN T M T, PUJOLLE G, et al. Resource allocation modes in C-V2X: from LTE-V2X to 5G-V2X[J]. *IEEE Internet of Things Journal*, 2022, 9(11): 8291-8314.
- [23] ZHANG X R, PENG M G, YAN S, et al. Deep-reinforcement-learning-based mode selection and resource allocation for cellular V2X communications[J]. *IEEE Internet of Things Journal*, 2020, 7(7): 6380-6391.
- [24] CHUNG Y C, CHANG H Y, CHANG R Y, et al. Deep reinforcement learning-based resource allocation for cellular V2X communications[C]//*Proceedings of the 2023 IEEE 97th Vehicular Technology Conference (VTC2023-Spring)*. Piscataway: IEEE Press, 2023: 1-7.
- [25] NGUYEN L H, NGUYEN V L, KUO J J. Efficient reinforcement learning-based transmission control for mitigating channel congestion in 5G V2X sidelink[J]. *IEEE Access*, 2022, 10: 62268-62281.
- [26] LUONG N C, HOANG D T, GONG S M, et al. Applications of deep reinforcement learning in communications and networking: a survey[J]. *IEEE Communications Surveys & Tutorials*, 2019, 21(4): 3133-3174.
- [27] SAAD M M, TARIQ M A, SEO J, et al. Age-of-information aware intelligent MAC for congestion control in NR-V2X[C]//*Proceedings of the 2023 Fourteenth International Conference on Ubiquitous and Future Networks (ICUFN)*. Piscataway: IEEE Press, 2023: 265-270.
- [28] TIAN J W, AN S, ISLAM A, et al. A hybrid power-rate management strategy in distributed congestion control for 5G-NR-V2X sidelink communications[J]. *Sensors*, 2023, 23(15): 6657.
- [29] 3GPP TS 38.214 V16.14.0 NR; Physical layer procedures for data (Release 16)[S].
- [30] ZHOU X K, HUI F, LIU J J, et al. Resource reservation in C-V2X networks for dynamic traffic environments: from vehicle density-driven to deep reinforcement learning[J]. *IEEE Transactions on Vehicular Technology*, 2025, 74(11): 17429-17444.
- [31] 3GPP TS 36.101 V14.8.0 Technical specification group radio access network; Evolved universal terrestrial radio access (E-UTRA); User equipment (UE) radio transmission and reception[S].
- [32] MNIH V, KAVUKCUOGLU K, SILVER D, et al. Human-level control through deep reinforcement learning[J]. *Nature*, 2015, 518(7540): 529-533.
- [33] FOERSTER J N. Deep multi-agent reinforcement learning[D]. Oxford: University of Oxford, 2018.
- [34] 3GPP TS 38.101-1 NR; User equipment (UE) radio transmission and reception; Part 1: Range 1 standalone[S].
- [35] CECCHINI G, BAZZI A, MASINI B M, et al. LTEV2Vsim: an LTE-V2V simulator for the investigation of resource allocation for cooperative awareness[C]//*Proceedings of the 2017 5th IEEE International Conference on Models and Technologies for Intelligent Transportation Systems (MT-ITS)*. Piscataway: IEEE Press, 2017: 80-85.