

面向高密度车间通信的能量特征图谱资源分配算法

邱恭安^① 刘永生^② 章国安^① 刘敏^{*①}

^①(南通大学信息科学技术学院 南通 226019)

^②(南通大学人工智能与计算机学院 南通 226019)

摘要: 车联网拓扑的动态性和资源分配的随机性增大了竞争接入相同资源的碰撞概率, 降低了频谱资源效率。该文基于高密度车辆运动位置的邻接稳定性, 提出了应用深度强化学习算法的能量特征图谱资源分配算法。首先, 应用资源感知过程测量值计算候选资源块的时隙接收信号强度指数和子载波信干噪比值, 构建候选资源库的时频能量特征图谱。随后, 将能量特征图谱输入构建的两层深度神经网络(DNN), 以系统吞吐量为奖励函数训练DNN权值系数矩阵, 建立匹配车辆运动状态的双DQN智能体模型, 并存储于车载用户终端(VUE)。当车间通信请求分配资源建立通信链路时, VUE将感知过程计算的接收信号强度指数和信干噪比值输入存储的主DQN模型, 根据训练后的DNN权值系数矩阵为车间通信选择高质量资源。应用离散时间马尔可夫链推导了资源接入碰撞概率、链路失效率与能量特征指数间的表达式。在高密度车间通信中, 所提出的算法提高了交通安全消息传播可靠性和频谱效率, 降低了端到端传播时延。在车辆密度不超过160 veh/km时, 提出算法的消息分组正确接收率超过95%、时延低于4 ms, 有效资源利用率高于0.6, 满足编队行驶等车联网应用的性能要求。

关键词: 蜂窝车联网; 资源分配; 深度强化学习; 能量特征图谱

中图分类号: TN929.5

文献标识码: A

文章编号: 1009-5896(2025)08-2642-10

DOI: 10.11999/JEIT250004

CSTR: 32379.14.JEIT250004

1 引言

在蜂窝车联网(Cellular Vehicle to Everything, C-V2X)中, 车间通信(Vehicle to Vehicle, V2V)利用位置邻近特点, 复用空闲频谱资源自主建立短距离直通通信连接, 以半双工通信模式实现交通安全消息的低时延、高可靠传播。在密集交通应用场景中, 大量V2V通信竞争接入有限频谱资源, 降低了资源选择冗余度, 增大了资源竞争接入碰撞概率^[1]。同时, 车辆高速运动导致的强动态网络拓扑影响, 降低了有限频谱资源效率^[2], 因此, 通过提高有限频谱资源分配的有效性有助于提升密集V2V通信性能和频谱资源效率。

目前, 车载用户终端(Vehicle User Equipment, VUE)使用基于感知的半持续调度(Sensing Based Semi-Persistent Scheduling, SB-SPS)机制中随机选择方法(Randomly Selected Scheme, RSS)分配可用频谱资源^[3,4]。通常, 减小资源选择的随机性一定程度上能够改善可用资源块(Resource Block, RB)集合分配的合理性。文献^[5]针对候选RB不确定性占用状态, 通过每个VUE宣称下

一次资源重选的预留信息来减少资源选择冲突, 信令开销较大, 通信资源效率低。通过调节通信速率或发射功率提高传输的可靠性。针对密集V2V链路慢衰落特征, 文献^[6]应用超图理论和遗传算法实现V2V可靠通信, 提升V2I通信容量, 但V2V通信具有更强的紧迫性。文献^[7]通过子载波选择和功率控制减小群集通信链路间的干扰, 降低了动态拓扑下的链路失效率, 增大了端到端时延。

当前, 增强的车载电子计算能力推进了应用智能计算方法解决资源竞争接入碰撞和V2V通信链路质量问题^[8]。文献^[9]借助可重构智能反射面联合优化功率分配和频谱共享, 减小高动态性下的信道增益损失, 算法性能依赖于信道状态信息的可靠性和实时性。文献^[10]应用图着色理论分簇车间通信链路, 通过三维匹配频谱资源与V2X链路, 降低链路间干扰, 提高系统吞吐量。深度强化学习(Deep Reinforcement Learning, DRL)的推理能力在解决不确定性问题上具有内在的优势^[11]。文献^[12]将通信链路建模为图端点, 提高DRL对全局链路状态的学习能力, 最小化链路间干扰, 确保高V2V通信接入率。文献^[13]提出的DRL-BH(DRL Based Hybrid)算法应用深度Q网络(Deep Q-Network, DQN)模型选择相对车辆运动位置具有最大信干噪比(Signal to Interference plus Noise Ratio, SINR)的资源, 消息传输可靠性高, 但频谱效率低。文献^[14]应用模糊逻辑辅助评价Q-Learning选择资源的有效性以

收稿日期: 2025-01-06; 改回日期: 2025-04-15; 网络出版: 2025-05-08

*通信作者: 刘敏 liuming@ntu.edu.cn

基金项目: 国家自然科学基金(62471258)

Foundation Item: The National Natural Science Foundation of China (62471258)

调整资源选择动作, 降低了不同V2V通信选择相同资源降低了接入碰撞问题, 资源效率达55%~60%。文献[15,16]使用多智能体模型适配V2V通信分布式特征提升了强化学习性能, 通过估计子信道选择概率或使用优先经验回放方法训练智能体, 减小资源状态不准确性, 降低竞争接入冲突概率。

在密集交通场景中, 频谱资源竞争接入的增大和链路状态的动态性降低了消息传播性能和频谱资源有效利用率, 传统方案一般从子载波SINR或链路负载状态上优化资源分配, 性能提升通常依赖于实时估计的资源状态参数。基于V2V通信的强邻近相关性和相对位置唯一性特征, 提出了应用DQN算法的能量特征图谱资源选择方法。首先, VUE采用经验回放方法训练智能体中主DQN模型的二层深度神经网络(Deep Neural Networks, DNN)权值参数, 并存储主DQN模型。当样本空间足够大时, 预计算的参数平均值等于实时的参数瞬时值, 算法性能独立于实时状态参数的估计。随后, VUE基于感知测量过程分别获取时隙和子信道的能量特征参数, 构建候选频谱资源的时频能量特征图谱(Energy Characteristic Map, ECM), 输入主DQN模型计算匹配当前V2V状态的频谱资源累积奖励函数值, 选择具有最大Q值的RBs建立V2V通信链路。

2 系统模型

设某双向6车道城市十字路口密集交通应用场景, 如图1所示, VUE采用分布式资源分配模式为V2V通信选择可用资源块, 包括同车道V2V通信对, 邻车道V2V通信对和邻路段V2V通信对。在通信区域内, 所有VUE竞争相同的空闲频谱资源库, 以建立V2V通信链路, 传播交通状态消息和交通安全消息。

2.1 能量特征图谱模型

在V2V通信中, VUE使用半双工通信方式收

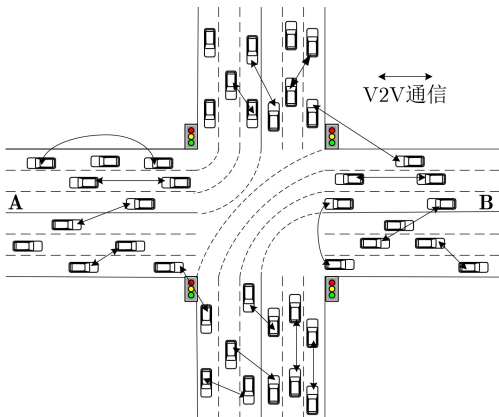


图1 密集交通应用场景

发消息分组, 通过资源感知过程获取空闲频谱状态。在3GPP序列标准中, 空闲频谱资源通常由 F 个时隙子帧和 C 个频域子信道构成的RB集合。当VUE触发资源请求时, 资源感知过程截取最近 H 个子帧时长为感知窗, 计算感知窗中每个子帧的接收信号强度指数(Received Signal Strength Indicator, RSSI)平均值, 则感知窗中第 i 子帧的能量特征参数RSSI均值如式(1)所示。

$$\overline{\text{RSSI}}_i = \frac{1}{H} \sum_{h=1}^H \text{RSSI} \quad (1)$$

其中, $i \in [1, F]$, $h \in [1, H]$ 为感知窗的第 h 次测量周期, $H = \frac{T}{\text{RRI}}$ 为感知窗口的测量周期总数, T 为感知窗的持续时间, RRI为资源预留间隔取值。当RSSI均值 $\overline{\text{RSSI}}$ 低于侧链路的RSSI门限值时, 表示该时隙子帧内资源不被蜂窝用户占用, 该子帧内RB作为备选资源块。当备选资源块的参考信号接收功率值低于设定的功率门限值时, 该资源块没有被通信区域内其他V2V占用, 则选择相应备选资源块放入候选资源库。

基于邻居车辆运动位置的相对稳定性, 通过计算子帧内子信道的SINR均值, 以估计子信道的准实时质量状态, 建立车辆运动状态和子信道质量间的适配关系。设第 i 子帧内第 j 子信道对应RB的能量特征参数SINR均值如式(2)所示。

$$\overline{\text{SINR}}_i^j = \frac{1}{H} \sum_{h=1}^H \frac{P_s G_{sr}}{N_0 + \sum_{k \in K} P_s G_{sk}} \quad (2)$$

其中, $j \in [1, C]$, P_s 为V2V单位资源块的发射功率, G_{sr} 为发送端 V_s 和接收端 V_r 之间的信道增益, N_0 为V2V链路噪声功率, K 为干扰VUE集, G_{sk} 为 V_s 和资源竞争端 V_k 间的干扰信道增益, $k \in [1, K]$ 。基于子帧能量特征参数 $\overline{\text{RSSI}}$ 值和子信道能量特征参数 $\overline{\text{SINR}}$ 值, 构建候选资源库的能量特征图谱模型如图2所示。

2.2 通信资源选择优化模型

在图1所示应用场景中, 设VUE集合为 $V = \{V_1, V_2, \dots, V_U\}$, U 为VUE总数。当V2V通信对中 V_s 选择候选资源库的第 i 子帧内RB向 V_r 传输消息分组时, 传输速率 R 如式(3)所示。

$$R = N \cdot B_{\text{RB}} \log_2 \left(1 + \frac{1}{N} \sum_{j=1}^N \overline{\text{SINR}}_i^j \right) \quad (3)$$

其中, N 为选择的相邻RB总数, B_{RB} 为单位RB带宽, 一般为15 kHz。当所有V2V通信都能建立相对自身运动状态的最高质量链路时, 实现最优化V2V

作, DQN计算当前状态下对应每一个动作的价值函数Q值, 为智能体决策提供参考。

设第 t 时刻智能体与环境交互产生经验样本 $e_t = (s_t, a_t, r_t, s_{t+1})$, 每次智能体与环境交互后放入经验池一个经验样本 e , 累积为经验样本集 $E = \{e_1, e_2, \dots, e_t\}$, 并使用经验回放方法训练DNN权值参数, 获得状态匹配的权值参数向量 θ 。设第 $(t+1)$ 时刻目标DQN的目标Q值 y 近似如式(6)所示

$$y = r_t + \gamma \max Q(s_{t+1}, a_{t+1}; \theta^-) \quad (6)$$

其中, γ 为折扣因子, $\gamma \max Q(s_{t+1}, a_{t+1}; \theta^-)$ 为期望未来折扣奖励。由此, 构造DNN权值参数向量 θ 的损失函数为 $L(\theta) = [y - Q(s_t, a_t; \theta)]^2$ 。

在训练DNN过程中, 每次从经验池样本集 E 中随机取出 N_E 个“经验样本”计算损失函数均值 $L_E(\theta)$, 如式(7)所示

$$L_E(\theta) = \frac{1}{N_E} \sum_1^{N_E} (y - Q(s_t, a_t; \theta))^2 \quad (7)$$

应用随机梯度下降(Stochastic Gradient Descent, SGD)算法最小化损失函数均值 $L_E(\theta)$ 计算DNN各边权值参数偏差, 如式(8)所示, 以调整权值参数向量 θ 取值使其适配输入状态, 如式(9)所示

$$\nabla_{\theta} L_E(\theta) = E \left[(Q(s_t, a_t; \theta) - y) \frac{\partial Q(s_t, a_t; \theta)}{\partial \theta} \right] \quad (8)$$

$$\theta = \theta - \alpha \nabla_{\theta} L_E(\theta) \quad (9)$$

其中, α 为学习率。每经过一个权值参数向量迭代周期, 将主DQN中DNN权值参数向量 θ 复制给目标DQN中DNN权值参数向量 θ^- 。VUE存储训练完成的主DQN模型, 用于V2V通信选择资源。

3.3 能量特征图谱资源选择方法

设在第 i 时隙内VUE业务请求分配通信资源, 若感知周期中测量的第 i 时隙内第 j 子信道上RB时

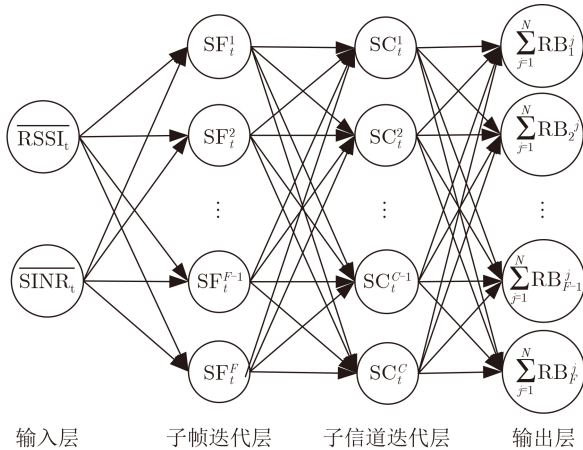


图4 DNN网络

频能量特征状态值为 $s_i = \{\overline{\text{RSSI}}_i, \overline{\text{SINR}}_i^j\}$, 则候选资源库内所有RB的能量特征图谱为 $s = (\{\overline{\text{RSSI}}_i\}, \{\overline{\text{SINR}}_i^j\})$, $i \in [1, F]$, $j \in [1, C]$ 。随后, 将候选资源库内所有RB的能量特征图谱输入主DQN模型, 输出每个时隙的RB集合 $\{\sum_{j=1}^N \text{RB}_i^j\}$, DQN计算每个时隙输出资源对应的Q值 $Q(s, a; \theta)$ 。最后, 智能体选择当前最大Q值的RB集作为输出动作 a , 即选择 $\min \{\overline{\text{RSSI}}_i\}$ 时隙子帧内具有 $\max \{\overline{\text{SINR}}_i^j\}$ 子信道的RB集建立V2V通信链路。智能体生成经验样本 $e = (s, a, r, s')$ 放入经验池 E , 并采用先入先出(First Input First Output, FIFO)方法更新保留最后 M 个经验样本, 同时, 资源调度机制将本次选择的RB集指配给当前V2V通信, 用于传输消息分组。

4 能量特征参数影响及算法复杂度分析

ECM算法优先选择相对车辆运动位置具有较高质量的资源建立通信链路, 因此, 资源竞争接入碰撞和链路动态性直接影响交通消息传播的分组正确接收率。根据V2V通信对消息分组时延的严格要求, 所有非正确接收分组都直接丢弃。在 t 时刻, 设消息分组成功传输概率为 P_{succ} , 则消息分组的传输状态转移过程建模为无缓存离散时间马尔可夫链(Discrete Time Markov Chains, DTMC)模型^[17], 如图5所示。

4.1 时域特征参数对竞争接入影响分析

设在资源选择窗内总时隙数为 N_{slot} , 共有 N_p 对V2V通信请求分配某一个时隙子帧内资源块, 则当前V2V在某一时刻内资源接入概率为 $P_{\text{access}} = 1 - \frac{\text{RSSI}}{\text{RSSI}_{\text{th}}}$, 且 $\sum_1^{N_{\text{slot}}} P_{\text{access}} = 1$, 其中, RSSI_{th} 为候选资源库选择门限值。设某一时刻内同时有 N_i 个V2V通信竞争接入概率为 $P(N_i, N_p) = C_{N_p}^{N_i} (1 - P_{\text{access}})^{(N_p - N_i)} \cdot P_{\text{access}}^{N_i}$, 则当前V2V通信在资源选择窗内竞争接入碰撞概率 $P_{\text{col}}^{\text{v2v}}$ 如式(10)所示。




图5 V2V通信DTMC分析模型

$$\begin{aligned}
P_{\text{col}}^{\text{v2v}} &= [P(N_i, N_p)]^{N_{\text{slot}}} \\
&= [C_{N_p}^{N_i}]^{N_{\text{slot}}} \cdot \left[\frac{\overline{\text{RSSI}}}{\text{RSSI}_{\text{th}}} \right]^{N_{\text{slot}}(N_p - N_i)} \\
&\quad \cdot \left[1 - \frac{\overline{\text{RSSI}}}{\text{RSSI}_{\text{th}}} \right]^{N_{\text{slot}} \cdot N_i} \quad (10)
\end{aligned}$$

当ECM选择匹配车辆运动状态时隙资源时, $\overline{\text{RSSI}}$ 取值小, $P_{\text{col}}^{\text{v2v}}$ 简化如式(11)所示。

$$\begin{aligned}
P_{\text{col}}^{\text{v2v}} &= [C_{N_p}^{N_i}]^{N_{\text{slot}}} \cdot P_{\text{access}}^{N_{\text{slot}} \cdot N_i} \\
&= [C_{N_p}^{N_i}]^{N_{\text{slot}}} \cdot \left[1 - \frac{\overline{\text{RSSI}}}{\text{RSSI}_{\text{th}}} \right]^{N_{\text{slot}} \cdot N_i} \quad (11)
\end{aligned}$$

由此可见, $P_{\text{col}}^{\text{v2v}}$ 是时隙能量特征参数的函数, 并因不同V2V通信具有差异化时隙 $\overline{\text{RSSI}}$ 而减小, 但会随V2V通信密度的增大而增大。

4.2 频域特征参数对链路失效影响分析

动态的交通状态随机影响V2V链路中通信信号的路径损耗和干扰值, 导致暂时性链路失效, 降低了消息分组的端到端正确接收率。当路径损耗使 V_r 信号接收功率 P_r 低于MCS信号感知门限值 P_{thr} 时, 无法正确解码消息信号。当累积干扰使 V_r 信号接收SINR低于解调最小SINR阈值时, 会增大信号误码率。在图1所示密集交通场景中, 设 V_s 发射功率为 P_s , 链路路径损耗 $\text{PL}(d_{s,r})$ 为通信间距 $d_{s,r}$ 的对数函数, 市区障碍物阴影效应衰落SH为零均值、方差 σ 的对数正态随机分布函数, 故 V_r 接收功率简化为 $P_r(d_{s,r}) = P_s - \text{PL}(d_{s,r}) - \text{SH}$, 则 $P_r(d_{s,r})$ 概率密度函数 $f_{P_r, d_{s,r}}(p)$ 如式(12)所示

$$f_{P_r, d_{s,r}}(p) = \frac{1}{\sigma\sqrt{2\pi}} \exp\left(-\left(\frac{P_s - \text{PL}(d_{s,r}) - p}{\sigma\sqrt{2}}\right)^2\right) \quad (12)$$

因此, 路径损耗使接收功率 P_r 低于感知门限值 P_{thr} 的概率, 即消息分组感知错误率如式(13)所示

$$\begin{aligned}
\delta_{\text{thr}}(d_{s,r}) &= \int_{-\infty}^{P_{\text{thr}}} f_{P_r, d_{s,r}}(p) dp \\
&= \frac{1}{2} \left(1 - \text{erf}\left(\frac{P_s - \text{PL}(d_{s,r}) - P_{\text{thr}}}{\sigma\sqrt{2}}\right) \right) \quad (13)
\end{aligned}$$

当 V_r 接收功率 $P_r(d_{s,r})$ 高于感知门限值 P_{thr} , 但链路累积干扰值使接收信号SINR低于解调阈值的错误率如式(14)所示

$$\delta_{\text{err}}(d_{s,r}) = \sum_{\text{SINR}=-\infty}^{\infty} \text{BL}(\text{SINR}) \cdot f_{\text{SINR}|P_r > P_{\text{thr}}, d_{s,r}}(\text{SINR}) \quad (14)$$

其中,

$$f_{\text{SINR}|P_r > P_{\text{thr}}, d_{s,r}}(\text{SINR}) = \begin{cases} \frac{f_{\text{SINR}, d_{s,r}}(\text{SINR})}{1 - \delta_{\text{thr}}(d_{s,r})} & P_r > P_{\text{thr}} \\ 0 & P_r \leq P_{\text{thr}} \end{cases}$$

V2V通信资源块错误率(BLOCK Error Rate, BLER), 即误块率, BL(SINR)受SINR值、MCS、信道模型和资源分配方式的综合影响, 但随SINR增大而减小, 文献[18]建立了SINR-BLER对应表用于查询不同配置状态下分组传输BLER值。因此, 在频域特征参数导致的V2V通信链路失效下, 消息分组接收率(Packet Reception Ratio, PRR)如式(15)所示

$$\text{PRR} = \prod_{s,r \in U} [1 - \delta_{\text{thr}}(d_{s,r})] \cdot [1 - \delta_{\text{err}}(d_{s,r})] \quad (15)$$

由式(15)可见, ECM算法通过学习不同频域能量特征下获得的累积奖励值, 建立优化的DNN权值系数矩阵, 用于选择资源, 以在链路传播损耗小、接收信号SINR值大的VUE之间建立V2V通信链路, 提高了消息分组传输性能。

4.3 算法复杂度分析

ECM算法分为预计算和资源选择两个过程, 预计算过程应用图3所示DRL模型训练图4所示DNN网络的权值向量取值, 时间复杂度集中于训练过程。如图4, 两层神经网络DNN输入状态参数集 $S = \{\overline{\text{RSSI}}, \overline{\text{SINR}}\}$ 维度为2, 迭代层数为2, 子帧迭代层输出参数维度为 F , 子信道迭代层输出参数维度为 C , 最终输出层动作空间 \mathbf{A} 的维度为 F , 则输入层的复杂度为 $O(2 \cdot F)$, 迭代层复杂度为 $O(2 \cdot F \cdot C)$, 输出层动作空间复杂度为 $O(C \cdot F)$, 因此, 一次训练总时间复杂度为 $O(\text{DNN}) = O(2 \cdot F) + O(2 \cdot F \cdot C) + O(C \cdot F)$ 。

在V2V通信实时资源选择过程中, 资源块状态参数集 $S = \{\overline{\text{RSSI}}, \overline{\text{SINR}}\}$ 输入智能体中主DQN网络, 应用训练后赋值的权值向量计算动作空间 \mathbf{A} 的Q函数值, 其空间复杂度为 F 行1列向量。智能体选择具有最大Q值的资源块集作为输出动作, 空间复杂度取决于时隙数。

5 仿真结果与分析

设在2 km双向6车道十字路口应用场景中车辆随机分布, 如图1所示, 平均车速为60 km/h, 车辆密度由VUE通信范围内车辆总数决定, 邻居车辆间随机生成不同V2V通信对, 仿真主要参数设置如表1所示。仿真首先在WiLabV2Xsim平台的Urban3GPP环境下, 基于Release 17的SB-SPS机

制生成训练样本构成样本池 E , 经验池容量 $E=10000$ 。随后, 样本池中样本按FIFO方法逐步被仿真值替换。在DQN初始化训练时, 设置 ϵ -greedy策略初始化 $\epsilon=1$, 并以0.995的比例下降, 直到 ϵ 小于0.01。

仿真首先分析了不同车辆密度对提出ECM算法的分组接收率和分组传输时延(Transmission Delay, TD)的影响, 如图6和图7所示。随后, 在V2V通信范围为200 m状态下, 仿真对比了不同学习率 α 和折扣因子 γ 对PRR和TD的影响, 如图8和图9所示。同时, 比较了不同车辆密度下ECM算法、SB-SPS机制RSS算法、DRL-BH算法的PRR和

TD和资源利用率(Resource Utilization, RU)性能指标, 如图10、图11和图12所示。

当V2V通信连接间距分别为100 m, 150 m和200 m时, 如图6, 随着V2V连接间距增大, PRR减小, 消息PRR取决于通信信号的时频能量特征参数。V2V连接间距越小, 车间直连信道衰落越小, 信号解码性能越好。同时, 近场直连通信能够选择更小RSSI值的时隙资源, 减小了蜂窝用户占用该资源的概率, 降低了V2V通信中断概率, 提高了分组正确接收率。当V2V间距一定时, 车辆密度

表 1 仿真参数

参数	参数值
信道带宽(MHz)	10
消息分组大小(Byte)	300
资源预留间隔(s)	0.1
资源保留概率	0.4
子载波间隔(kHz)	15
MCS	11
信道传播模型	WINNER+B1
学习率 α	0.01
折扣因子 γ	0.9
小批量经验样本数目	64




图 6 ECM算法PRR与车辆密度关系曲线

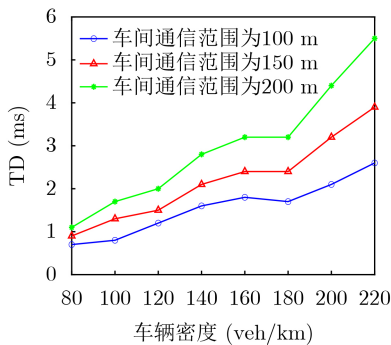


图 7 ECM算法TD与车辆密度关系曲线




图 8 学习率和折扣因子对PRR影响曲线




图 9 学习率和折扣因子对TD影响曲线




图 10 不同算法的PRR与车辆密度关系曲线

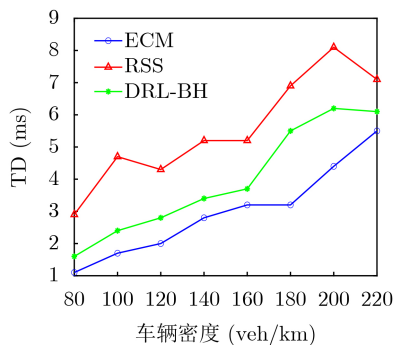


图 11 不同算法的TD与车辆密度关系曲线

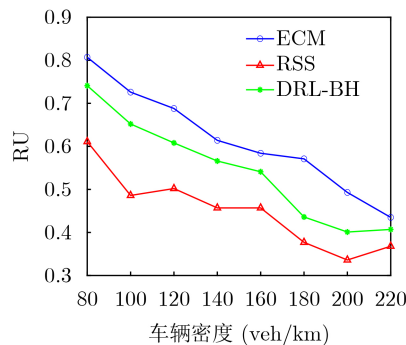


图 12 不同算法的RU与车辆密度关系曲线

越大, PRR降低越明显, 此时, V2V通信连接对增多导致链路间干扰增大, 降低了直连通信信道的SINR值。特别是当车辆密度超过160 veh/km时, 大量V2V通信连接增大了竞争接入有限频谱资源的碰撞概率, 导致PRR性能指标急剧下降。图7显示随着V2V连接间距减小, 增大的PRR降低了消息分组重传次数, 整体上获得了较好的端到端时延性能。当V2V连接间距一定时, 伴随PRR的减小, V2V通信重传增大, 降低了TD性能, 特别是当车辆密度超过180 veh/km时, TD性能下降较明显, 但ECM算法优先选择信道状态好的链路建立V2V直连通信, 其端到端TD基本保持在5 ms以下, 能满足编队行驶应用的时延性能要求。

在不同学习和折扣因子取值下, ECM算法性能表现趋势上一致, 如图8和图9, 但性能指标对通信密度的变化适应性存在差异。当学习率 $\alpha = 0.01$ 、折扣因子 $\gamma = 0.9$ 时, 算法对环境状态改变的适应性较强, 当车辆密度为160 veh/km时, PRR曲线波动大, 而TD曲线多处波动性明显。

如图10, 随着车辆密度增大, 3种算法的PRR均呈下降趋势。当车辆密度小于160 veh/km时, ECM算法将SINR作为子信道的评价参数, 选择干扰值小的资源, 其PRR均大于0.95。当车辆密度超过160 veh/km时, 伴随V2V通信对的增多带来明显增大的干扰信号强度, 其中, RSS算法的PRR性能急剧恶化, 甚至达不到辅助驾驶应用需要的0.9要求。DRL-BH算法仅通过SINR指标选择资源块, 干扰信号的增大导致PRR性能明显下降。ECM算法通过联合学习时隙RSSI信号强度和子信道SINR值, 实现V2V通信对的邻近距离相关性和不同V2V通信链路分布的空间稀疏化, 使PRR保持在0.9以上。图11显示ECM算法的良好PRR性能降低了消息分组重传率, 使端到端TD基本在5 ms超低时延内, 特别是车辆密度在160~180 veh/km区间内, ECM算法仍然具有较小的TD值。但是, 当车辆密度超过180 veh/km时, V2V通信对的数量相

对于有限可用频谱资源呈重载状态, DQN模型无法为所有V2V通信对搜索到匹配运动状态的最优通信资源, 迫使部分V2V通信使用处于深衰落或/和重干扰状态的资源块建立通信连接, 降低了分组的成功解码率, 增大了分组重传次数, 使得TD显著增大。

图12显示, ECM算法应用训练后的DQN模型综合评价子帧和子信道内的能量特征参数选择具有最佳质量状态的资源块建立V2V通信连接, 提高了消息分组的传输成功率, 资源效率高于60%。当车辆密度超过180 veh/km时, 有效可用资源减少, ECM算法难以找到高质量状态的资源建立V2V通信连接, 增大了V2V通信中断概率和重传次数, 降低了资源利用率。

6 结论

蜂窝车联网扩展了网联车对交通路网状态的感知, 高密度交通状态是路网波动性的常态, 是自动驾驶等车联网应用必然面临的日常交通现状, 提升密集交通状态中交通消息的传播性能有助于提高道路通行效率和交通安全。针对高密度交通状态下资源竞争接入和链路动态性问题, 应用DRL算法通过与环境交互学习的方式训练适配时频资源块能量分布图谱的DNN网络, 用于选择相对于车辆运动状态最优的资源块建立V2V通信链路。在车速60 km/h, 车辆密度不大于160 veh/km(即车间间距不小于13m)场景下, 提出算法的消息分组接收率和时延性能达到智能驾驶所需要的高可靠低时延要求。同时, 通过最大化使用高质量可用通信资源, 消息分组成功传输率高, 资源效率高于60%, 保障V2V通信的服务质量和有效性。

参考文献

- [1] GU Bo, CHEN Weixiang, ALAZAB M, *et al.* Multiagent reinforcement learning-based semi-persistent scheduling scheme in C-V2X mode 4[J]. *IEEE Transactions on Vehicular Technology*, 2022, 71(11): 12044–12056. doi: 10.

- 1109/TVT.2022.3189019.
- [2] SEIFHASHEMI F, HAJRASOULIHA A, and GHAFHAROKHI B S. Resource-aware multi-hop routing protocol for unicast cellular V2V communications[J]. *IEEE Access*, 2025, 13: 6584–6593. doi: [10.1109/ACCESS.2025.3526697](https://doi.org/10.1109/ACCESS.2025.3526697).
- [3] GARCIA M H C, MOLINA-GALAN A, BOBAN M, *et al.* A tutorial on 5G NR V2X communications[J]. *IEEE Communications Surveys & Tutorials*, 2021, 23(3): 1972–2026. doi: [10.1109/COMST.2021.3057017](https://doi.org/10.1109/COMST.2021.3057017).
- [4] 王巨震, 江昊, 陈琪美, 等. C-V2X资源分配方法研究综述[J]. 太赫兹科学与电子信息学报, 2022, 20(1): 1–7. doi: [10.11805/kyda2021145](https://doi.org/10.11805/kyda2021145).
WANG Juzhen, JIANG Hao, CHEN Qimei, *et al.* Summary of research on C-V2X resource allocation method[J]. *Journal of Terahertz Science and Electronic Information Technology*, 2022, 20(1): 1–7. doi: [10.11805/kyda2021145](https://doi.org/10.11805/kyda2021145).
- [5] JEON Y and KIM H. An explicit reservation-augmented resource allocation scheme for C-V2X sidelink mode 4[J]. *IEEE Access*, 2020, 8: 147241–147255. doi: [10.1109/ACCESS.2020.3015549](https://doi.org/10.1109/ACCESS.2020.3015549).
- [6] 李一兵, 王宁馨, 吕威. 蜂窝车联网中基于服务异构性的V2V通信资源分配算法研究[J]. 电子与信息学报, 2023, 45(1): 235–242. doi: [10.11999/JEIT211160](https://doi.org/10.11999/JEIT211160).
LI Yibing, WANG Ningxin, and LÜ Wei. Research on resource allocation algorithm based on service heterogeneity in V2V communication in C-V2X[J]. *Journal of Electronics & Information Technology*, 2023, 45(1): 235–242. doi: [10.11999/JEIT211160](https://doi.org/10.11999/JEIT211160).
- [7] BANITALEBI N, AZMI P, MOKARI N, *et al.* Distributed learning-based resource allocation for self-organizing C-V2X communication in cellular networks[J]. *IEEE Open Journal of the Communications Society*, 2022, 3: 1719–1736. doi: [10.1109/OJCOMS.2022.3211340](https://doi.org/10.1109/OJCOMS.2022.3211340).
- [8] PARVINI M, SCHULZ P, and FETTWEIS G. Resource allocation in V2X networks: From classical optimization to machine learning-based solutions[J]. *IEEE Open Journal of the Communications Society*, 2024, 5: 1958–1974. doi: [10.1109/OJCOMS.2024.3380509](https://doi.org/10.1109/OJCOMS.2024.3380509).
- [9] 陈发堂, 张若凡. 可重构智能反射面辅助的车联网资源分配算法研究[J]. 通信学报, 2023, 44(9): 70–78. doi: [10.11959/j.issn.1000-436x.2023145](https://doi.org/10.11959/j.issn.1000-436x.2023145).
CHEN Fatang and ZHANG Ruofan. Research on IoV resource allocation algorithm assisted by reconfigurable intelligent surface[J]. *Journal on Communications*, 2023, 44(9): 70–78. doi: [10.11959/j.issn.1000-436x.2023145](https://doi.org/10.11959/j.issn.1000-436x.2023145).
- [10] 许耀华, 王慧平, 王贵竹, 等. 基于图着色和三维匹配的车联网资源分配算法[J]. 系统工程与电子技术, 2023, 45(3): 869–875. doi: [10.12305/j.issn.1001-506X.2023.03.29](https://doi.org/10.12305/j.issn.1001-506X.2023.03.29).
XU Yaohua, WANG Huiping, WANG Guizhu, *et al.* Resource allocation algorithm for internet of vehicles based on graph coloring and three-dimensional matching[J]. *Systems Engineering and Electronics*, 2023, 45(3): 869–875. doi: [10.12305/j.issn.1001-506X.2023.03.29](https://doi.org/10.12305/j.issn.1001-506X.2023.03.29).
- [11] JI Baofeng, DONG Bingyi, LI Da, *et al.* Optimization of resource allocation for V2X security communication based on multi-agent reinforcement learning[J]. *IEEE Transactions on Vehicular Technology*, 2025, 74(2): 1849–1861. doi: [10.1109/TVT.2023.3340424](https://doi.org/10.1109/TVT.2023.3340424).
- [12] JI Maoxin, WU Qiong, FAN Pingyi, *et al.* Graph neural networks and deep reinforcement learning-based resource allocation for V2X communications[J]. *IEEE Internet of Things Journal*, 2025, 12(4): 3613–3628. doi: [10.1109/JIOT.2024.3469547](https://doi.org/10.1109/JIOT.2024.3469547).
- [13] YACHEUR B Y, AHMED T, and MOSBAH M. Efficient DRL-based selection strategy in hybrid vehicular networks[J]. *IEEE Transactions on Network and Service Management*, 2023, 20(3): 2400–2411. doi: [10.1109/TNSM.2023.3300653](https://doi.org/10.1109/TNSM.2023.3300653).
- [14] ZHANG Minglong, DOU Yi, MAROJEVIC V, *et al.* FAQ: A fuzzy-logic-assisted Q-learning model for resource allocation in 6G V2X[J]. *IEEE Internet of Things Journal*, 2024, 11(2): 2472–2489. doi: [10.1109/JIOT.2023.3294279](https://doi.org/10.1109/JIOT.2023.3294279).
- [15] LI Pengfei and HUANG Xinlin. Cooperative spectrum sensing approach in C-V2X based on multi-agent reinforcement learning[C]. Proceedings of 2023 17th International Conference on Telecommunications, Graz, Austria, 2023: 1–6. doi: [10.1109/ConTEL58387.2023.10199063](https://doi.org/10.1109/ConTEL58387.2023.10199063).
- [16] WANG Junhan, HE He, CHA J, *et al.* Multi-agent reinforcement learning for efficient resource allocation in Internet of Vehicles[J]. *Electronics*, 2025, 14(1): 192. doi: [10.3390/electronics14010192](https://doi.org/10.3390/electronics14010192).
- [17] WIJESIRI G P N B A, HAAPOLA J, and SAMARASINGHE T. A discrete-time Markov chain based comparison of the MAC layer performance of C-V2X Mode 4 and IEEE 802.11p[J]. *IEEE Transactions of Communications*, 2021, 69(4): 2505–2517. doi: [10.1109/TCOMM.2020.3044340](https://doi.org/10.1109/TCOMM.2020.3044340).
- [18] LAGEN S, WANUGA K, ELKOTBY H, *et al.* New radio physical layer abstraction for system-level simulations of 5G networks[C]. Proceedings of the ICC 2020-2020 IEEE International Conference on Communications, Dublin, Ireland, 2020: 1–7. doi: [10.1109/ICC40277.2020.9149444](https://doi.org/10.1109/ICC40277.2020.9149444).

邱恭安: 男, 教授, 研究方向为智能通信理论、广域车联网通信技术。
刘永生: 男, 硕士生, 研究方向为人工智能技术。
章国安: 男, 教授, 研究方向为数字孪生和车联网通信理论。
刘敏: 男, 副教授, 研究方向为无线智能通信理论与技术。

责任编辑: 陈倩

Energy Characteristic Map Based Resource Allocation Algorithm for High-density V2V Communications

QIU Gongan^① LIU Yongsheng^② ZHANG Guoan^① LIU Min^①

^①(School of Information Science and Technology, Nantong University, Nantong 226019, China)

^②(School of Artificial Intelligence and Computer Science, Nantong University, Nantong 226019, China)

Abstract:

Objective In high density scenarios, the random resource selection method has limitations in handling the high access collision probability of traffic safety messages under the limited frequency resource. At the same time, the variable topology accompanied by high mobility increases the failure rate of Vehicle to Vehicle (V2V) links. However, the traffic safety messages with ultra-high reliability and ultra-low latency are very important to ensure traffic safety and road efficiency under the present scenarios. To address these challenges, integrating the energy characteristic parameters in sub-frames and sub-carriers into the resource block map has emerged as a promising approach. By incorporating the distributed V2V links and designing effective reward functions, it is possible to decrease the access collision probability and smooth the dynamics of variable topology while maintaining high resource efficiency, thereby better meeting the needs of dense traffic. This research offers an intelligent solution for resource allocation in Cellular Vehicle to Everything (C-V2X) and provides theoretical support for the coordinated access of limited frequency with diverse link quality.

Methods Based on the sustainable adjacency among the neighborhood vehicles in high-density V2V communications, Energy Characteristic Map (ECM) based resource allocation algorithm is proposed using Deep Reinforcement Learning algorithm. The guidance logic of the ECM algorithm periodically renews the energy indicators of candidate resources to train the weight coefficient matrix of two-layer Deep Neural Network (DNN) based on the characteristic results within the sensing window. The algorithm is then used as the action space in double Deep Q-learning Network (DQN) agent to maximize the V2V throughput, which has a main DQN and a target DQN. The state space in the DQN model includes the energy indicators of candidate resources such as the Received Signal Strength Indicator (RSSI) in sub-frames and Signal-to-Interference plus Noise Ratio (SINR) in sub-carriers, along with dynamic factors like the relative position and speed of other vehicles. The reward function is crucial for ensuring the resource efficiency and performance of the safety messages during the resource blocks selection. It accounts for factors such as the bandwidth and SINR of V2V links rewards to optimize decision-making. Additionally, the discount factor determines the weight of future rewards, balancing the importance of immediate versus future rewards. A lower discount factor typically emphasizes immediate rewards, leading to frequently resource block reselection, while a higher discount factor enhances the robustness of occupied resource.

Results and Discussions The ECM algorithm periodically renews the energy indicators of candidate resources based on the characteristic results within the sensing window, which then serves as the action space in the double DQN agent. By defining an appropriate reward function, the main DQN in double DQN agent is established to select the candidate resource with high energy indicators for V2V links. The numerical results (Eq.(11) and Eq.(15)) between the packet received ratio and the energy indicators are analyzed using the discrete-time Markov chains. Simulation results show that the end-to-end disseminating performance of safety messages under variable V2V distances, simulated on WiLabV2Xsim, are represented (Fig.6, Fig.7). The reliability, PRR, is more than 0.95 under less than 160 veh/km (the blue line), while the comparative PRR is more than 0.95 under less than 120 veh/km (the green line) and 90 veh/km (the red line), respectively (Fig.10). At the same time, the latency, TD, is less than 3 ms under less than 180 veh/km (the blue line), while the comparative TD is less than 3 ms under less than 160 veh/km (the green line) and about 80 veh/km (the red line), respectively (Fig.11). The resource utilization, RU, is more than 0.6 under less than 180 veh/km (the blue line), while the comparative RU is more than 0.6 under less than 160 veh/km (the green line) and about 80

veh/km (the red line), respectively (Fig.12), demonstrating a 10~20% improvement in resource efficiency. When the discount factor is set to 0.9 while the learning rate is set to 0.01 (Fig.8, Fig.9), the VUE selects the resource blocks that balances immediate and long-term throughput, effectively improving the robustness of the main DQN, which meets the advanced V2V service requirements such as platooning in C-V2X.

Conclusions This paper addresses the challenge of resource allocation in high-density V2V communications by integrating the ECM algorithm with double DQN agent. The proposed resource selection scheme enhances the RSS algorithm by establishing distributed V2V links using high quality resource blocks to maximize throughput. The scheme is evaluated through disseminating safety messages simulations under variable density, and the results show that: (1) The proposed scheme has high reliability with more than 0.95 PRR and ultra-low latency with less than 3 ms TD under upper 160 veh/km. (2) The resource efficiency has been improved by 10~20% over the RSS method; (3) Long-term and short-term rewards are considered by selecting the discount factor of 0.9 and the learning rate of 0.01 and enhance the robustness of DQN model. However, this study has not considered different resource characteristics for the heterogeneous messages with diverse Quality of Service (QoS) providing, which should be accounted for in future work.

Key words: C-V2X; Resource allocation; Deep reinforcement learning; Energy characteristic map