

# 历史交通数据驱动的 VANET 智能路由算法<sup>\*</sup>

李 洁, 陈 青, 陈侃松

(湖北大学 计算机学院, 湖北 武汉 430062)

通信作者: 陈侃松, E-mail: [kschen1999@aliyun.com](mailto:kschen1999@aliyun.com)



**摘 要:** 随着智能出行的推广, 车载自组织网络 (vehicular ad hoc network, VANET) 在数据采集上应用得到越来越多的关注. 然而, 由于车辆的高速移动和轨迹难以预测, 传统的基于位置的贪婪转发策略难以适应于高动态 VANET 下数据传递的需求. 为解决这一问题, 提出一种历史交通数据驱动的 VANET 智能路由算法. 首先, 通过离线学习方法基于网络的历史交通流信息, 获取用于最优路径选择的转发表; 其次, 在路径上, 利用基于 Markov 预测的在线 V2V 传输机制, 通过考虑车辆的运动状态等因素选择可靠的下一中继车辆. 最后, 与 3 种路由算法进行了对比, 实验结果表明, 该算法在数据包投递率、平均端到端时延、网络收益率、平均成功发包开销和在线计算时间复杂度这 5 个性能上均表现优越.

**关键词:** 车载自组织网络; 强化学习; 马尔可夫预测; 路由空洞

**中图法分类号:** TP393

中文引用格式: 李洁, 陈青, 陈侃松. 历史交通数据驱动的 VANET 智能路由算法. 软件学报, 2025, 36(12): 5780–5800. <http://www.jos.org.cn/1000-9825/7431.htm>

英文引用格式: Li J, Chen Q, Chen KS. Intelligent Routing Algorithm Driven by Historical Traffic Data for VANET. Ruan Jian Xue Bao/Journal of Software, 2025, 36(12): 5780–5800 (in Chinese). <http://www.jos.org.cn/1000-9825/7431.htm>

## Intelligent Routing Algorithm Driven by Historical Traffic Data for VANET

LI Jie, CHEN Qing, CHEN Kan-Song

(School of Computer Science, Hubei University, Wuhan 430062, China)

**Abstract:** With the widespread promotion of smart mobility, there has been increasing attention on the application of vehicular ad hoc network (VANET) in data collection. However, due to the high-speed movement of vehicles and the unpredictability of their trajectories, traditional position-based greedy forwarding strategies struggle to meet the data transmission demands of highly dynamic VANET. To address this issue, an intelligent routing algorithm driven by historical traffic data for VANET (HTD-IR) is proposed. First, an optimal forwarding table for path selection is obtained through an offline learning method based on historical traffic flow information. Then, using an online V2V transmission mechanism based on Markov prediction, the next reliable vehicle is selected according to the vehicle's motion state. Finally, this study compares HTD-IR with other routing protocols in simulations. The results demonstrate that HTD-IR outperforms in terms of packet delivery ratio, average end-to-end delay, network yield, average successful packet transmission cost, and online computation time complexity.

**Key words:** vehicular ad hoc network (VANET); reinforcement learning; Markov prediction; routing hole

随着通信技术的不断发展, 车载自组织网络 (vehicular ad hoc network, VANET) 已成为智能交通系统设计中的关键组成部分. 在 VANET 中, 一方面, 由于建设成本高且难度大, 路侧单元 (road side unit, RSU) 等基础设施难以实现密集部署<sup>[1,2]</sup>; 另一方面, 已部署的固定设施容易受到人为或自然灾害的毁坏<sup>[3]</sup>. 在这种情况下, 车辆无法通过车对一切 (vehicle-to-everything, V2X) 的单跳技术将数据直接传输至 RSU. 面向智慧出行的需求, 尤其是对延迟

<sup>\*</sup> 基金项目: 国家自然科学基金 (62377009); 湖北省自然科学基金青年项目 (2023AFB313); 湖北省重点研发计划 (2022BAA045)  
收稿时间: 2024-01-03; 修改时间: 2024-03-13, 2024-08-23, 2025-02-19; 采用时间: 2025-03-19; jos 在线出版时间: 2025-07-17  
CNKI 网络首发时间: 2025-07-18

容忍型数据(如  $\text{PM}_{2.5}$ ,  $\text{CO}_2$  浓度, 天气状况等<sup>[4]</sup>)的采集要求, 车对车 (vehicle-to-vehicle, V2V) 多跳路由机制因其更高的灵活性成为学术界科研工作者的一个主要研究方向<sup>[5-9]</sup>。然而, 在 V2V 通信中, 车辆的高速移动导致节点分布不均匀且通信链路频繁中断。因此, 如何有效应对车辆的高动态性, 提供高效、可靠的通信, 始终是 VANET 路由亟待解决的关键问题<sup>[10]</sup>。

现有 VANET 路由研究主要分为基于拓扑和基于位置两种。其中, 基于拓扑的协议利用网络中各个节点之间的连接关系, 来决定如何进行数据包传输, 难以适用于动态拓扑结构的大规模网络<sup>[11-13]</sup>。随着全球定位系统 (global positioning system, GPS) 和地理信息系统 (geographic information system, GIS) 技术的不断发展, 基于地理位置的路由协议已成为解决 VANET 信息传递问题的主要技术之一。在这种协议中, 采用贪婪策略来选择转发节点是一种经典的解决方案。然而, 由于 VANET 中车辆的动态移动, 存在当前携带信息的车辆难以找到距离目的地更近的下一跳转发车辆, 从而导致路由空洞<sup>[14,15]</sup>问题的出现。针对这一问题, 虽然一些方案<sup>[16-18]</sup>通过绕过路由空洞的方法来恢复路由, 但带来了较大的时延。此外, 由于车辆的高速移动及行驶路径的不可预测, 车辆之间的通信链路很容易中断, 仅依靠车辆的位置信息来确保可靠的数据包传递是不可行的。

面向基础设施稀疏、信息无法通过 V2X 单跳传输到达可用 RSU 的通信场景约束, 针对车辆分布不均匀及轨迹难以预测等挑战, 本文提出了一种历史交通数据驱动的 VANET 智能路由算法 (intelligent routing algorithm driven by historical traffic data for VANET, HTD-IR), 将对历史交通流信息的学习运用在 VANET 路由上, 以较低的时延和开销实现较大的包投递率, 有效提高 VANET 路由效率。本文的主要贡献如下。

(1) 提出了一种基于 Q-learning 的离线学习路径选择策略, 利用 VANET 道路交通中历史交通流信息的可依赖性, 指引数据包的转发路径, 有效减少 VANET 中的路由延迟和通信成本。

(2) 设计了一种基于 Markov 预测的在线 V2V 传输机制, 通过对车辆的历史状态信息和邻居车辆信息的学习, 在转发路径上为数据包选择合适的中继车辆, 以提高数据包的投递率并减少数据包传输时延。

本文第 1 节对现有工作进行总结并分析其贡献与待改善之处。第 2 节对本文的系统模型进行介绍。第 3 节描述所提出的算法。第 4 节进行实验来评估所提出的路由方案。最后对本文研究进行总结, 并对未来工作进行展望。

## 1 相关工作

车辆的高度机动性使基于地理位置的路由协议能够更好地适应 VANET 的移动性, 因此被视为 VANET 首选的路由协议<sup>[19]</sup>。GPSR 协议是经典的地理路由协议, 由贪婪转发和周边转发两部分组成, 其中周边转发是针对“贪婪搜索”特性可能会出现局部最优导致的“路由空洞”问题的解决方法<sup>[20]</sup>。文献<sup>[16]</sup>提出了一种自适应地利用位置信息、剩余能量和能耗特征进行路由决策, 并动态地利用两个节点不连接的锚表来穿过路由空洞的两侧, 移动路由路径实现负载均衡。文献<sup>[18]</sup>提出了一种基于权重的路径感知贪婪周界无状态路由协议, 在路由建立阶段采用权值贪婪转发策略, 在路由维护阶段根据数据包的投递角度和可靠节点密度, 采用加权周界转发策略选择下一跳节点进行转发。文献<sup>[21]</sup>提出了一种处理路由空洞的新方法, 节点合作确定特定空洞的近似多边形, 根据空洞覆盖平行四边形和特定节点的孔视角, 数据包可以沿着绕过空洞的弯曲逃生路线转发。尽管这些研究解决了路由空洞问题, 但是解决方案的成本较高, 带来较大时延。

由于 VANET 道路交通具有复杂的交通状况和频繁的通信链路断开等特点, 仅依靠位置信息可能不能完全反映车辆间的通信状态。文献<sup>[22]</sup>提出了一种新的 V2V 路由协议, 结合了基于 GPSR 并进行位置预测的 GPSR+Predict 和考虑链路质量的链路状态感知地理路由协议。文献<sup>[23]</sup>提出了一种基于 LORAWAN 的地理路由协议 (LGRP), LGRP 选择最健壮的路由路径, 以实现较高的报文投递率、较小的端到端延迟和功耗。同时引入距离、延迟、丢包和相对速度作为选择网关节点的代价, 确保选择可靠和低维护的路由路径。文献<sup>[24]</sup>提出了一种基于车辆密度预测的路由协议, 首先根据车辆轨迹的时空特征引入了车辆密度预测模型, 然后提出了一种综合考虑车辆密度、链路质量和路由长度的路由路径评估方案, 以降低通信开销并提高通信效率。在文献<sup>[25]</sup>中引入了一种基于车辆节点特征和车辆节点间相关特征的连通性预测方法, 建立了基于车辆节点间连通性和车辆节点密度的动态聚类模

型,实现了车辆节点间的稳定通信.陈侃松等人在文献[26]中选择路由时利用跨层思想并结合网络节点移动速度提出链路权值计算方法,然后依据链路权值选择路由路径.尽管以上文献考虑了车辆之间通信的可靠性,但并未考虑到由于车辆节点分布不均匀可能引起的路由空洞问题.

近年来,在VANET路由领域引入了强化学习方法(reinforcement learning, RL),旨在更好地适应动态环境的变化[27].Casas-Velasco等人[28]提出了基于软件定义网络中的RL路由解决方案,该方案考虑了路径状态度量,以产生适应动态流量变化的主动、高效和智能路由.刘静茹等人[29]提出一种基于RL的地理位置路由协议,在选定的下一跳网格中,选择距离目的地最近的车辆,当最优下一跳网格中没有邻居车辆时,选择次优下一跳网格中的车辆,从而提高分组投递率,降低传输时延并减少通信跳数.文献[30]提出了一种基于RL的分层协议(QGrid),该协议以尽可能少的延迟和跳数来提高消息传递率.文献[31]提出了一种基于协作学习的多接入车辆边缘计算环境路由方案,该方案采用基于端到边缘云协作的强化学习算法,以低通信开销的方式主动寻找路由.文献[32]在VANET中提出了一种基于交叉口的路由协议,通过强化学习和实时监控网络状态的一种改进的贪心策略来选择路径上的最优中继,从而提高报文的传输率并降低端到端时延.尽管这些研究从动态变化的环境中学习路由策略,但不仅没有考虑到车辆间通信链路的动态性,还没有考虑到可能存在路由空洞的问题.文献[33]在VANET中提出了一种多跳通信的激励方案.该方案基于模糊逻辑方法对复杂的动态环境进行估计,然后基于全分布式的强化学习方法,从长远的角度进一步刺激中间节点,使期望效用最大化.文献[34]提出了一种环境感知自适应增强路由协议,将RL应用于VANET的路径选择,该协议通过感知车速、可用带宽、信号接收强度等因素,自适应调整Q表,从而完成中继车辆的选择,这一方法有助于解决链路突然中断的问题,提高通信的可靠性.虽然二者考虑了车辆间通信链路的动态性,但仍没有考虑路由空洞的问题.然而,文献[35]提出了一种基于强化学习的机会路由协议,以降低能耗并提高传输可靠性,同时也解决了水声传感器网络中路由空洞的问题.文献[36]提出了一种基于强化学习的机会路由协议,将RL与机会路由相结合以确保数据传输的实时性和能源效率,为了在遇到空洞时实现可靠传输设计了空洞恢复机制,使得报文能够绕过空洞节点继续转发.尽管这些研究考虑到路由空洞,两节点之间通信的可靠性,并且能够从环境中学习找到最优路由路径,但并不适用于车载自组织网络.

综上所述,尽管当前有许多研究专注于解决VANET路由问题,但适用于这一应用场景的路由算法仍然需要进一步的探索.在复杂、动态和不确定的交通环境下,如何实现源到目的地的数据传输,以达到较低的时延和较高的包投递率,依然是一个亟需解决的问题.因此,本文提出了HTD-IR算法,该算法从道路和车辆两个方面进行综合考虑.在道路层面,涉及路由路径的选择;而在车辆层面,通过选择合适的中继车辆在选定的路径上进行数据包传输.这种综合性的方法提高了VANET路由的包投递率,同时减少了时延.

## 2 系统模型

面向基础设施稀疏、采集到的数据无法通过V2X单跳到达可用RSU的场景[37],VANET中采集到数据的车辆可以通过V2V多跳路由机制将数据传递至可用RSU,再由RSU将数据传至服务器.如后文图1所示,生成数据的车辆( $S$ ,即源节点)首先搜索离它最近的可用RSU( $D$ ,即目的节点),若 $D$ 位于 $S$ 的通信范围内, $S$ 可直接将数据传输给 $D$ ;否则,需借助邻居车辆通过多跳路由的方式将数据传输至 $D$ . $D$ 一旦接收到该数据,便可通过有线传输将数据传至服务器.因此,如何在 $S$ 和 $D$ 之间找寻一条延迟小且数据包投递率高的V2V多跳传输路径成为提高数据采集效率的关键.

### 2.1 网络模型

这里,本文把VANET环境建模为图 $E(V, G)$ ,其中, $V = \{v_i | i = 1, 2, \dots, n\}$ 表示VANET中车辆节点集合, $v_i$ 为第 $i$ 个车辆, $G$ 表示环境地图.考虑到将车辆刻画为强化学习的状态时,状态空间会过于庞大,本文将地图划分为大小相等的网格,并将其作为强化学习的状态[29].这样可以减小状态空间,降低 $Q$ -table的规模,从而节省大量的系统资源和时间.如图2所示,将整个地图用 $G = \{G_g | g = 1, 2, \dots, N\}$ 表示,其中 $G_g = \langle id, x, y, VG \rangle$ , $id$ 为网格 $G_g$ 的标识符, $x$ 和 $y$ 分别为网格 $G_g$ 的横坐标和纵坐标, $VG = \{VG_g^t | t = 1, 2, \dots, T\}$ , $VG_g^t$ 为 $t$ 时刻网格 $G_g$ 内车辆的集合.




图1 VANET 通信场景




图2 VANET 网络图

## 2.2 节点模型

### (1) 车辆节点模型

网络区域内分布着许多车辆节点, 车辆本身配备有 GPS 系统和数字地图, 使它们能够实时获取自己和路侧单元的地理位置. 在网络中, 车辆需要定期交换状态信息, 包括  $id$ 、位置 (横坐标, 纵坐标)、速度、行驶方向角、邻居车辆数量和位置转移概率向量信息  $P_{neigh}$ , 用符号  $v_i = \langle id, x_i, y_i, u_i, \theta_i, VR', P_{neigh} \rangle$  表示. 其中,  $x_i$  和  $y_i$  为  $t$  时刻车辆的位置, 其更新方式如下:

$$x_t = x_{t-1} + u_t \times \cos \theta_t \quad (1)$$

$$y_t = y_{t-1} + u_t \times \sin \theta_t \quad (2)$$

其中,  $x_{t-1}$  表示车辆在  $t-1$  时刻的横坐标,  $y_{t-1}$  表示车辆在  $t-1$  时刻的纵坐标,  $u_t$  表示车辆在  $t$  时刻的行驶速度,  $\theta_t$  表示车辆在  $t$  时刻的行驶方向角.

$VR'$  为当前车辆的邻居表信息, 维护着  $t$  时刻车辆传输半径内所有邻居车辆信息;  $P_{neigh}$  表示下一时刻车辆转移到其他位置的概率向量.

### (2) 路侧单元和服务端

RSU 负责收集 VANET 中车辆传输的信息, 并将其上传到服务器 Agent, 实现车辆与 RSU、RSU 与 Agent 之间的信息交流.

Agent 是拥有历史流量信息的服务器, 其特点是具有丰富的计算能力和数据存储能力. 因此可充当强化学习的学习者和决策者, 通过不断探索 VANET 环境来学习数据包转发的路由路径规划策略, 最终将学习的策略共享给 VANET 中的 RSU, RSU 再将策略传递给车辆, 车辆之间可通过定期与邻居车辆共享策略, 实现所有的车辆都拥有此策略, 并能根据该策略进行数据包传输路径的选择.

## 3 HTD-IR 算法

为了提高 VANET 数据包的投递率并减少传输时延, 本文提出了 HTD-IR 算法. 首先, 针对 VANET 场景中车辆分布不均匀的情况在第 3.1 节设计了一种基于 Q-learning 的离线学习路径选择策略, 为数据包提供最优的转发路径; 其次, 考虑到路径上车辆之间通信链路的动态性及车辆轨迹的难以预测性, 在第 3.2 节提出了一种基于 Markov 预测的在线 V2V 传输机制, 为当前车辆找寻下一相对可靠的中继车辆.

### 3.1 基于 Q-learning 的离线学习路径选择策略

在 VANET 道路交通场景中, 尽管车辆个体轨迹充满不确定性, 但整个 VANET 道路交通流的历史数据表现出相对稳定的模式, 每一路段在什么时候交通密度大, 什么时候交通密度小, 一定程度上是可基于历史信息预测的. 基于此, 面向 VANET 高动态环境下的数据包转发问题, 我们从 VANET 道路交通特点入手, 设计了一种基于 Q-learning 的离线学习路径选择策略. 对 VANET 交通网的历史信息进行训练, 以生成用于路径选择的转发表, 引导数据包在 VANET 中选择最佳路径, 以确保数据包经由交通密度较高且延迟较低的路径到达目的地.

在这里, 将每个网格映射为环境状态, 对于网格, 我们用  $G_t^i$  来表示时刻  $t$  的状态; 动作空间  $A$  包括相邻网格之间移动的 8 个方向, 即  $A = \{\text{北, 南, 东, 西, 东北, 东南, 西北, 西南}\}$ . Agent 通过不断地学习来获取知识, 得到环境给予的反馈并改进决策, 以适应不断变化的动态环境. 如图 3 所示, 在  $t-1$  时刻 Agent 采取动作以后, 环境向 Agent 反馈状态  $G_t^i$  和奖励  $R^t$ , 因此  $t$  时刻 Agent 所处的状态为  $G_t^i$ , 接着 Agent 根据策略选择动作  $A_t$ , 环境将状态  $G_{j+1}^{t+1}$  和奖励  $R^{t+1}$  返回给 Agent, Agent 所处的状态由  $G_t^i$  变成  $G_{j+1}^{t+1}$ .  $R^{t+1}$  是 Agent 在执行动作  $A_t$  后从当前网格  $G_t^i$  过渡到下一网格  $G_{j+1}^{t+1}$  所获得的奖励, 如公式 (3) 所示, 如果数据包被成功转发到目的网格  $D$ , 则奖励为  $\varphi$ , 否则, 奖励为 0.

$$R_{G_t^i \rightarrow G_{j+1}^{t+1}}^{t+1} = \begin{cases} \varphi, & \text{if reach } D_y \\ 0, & \text{others} \end{cases} \quad (3)$$




图 3 强化学习原理图

在数据采集的过程中每个数据信息的源头不同, 其相应的目的地也不尽相同. 我们设源车辆所处网格作为当前网格, 目的地 RSU 所处网格作为目标网格, 将问题转化为在当前网格和目标网格之间寻求一条最优的网格路径. 因此, 我们将原来基于特定目标的二维  $Q$ -table 改为基于任意目标的三维  $Q$ -table.  $Q$ -table 内存储的  $Q$  值为  $Q(G_x^t, D_y, a_z^t)$ , 其表示目标网格为  $D_y$  的情况下,  $t$  时刻在当前网格  $G_x^t$  处采取动作  $a_z^t$  所期望得到的奖励; Agent 每执行一步策略就更新一次  $Q(G_x^t, D_y, a_z^t)$  值, 改进后的  $Q(G_x^t, D_y, a_z^t)$  值更新方法如下所示:

$$Q(G_x^t, D_y, a_z^t) \leftarrow (1 - \alpha) \times Q(G_x^t, D_y, a_z^t) + \alpha \times \{R(G_x^t, D_y, a_z^t) + \max_{a^{t+1}} Q(G_{j+1}^{t+1}, D_y, a^{t+1}) \times \gamma_t\} \quad (4)$$

其中,  $R(G_x^t, D_y, a_z^t)$  表示在当前网格  $G_x^t$  处采取动作  $a_z^t$  所获得的奖励;  $Q(G_{j+1}^{t+1}, D_y, a^{t+1})$  表示  $t+1$  时刻在状态  $G_{j+1}^{t+1}$  处采取动作  $a^{t+1}$  所期望得到的奖励;  $\alpha$  是学习率, 它决定了新信息覆盖旧信息的程度; 折扣因子  $\gamma_t$  用于确定未来奖励的规模.

考虑到路径长度及其车辆密度对 VANET 数据包转发效率的影响, 我们将折扣因子  $\gamma_t$  设计成与车辆密度和网格之间距离相关的动态参数:

$$\gamma_t = \delta \times \rho_t(G_t^i \rightarrow G_{j+1}^{t+1}) + (1 - \delta) \times d_t(G_t^i \rightarrow G_{j+1}^{t+1}) \quad (5)$$

$$\rho_t(G_t^i \rightarrow G_{j+1}^{t+1}) = 1 - \frac{s_{\max} - |VG_{j+1}^{t+1}|}{s_{\max} - s_{\min}} \quad (6)$$

$$d_t(G_t^i \rightarrow G_{j+1}^{t+1}) = \max \left( 0, 1 - \frac{dist_{G_{j+1}^{t+1} \rightarrow D_y}^{t+1}}{dist_{G_t^i \rightarrow D_y}^t} \right) \quad (7)$$

$$dist_{G_t^i \rightarrow D_y}^t = \sqrt{(x(i) - x(D_y))^2 + (y(i) - y(D_y))^2} \quad (8)$$

其中,  $\rho_t(G_t^i \rightarrow G_{j+1}^{t+1})$  用来衡量网格的密度;  $d_t(G_t^i \rightarrow G_{j+1}^{t+1})$  则用来表示距离变化;  $s_{\max} = \max(|VG_i^t|), i \in \{1, \dots, N\}$  为  $t$  时刻所有网格中最大车辆数,  $N$  为划分的网格总数;  $s_{\min} = \min(|VG_i^t|), i \in \{1, \dots, N\}$  为  $t$  时刻网格中最小车辆数;  $dist_{G_t^i \rightarrow D_y}^t$  为当前所在网格  $G_t^i$  与目标网格  $D_y$  的距离;  $dist_{G_{j+1}^{t+1} \rightarrow D_y}^{t+1}$  是下一网格  $G_{j+1}^{t+1}$  与  $D_y$  之间的距离;  $x(i)$  表示网格  $i$  的横坐标,  $y(i)$  表示网格  $i$  的纵坐标;  $\delta$  为权重因子,  $0 < \delta < 1$ . 如果下一网格比当前网格到目标网格的距离更近, 则  $d_t(G_t^i \rightarrow G_{j+1}^{t+1})$  更接近 1. 从公式 (6) 可看出, 当下一网格  $G_{j+1}^{t+1}$  的车辆密度更接近最大车辆密度, 且更接近目标网格时, 折现因子  $\gamma_t$  越大.

基于 Q-learning 的离线学习路径选择策略的具体过程如算法 1 所示. 其中, 步骤 3 对于可到达目标网格的网格将相应的奖励设置为  $\varphi$ ; 步骤 4-14 对  $Q$ -table 进行迭代更新, 其中步骤 7-11 以  $\varepsilon$  的概率选择一个随机动作, 以

$1-\varepsilon$  的概率选择当前具有最大  $Q$  值的动作, 步骤 12, 13 根据公式 (5) 计算折扣因子  $\gamma_t$  并更新相应的  $Q$  值; 重复步骤 4–14, 直至  $Q$ -table 收敛或达到预定迭代次数; 步骤 15 将此目标网络的奖励还原为 0, 进行下一目标网络的处理.

---

**算法 1.** 改进的 Q-learning 算法.

---

输入:  $G, A, R, \varepsilon, \alpha, \delta$ ;

输出: 三维  $Q$ -table.

---

1. 初始化  $Q$  矩阵和  $R$  矩阵为零矩阵;
  2. **for all**  $D_y \in G$  **do**
  3.    $R[D_y] = \varphi$ ;
  4.   **for**  $episode = 1$  to  $M$  **do**
  5.     选择一个网格作为初始网格;
  6.     生成一个随机数  $r \in (0, 1)$ ;
  7.     **if**  $r \leq \varepsilon$  **then**
  8.       随机选择一个网格;
  9.     **else**
  10.      选择具有最大  $Q$ -value 的网格;
  11.     **end if**
  12.     根据公式 (5) 计算  $\gamma_t$ ;
  13.     根据公式 (4) 来更新  $Q$ -value;
  14.   **end for**
  15.    $R[D_y] = 0$ ;
  16. **end for**
- 

为了更有效地引导数据包转发, 我们将目标网格作为索引项, 利用  $Q$ -table 生成转发表并共享给网络中所有的车辆. 转发表中记录了从当前网格到目标网格应选择的下一最优网格  $G_{\text{best}}$ , 即下一路径.

### 3.2 基于 Markov 预测的在线 V2V 传输机制

面向 VANET 的数据采集业务需求, 在基础设施稀疏且车辆高速动态的环境下, 如何实现高效、可靠的数据传输至关重要. 为了进一步提高数据转发效率, 提出了基于 Markov 预测的在线 V2V 传输机制. 该机制旨在通过算法 1 得到的转发路径上选择合适的中继车辆, 实现数据包的高效转发. 这里, 考虑到除了车辆节点的位置会影响路由性能外, 其他因素, 如节点之间链路生存性和路由空洞等, 也对路由性能起着较大的影响. 我们在选择中继车辆时综合考虑以上因素, 以确保数据的高效可靠传输. 与此同时, 考虑到在线机制的性能要求, 对算法的计算时间复杂度和空间占用情况进行了分析.

#### 3.2.1 路由性能的影响因素

##### (1) 车辆位置的影响

由于数据转发方向已定, 这里我们首先将车辆当前所处的位置和下一阶段可能出现的位置与数据包转发路径的关系作为参考, 计算车辆基于位置的代价. 对此, 本文引入了 Markov 预测方法来对车辆的位置进行预测.

首先每个车辆节点, 可利用条件概率根据其历史轨迹信息计算下一时刻移动到各个网格的概率, 生成位置转移概率矩阵  $P$ . 如公式 (10) 所示, 对于每个车辆, 我们可以通过公式 (9) 计算车辆在时刻  $t$  从当前网格  $G_i$  到下一网格  $G_j$  的位置转移概率  $P_{ij}$ , 从而得到  $P$ .

$$P(G_i' \rightarrow G_j^{t+1}) = P(G_j^{t+1} | G_i') = P(G_i' G_j^{t+1}) / P(G_i') = P_{ij} \quad (9)$$

$$P = \begin{bmatrix} P_{11} & P_{12} & \dots & P_{1N} \\ P_{21} & P_{22} & \dots & P_{2N} \\ \vdots & \vdots & \ddots & \vdots \\ P_{N1} & P_{N2} & \dots & P_{NN} \end{bmatrix} \quad (10)$$

其中,

$$\begin{cases} 0 \leq P_{ij} \leq 1, i, j = 1, 2, \dots, N \\ \sum_{j=1}^N P_{ij} = 1, i = 1, 2, \dots, N \end{cases} \quad (11)$$

然后, 引入  $t$  时刻车辆的位置转移概率向量  $\pi(t) = [\pi_1(t), \pi_2(t), \dots]$ , 其中,  $\pi_i(t), i = 1, 2, \dots, N$  表示在第  $t$  个时刻处于网格  $G_i$  的概率. 如公式 (12) 所示, 可以利用转移概率矩阵  $P$  计算得到  $t+1$  时刻车辆的位置转移概率向量:

$$\pi(t+1) = \pi(t) \cdot P \quad (12)$$

这里, 递推可得  $\pi(t+1) = \pi(0) \cdot P^{t+1}$ . 其中  $\pi(0)$  为初始时刻车辆位置概率向量, 该向量模为 1, 即只有一个元素是 1, 其余元素都是 0. 考虑到车辆在下一时刻的网格位置受限于当前所在网格位置的邻域范围, 这里我们仅需从  $\pi(t+1)$  中提取到以其当前所在网格为中心由周围相邻网格构建的九宫格的位置转移概率生成当前位置转移概率向量  $P_{\text{neigh}}$  即可.

在数据包传输的过程中, 当前携带数据包车辆  $v_B$  的邻居车辆  $v_A$  的位置存在以下两种情况: 在下一路径上 (如图 4 所示) 和不在下一路径上 (如图 5 所示), 为了确保数据包能够继续沿着既定路径传输, 设计了如公式 (13) 所示的基于位置的代价  $Place_A$  计算公式.

$$Place_A = \begin{cases} \lambda_1 \times \frac{1}{p_A} + \lambda_2 \times \frac{dist_{AD}}{dist_{BD}} + \lambda_3 \times (1 - \cos \langle \vec{v}_A, \vec{BD} \rangle), & \exists v_A \in VG'_{\text{best}} \\ \lambda_1 \times \frac{1}{p_A} + \lambda_2 \times \frac{dist_{Ag}}{dist_{Bg}} + \lambda_3 \times (1 - \cos \langle \vec{v}_A, \vec{BD} \rangle), & \forall v_A \notin VG'_{\text{best}} \text{ 且 } p_A > 0 \\ \lambda_4 \times \frac{dist_{Ag}}{dist_{Bg}} + \lambda_5 \times (1 - \cos \langle \vec{v}_A, \vec{BD} \rangle), & \forall v_A \notin VG'_{\text{best}} \text{ 且 } p_A = 0 \end{cases} \quad (13)$$

$$\vec{v}_A = (a_{v_A}, b_{v_A}) = (u_A \times \cos \theta, u_A \times \sin \theta) \quad (14)$$

$$\vec{BD} = (a_{BD}, b_{BD}) = (x_D - x_B, y_D - y_B) \quad (15)$$

$$\cos(\vec{v}_A, \vec{BD}) = \frac{a_{v_A} \times a_{BD} + b_{v_A} \times b_{BD}}{\sqrt{a_{v_A}^2 + b_{v_A}^2} \times \sqrt{a_{BD}^2 + b_{BD}^2}} \quad (16)$$

其中,  $p_A$  表示邻居车辆  $v_A$  下一时刻出现在下一路径上的转移概率;  $VG'_{\text{best}}$  表示下一路径上车辆的集合;  $dist_{AD}$  表示邻居车辆  $v_A$  与目的地  $D$  之间的距离;  $dist_{BD}$  表示当前车辆  $v_B$  与  $D$  之间的距离;  $dist_{Ag}$  表示邻居车辆  $v_A$  与下一路径  $G_g$  之间的距离;  $dist_{Bg}$  表示当前车辆  $v_B$  与  $G_g$  之间的距离.  $dist_{AD}/dist_{BD}$  值越小, 说明  $v_A$  相较于  $v_B$  距  $D$  越近;  $dist_{Ag}/dist_{Bg}$  值越小, 说明  $v_A$  相较于  $v_B$  距  $G_g$  越近.  $\theta$  为  $v_A$  行驶方向角;  $\vec{v}_A$  表示  $v_A$  的行驶方向向量;  $\vec{BD}$  表示当前车辆  $v_B$  与  $D$  所形成的向量, 将其作为数据包投递的主方向;  $\cos(\vec{v}_A, \vec{BD})$  表示  $\vec{v}_A$  与  $\vec{BD}$  所成夹角的余弦值, 余弦值越大, 说明数据包投递方向越靠近目标方向.  $\lambda_1, \lambda_2, \lambda_3$  为 3 个参考量的权重占比,  $\lambda_1, \lambda_2, \lambda_3 \in [0, 1]$  且  $\lambda_1 + \lambda_2 + \lambda_3 = 1$ ;  $\lambda_4, \lambda_5$  为 2 个参考量的权重占比,  $\lambda_4, \lambda_5 \in [0, 1]$  且  $\lambda_4 + \lambda_5 = 1$ .

对于图 4 所示的邻居车辆在下一路段的情况我们综合考虑位置转移概率  $p_A$ 、距离和行驶方向作为其位置代价. 对于图 5 所示邻居车辆不在下一路段的情况我们首先根据位置预测得到位置转移概率  $p_A$ , 若大于 0, 位置代价进一步考虑距离和行驶方向; 若为 0, 位置代价仅包括距离和行驶方向. 这个代价越小, 说明  $v_B$  通过  $v_A$  传输数据包的代价越小, 即更靠近目的地, 可以有效地减少跳数, 同时增加了邻居车辆将数据包沿着下一路段传递的可能性.

## (2) 车辆之间链路生存性的影响

如图 6 所示, 由于车辆之间通信链路的动态性, 车辆之间通信链路的维护时间同样对数据包传递的可靠性产

生影响. 因此, 我们定义车辆  $v_A$  与车辆  $v_B$  之间通信链路的维护时间  $L_{AB}^T$  计算公式如下:

$$L_{AB}^T = \begin{cases} \frac{R + |\vec{AB}| \times \cos\beta}{\text{abs}(|\vec{v}_A| - |\vec{v}_B| \times \cos(\pi - \theta'))}, & \cos\theta' < 0 \text{ 且 } \cos\beta < 0 \\ \frac{R + |\vec{AB}| \times \cos\beta}{|\vec{v}_A| + |\vec{v}_B| \times \cos(\pi - \theta')}, & \cos\theta' < 0 \text{ 且 } \cos\beta > 0 \\ \frac{R + |\vec{AB}| \times \cos(\pi - \beta)}{\text{abs}(|\vec{v}_A| - |\vec{v}_B| \times \cos\theta')}, & \cos\theta' > 0 \text{ 且 } |\vec{v}_B| \times \cos\theta' > |\vec{v}_A| \\ \frac{R + |\vec{AB}| \times \cos\beta}{\text{abs}(|\vec{v}_A| - |\vec{v}_B| \times \cos\theta')}, & \cos\theta' > 0 \text{ 且 } |\vec{v}_B| \times \cos\theta' < |\vec{v}_A| \end{cases} \quad (17)$$

其中,  $\theta'$  为车辆  $v_A$  的行驶方向向量  $\vec{v}_A$  与车辆  $v_B$  行驶方向向量  $\vec{v}_B$  所形成的夹角;  $\vec{AB}$  为车辆  $v_A$  到车辆  $v_B$  的向量;  $\beta$  为  $\vec{v}_A$  与  $\vec{AB}$  所成夹角.




图4 存在邻居在下一路径上




图5 邻居都不在下一路径上




图6 车辆之间的链路评估

用  $Link_A$  表示当前车辆  $v_B$  与其邻居车辆  $v_A$  之间通信链路的生存性, 其公式如下:

$$Link_A = \frac{L_{AB}^T - T_{\text{data}}}{2 \times R} \quad (18)$$

其中,  $L_{AB}^T$  表示  $v_A$  与  $v_B$  之间通信链路维护时间;  $T_{\text{data}}$  表示车辆之间完成一次数据包传输所需要的时延;  $Link_A$  的值越大, 表示  $v_A$  与  $v_B$  之间的链路生存性越好.

### (3) 路由空洞的影响

考虑到  $v_A$  作为中继若其邻居车辆分布较为稀疏时, 容易在下次路由中产生路由空洞. 为了避免路由空洞, 综合考虑  $v_A$  的邻居数量以及其邻居在单位时间内的变化情况, 计算车辆  $v_A$  后继可转发的概率  $F_A$ , 其公式如下:

$$F_A = \kappa \frac{n_A}{N_{\text{mean}}} + (1 - \kappa) \frac{m_A}{N_{\text{mean}}} \quad (19)$$

其中,  $n_A$  为  $v_A$  的邻居数量;  $m_A$  为单位时间后  $v_A$  的邻居车辆中比  $v_A$  更接近目的地的车辆数量;  $N_{\text{mean}}$  为 VANET 中车辆的平均邻居数量;  $n_A/N_{\text{mean}}$  表示车辆  $v_A$  周围的车辆密度,  $m_A/N_{\text{mean}}$  表示  $v_A$  陷入路由空洞的可能性, 其值越大, 则可能性越小.  $\kappa$  为权重因子且  $0 < \kappa < 1$ .

### 3.2.2 中继车辆选择策略

基于以上因素考虑, 本文在现有贪婪转发策略的基础上进行优化, 引入车辆的位置代价、车辆之间链路生存性和路由空洞等参考因素, 设计了如公式 (20) 所示的转发代价  $Cost_A$ .

$$Cost_A = \omega_1 \times Place_A + \omega_2 \times \frac{1}{Link_A} + \omega_3 \times \frac{1}{F_A} \quad (20)$$

其中,  $Place_A$  表示邻居车辆  $v_A$  基于位置的代价;  $Link_A$  表示  $v_A$  与  $v_B$  之间通信链路的生存性;  $F_A$  表示  $v_A$  后继可转发的概率;  $\omega_1$ 、 $\omega_2$ 、 $\omega_3$  是权重因子且  $\omega_1 + \omega_2 + \omega_3 = 1$ .

基于 Markov 预测的在线 V2V 传输机制的具体过程如算法 2 所示. 首先, 如果目的地在当前车辆  $v_B$  的传输半径内, 则直接将数据包传递给目的地; 否则, 在步骤 4–20 中, 通过基于 Markov 预测的在线 V2V 传输机制生成下一中继车辆进行数据包传递. 步骤 5–7 中, 如果当前车辆  $v_B$  的邻居车辆在下一路径上, 对于这些邻居根据公式 (20) 选择下一车辆; 步骤 9–16 处理邻居车辆不在下一路径上的情况, 其中, 步骤 11, 12 考虑存在邻居下一时刻可能出现在下一路径上的情况, 对于这些邻居根据公式 (20) 选择下一中继车辆; 而步骤 14, 15 处理邻居车辆都不可能出现在下一路径上的情况, 同样对于这些邻居根据公式 (20) 选择下一中继车辆. 如果  $v_B$  没有邻居车辆, 则在步骤 19 中采取携带转发策略.

---

#### 算法 2. V2V 转发策略.

---

输入: 当前车辆  $v_B$ 、下一路径  $G_{\text{best}}$ ;

输出: 下一中继车辆.

---

1. **if**  $dist_{BD} < R$  **then**
  2.   将数据包直接转发给目的地  $D$ ;
  3. **else**
  4.   **if**  $\exists v_A \in VR'_B$  **then**
  5.     **if**  $v_A \in VG'_{\text{best}}$
  6.       根据公式 (20) 选择具有最小  $Cost_A$  的中继车辆  $v_A$ ;
  7.       转发数据包给车辆  $v_A$ ;
  8.     **else**
  9.       查找下一时刻邻居  $v_A$  出现在下一路径  $G_{\text{best}}$  上的概率  $p_A$ ;
  10.       **if**  $\exists p_A > 0$
  11.          根据公式 (20) 选择具有最小  $Cost_A$  的中继车辆  $v_A$ ;
  12.          转发数据包给车辆  $v_A$ ;
  13.       **else**
  14.          根据公式 (20) 选择具有最小  $Cost_A$  的中继车辆  $v_A$ ;
  15.          转发数据包给车辆  $v_A$ ;
  16.       **end if**
  17.     **end if**
  18. **else**
  19.   当前车辆  $v_B$  采用携带转发方式进行传输;
-

20. end if

21. end if

### 3.2.3 算法在线性能分析

考虑到第 3.2.2 节提出的策略需要当前车辆在线计算下一跳转发中继, 其算法的实时响应至关重要. 因此, 为了验证该在线中继选择策略的实际可行性, 我们对其计算时间复杂度和空间复杂度进行了如下具体分析.

#### (1) 计算时间复杂度

对于当前车辆  $v_B$ , 当其收到待转发数据包时, 其需在候选邻居集合  $C_B$  中计算各邻居节点  $v_A$  的转发代价. 由公式 (20) 可知, 该代价函数包含 3 个核心维度: 位置代价  $Place_A$ 、链路生存性  $Link_A$  以及后继可转发概率  $F_A$ .

这里, 对于  $Place_A$ , 由公式 (13) 可知, 其最高仅涉及二维空间单点对的欧氏距离计算和余弦相似度计算, 用到的坐标位置和位置转移概率可直接通过邻居信息表查询得到, 其计算时间复杂度约为  $O(1)$ . 同理, 对于  $Link_A$  和  $F_A$ , 如公式 (18) 和公式 (19) 所示, 其仅涉及简单的四则运算, 所以其计算复杂度亦为  $O(1)$ . 因此, 对于当前车辆  $v_B$  来说, 每个邻居  $v_A$  的转发代价计算复杂度约为  $O(1)$ .

然而, 由公式 (13) 可知, 当前车辆  $v_B$  的候选邻居集合  $C_B$  并不一定等于其传输范围内的邻居集合  $VR'_B$ . 其需按照相应约束条件从  $VR'_B$  中按优筛选候选邻居. 若存在任一邻居当前位于最优的下一路径上, 即  $\exists v_A \in VG'_{best}$ , 则  $C_B = VG'_{best}$ , 我们仅需计算在  $VG'_{best}$  中各邻居节点的转发代价即可. 否则, 我们需要根据各邻居到下一路径的位置转移概率值  $p_A$  进行筛选. 若存在  $p_A > 0$ , 此时  $C_B = \{v_A | p_A > 0\}$ ; 否则, 我们才需计算所有邻居的转发代价. 因此, 在本文提出的基于 Markov 预测的在线 V2V 传输机制中, 车辆在选择下一中继节点时, 对比的邻居节点数量要小于等于传输半径内邻居的数量, 即  $|C_B| \leq |VR'_B|$ . 因此, 本文提出的在线 V2V 转发策略的计算复杂度为  $O(|C_B|)$ .

#### (2) 计算空间复杂度

对于当前车辆  $v_B$ , 在计算邻居的转发代价前需要查询邻居表以获取必要信息. 传统的基于位置的路由协议中, 车辆通过周期性地广播 HELLO 消息来共享自身信息, 并建立邻居表以维护单跳邻居的信息. 该表通常包括车辆 ID、位置 position 以及最近一次接收到信号的时间戳 time. 本文对邻居表的格式进行了修改, 除以上基本信息外, 新增了车辆的当前速度  $u$ 、行驶方向角  $\theta$ 、邻居节点数量  $|VR'_{ID}|$ , 以及位置转移概率向量  $P_{neigh}$  (下阶段前往当前所在网格或与当前网格直接/对角线相邻的八邻域网格的概率) 等扩展信息, 以满足下一中继选择的要求.

修改后的邻居表结构如图 7 所示, 每个邻居条目占用 32 个字节, 邻居条目中各字段的大小参考 BSM 报文的一些格式设置和 SAE J2735 标准<sup>[38,39]</sup>. 其中, 新增的当前速度  $u$ 、行驶方向角  $\theta$  字段分别占用 2 字节. 考虑到面向的应用场景以及邻居数量对通信质量的影响, 设邻居节点数量字段占用 1 个字节. 由于  $P_{neigh}$  需要存放到目前网格和八邻域网格的转移概率, 其需维护 9 个概率值, 每个概率值占用 1 个字节用 0–100 的整型数据表示, 共占用 9 个字节. 由于扩展信息仅占用 14 字节, 符合 HELLO 包的扩展限制<sup>[26]</sup>, 可以直接通过 HELLO 包完成信息的获取.



图 7 邻居表

由算法 2 和上述计算时间复杂度分析可知, 当前车辆在计算下一转发中继时仅需通过对邻居表中邻居信息的查找计算来选择最优转发中继, 并没有使用额外的数据结构. 因此, 在内存空间的占用上额外空间的占用约为  $O(1)$ , 总空间的占用主要受输入的邻居表大小的影响. 考虑到算法最多需要查询其传输半径内所有邻居的相关信息完成中继的计算, 邻居表最多需维护  $|VR'_B|$  个邻居条目信息. 因此, 对于每个车辆节点来说, 执行在线 V2V 算法时其计算空间复杂度主要受邻居表的大小影响为  $O(32|VR'_B|)$ .

#### 4 仿真实验

为了验证 HTD-IR 的性能, 在 Matlab 平台上对其与相应的对比算法 W-PAGPSR<sup>[18]</sup>、QGrid-M<sup>[30]</sup>和 QGrid-G<sup>[30]</sup>进行了仿真实现, 实验计算机配备 AMD Ryzen 7 5800H 处理器, RTX 3050 显卡, 运行内存 16 GB, 采用 Windows 11 操作系统. 在此环境下, 建立了如图 8(a) 所示 3000 m×3000 m 的仿真区域, 将区域划分为 12×12 的网格, 每个网格长度为 250 m. 其中黑色线段表示交通道路模型, 共包括 6 个路口和 14 条双向车道. 红色正方形表示源节点、绿色正方形表示目的地. 源节点以每秒 3 个数据包的速度发送请求, 并为每个数据包设置一个超时时钟器, 如果在超时时钟器内源节点未收到来自目的地的确认消息, 源节点将认为数据包投递失败, 对该数据包进行重新发送. 在模拟的过程中, 如图 8(b) 所示车辆的初始位置随机分布, 车辆的速度范围为 0–40 m/s, 强化学习的学习率  $\alpha$  为 0.8,  $\varepsilon$  为 0.2, 评估  $\gamma$  的因子  $\delta$  为 0.5.




图 8 道路交通图

##### 4.1 性能指标

为了评价 HTD-IR 的有效性, 我们采用以下指标来衡量路由协议性能的好坏.

平均跳数: 数据包从源节点到目的地在路由路径上经过的平均节点数, 即所有成功数据包经过的总跳数与目的地成功接收到的数据包总数  $P_s$  之比.

平均端到端时延: 数据包从源节点到目的地所花费的平均时间.

投递率: 目的地成功接收到的数据包总数  $P_s$  与源节点发送的数据包总数  $P_w$  之比.

网络收益率: 目的地成功接收到的数据包总数  $P_s$  与网络中所有参与数据包传输的车辆数  $\sum_{pi \in P_w} H(pi)$  之比, 计算公式如 (21) 所示, 其中  $H(pi)$  表示数据包  $pi$  所经过的车辆数.

$$Networkyield = \frac{P_s}{\sum_{pi \in P_w} H(pi)} \quad (21)$$

平均成功发包开销: 源节点发送不同数据包的总数  $DP_w$  与成功接收的不同数据包的数量  $P_k$  之比, 这意味着为成功传递每一个数据包需要额外传输多少个数据包作为开销, 计算公式如公式 (22) 所示:

$$OverheadRatio = \frac{DP_w}{P_k} \quad (22)$$

##### 4.2 HTD-IR 有效性验证

为了验证 HTD-IR 的有效性, 考虑到车辆的传输半径通常是异构的, 其具备不同发射功率和动态调整功率以

降低能耗的能力<sup>[40]</sup>. 我们通过调整车辆的传输半径来验证算法在不同发射功率下的性能表现. 与此同时, 考虑到  $TTL$  值对数据投递率的影响, 我们对不同  $TTL$  下算法的性能进行测量. 最后在不同的车辆传输半径  $R$  和数据包生存时间  $TTL$  下, 分别对比本文算法 HTD-IR 与 W-PAGPSR、QGrid-M 和 QGrid-G 算法在平均跳数、平均端到端时延、投递率、网络收益率、平均成功发包开销这 5 个方面的性能.

图 9 和图 10 为各种路由算法的平均跳数与车辆的传输半径  $R$  和数据包的生存时间 ( $TTL$ ) 之间的关系. 其中,  $TTL$  表示数据包在网络中允许被转发的最大跳数, hopCount 表示数据包从源节点传输到目的节点实际经过的平均跳数, hopCount 不能超过  $TTL$ . QGrid-M 和 QGrid-G 的平均跳数最高, 数据包经过的跳数在 HTD-IR 中比 W-PAGPSR 要多. QGrid-M 和 QGrid-G 每次通过 Q-learning 提前规划好的并非较短路由路径转发数据包, 而 QGrid-G 每次按照路径将数据包转发到距离目的地最近的邻居节点. 因此, QGrid-M 的平均跳数最大, QGrid-G 次之. W-PAGPSR 通过改进的贪婪策略选择中继节点, 传递数据包可靠性较低, 在传输过程中当前车辆只能等待转发, 从而减少了平均跳数.




图 9 不同车辆节点的传输半径  $R$  下的平均跳数




图 10 不同数据包的生存时间 ( $TTL$ ) 下的平均跳数

图 9(a) 和图 9(b) 显示了各种不同算法在车辆的不同传输半径  $R$  下平均跳数的仿真结果. 平均跳数与车辆的传输半径  $R$  呈负相关关系, 当源节点与目的地之间的距离一定时, 车辆节点的传输半径越大, 平均跳数越少.

图 10(a) 和图 10(b) 显示了各种不同算法在数据包不同的生存时间 ( $TTL$ ) 下平均跳数的仿真结果. 随着数据包生存时间的增加, QGrid-M 的平均跳数略有增加, 因为随着数据包生存时间的增加, 数据包传输策略从等待转发转变为马尔可夫预测策略, 使得平均跳数增加. QGrid-G、W-PAGPSR 和 HTD-IR 的平均跳数保持相对稳定.

虽然 HTD-IR 的跳数不是最优的,但是本文考虑数据包传输时延较低的问题,HTD-IR 在平均端到端时延上表现最优.如图 11 和图 12 为各种路由算法的平均端到端时延与车辆的传输半径  $R$  和数据包的生存时间 ( $TTL$ ) 之间的关系. QGrid-M、QGrid-G 和 W-PAGPSR 的平均端到端时延高于 HTD-IR. 特别是在  $R=400$  m,  $TTL=20$  跳时, HTD-IR 的平均端到端时延相比于 W-PAGPSR、QGrid-M、QGrid-G 分别降低了 20.11%、30.63%、20.97%. QGrid-M 和 QGrid-G 虽然这两个算法总是选择车辆密度最大的网格作为下一网格,路径较长导致端到端时延增大,而 HTD-IR 将数据包转发到车辆密度与路径长度均较优的路段进行数据包传输,从而缩短了端到端时延. W-PAGPSR 由于在处理路由空洞问题时采用周边转发策略以及选择中继节点的可靠性不够,长时间不可达造成较大的端到端时延,因此 HTD-IR 具有最低的平均端到端时延.




图 11 不同车辆节点的传输半径  $R$  下的平均端到端时延




图 12 不同数据包的生存时间 ( $TTL$ ) 下的平均端到端时延

图 11 显示了各种不同算法在车辆不同的传输半径  $R$  下平均端到端时延的仿真结果. 随着车辆传输半径  $R$  的增加, 平均端到端时延减小. 由于车辆的传输半径  $R$  越大, 可选的下一车辆概率越大, 发生路由空洞及携带转发的次数减小, 从而大大减少时延. 另外, 在  $TTL=20$  跳,  $R$  为 320–400 m 的情况下, 观察到 QGrid-G 和 W-PAGPSR 在车辆传输半径变化时性能出现交叉现象. 这是因为 QGrid-G 选择车辆密度较大的路径进行数据包传输, 而 W-PAGPSR 在下一车辆选择时节点密度并不是作为主要考虑因素. 因此, 当车辆的传输半径较小时, W-PAGPSR 的可通信邻居数量较少, 采用周边转发策略次数增多, 从而使得时延比 QGrid-G 大. 而车辆的传输半径较大时, W-PAGPSR 能够与更多车辆建立通信连接, 减少了携带转发的情况, 因此时延显著减少. 从图 11(a) 和图 11(b) 可以看出, HTD-IR 在平均端到端时延上一直处于最低状态, 因为 HTD-IR 沿较短路径传输的同时减少路由空洞的发生

使得时延最少, 能够更好地适应车辆的传输半径  $R$  的变化, 另外, 在数据包生存时间 ( $TTL$ ) 发生变化的情况下也有较好表现。

图 12 显示了各种不同算法在数据包不同的生存时间 ( $TTL$ ) 下平均端到端时延的仿真结果。随着数据包的生存时间 ( $TTL$ ) 的增加, 平均端到端时延也随之增加。增加数据包的生存时间允许数据包有更多的时间到达目的地, 从而增加延迟。另外, 在  $R=360$  m,  $TTL$  为 13–23 跳情况下, 观察到 QGrid-G 和 W-PAGPSR 在  $TTL$  变化时性能出现交叉现象。这是因为 QGrid-G 选择的路径密度较高, 路径较长, 而 W-PAGPSR 在下一车辆选择时更多考虑距离因素。因此, 当  $TTL$  较小时, QGrid-G 所成功转发的数据包所选路径较长从而使得时延比 W-PAGPSR 大。而  $TTL$  较大时, QGrid-G 有更多的时间到达目的地, 而 W-PAGPSR 与邻居车辆可通信的数量比 QGrid-G 少, 存在更多携带转发的情况, 因此 QGrid-G 的时延少。同样地, 图 12(a) 和图 12(b) 也表明, HTD-IR 在不同传输半径  $R$  下对平均端到端时延有一定的改善。

图 13 和图 14 展示了各种路由算法的数据包投递率与车辆的传输半径  $R$  和数据包生存时间 ( $TTL$ ) 之间的关系。HTD-IR 在数据包投递率方面表现出较高水平, 特别是在  $R = 340$  m,  $TTL = 20$  跳时, HTD-IR 的投递率相较于 W-PAGPSR、QGrid-M、QGrid-G 分别提高了 42.93%、51.52%、54.04%。这表明 HTD-IR 通过选择最优的路由路径并采用较优的 V2V 传输策略, 相较于其他算法更能有效提高数据包的投递率。相比之下, QGrid-M 和 QGrid-G 对划分的网格区域采用马尔可夫预测策略和贪婪策略, 其中要么未考虑车辆之间链路的动态性, 要么未考虑车辆运行轨迹的动态性可能导致数据包丢失。而 W-PAGPSR 对节点间通信链路质量进行评估, 但由于缺乏对节点运动轨迹动态性的考虑, 也可能导致数据包丢失。因此, HTD-IR 在网络性能方面表现出最佳水平。




图 13 不同车辆节点的传输半径  $R$  下的数据包投递率

图 13(a) 和图 13(b) 显示了各种不同算法在车辆不同的传输半径  $R$  下数据包投递率的仿真结果。随着车辆传输半径  $R$  的增加, 各个算法的数据包投递率逐渐增加。由于车辆的传输半径  $R$  越大, 车辆之间链路的生存时间会提高, 使得数据包在传输过程中的丢包率减少。由于本文 HTD-IR 算法, 对下一中继的选择较为严格, 能够选择更可靠的中继车辆, 所以数据包投递率优于其他算法。另一方面也反映出, HTD-IR 在不同数据包生存时间 ( $TTL$ ) 下的数据包投递率也优于其他 3 种协议。

图 14 显示了各种不同算法在数据包不同的生存时间 ( $TTL$ ) 下数据包投递率的仿真结果。随着数据包生存时间 ( $TTL$ ) 的增加, 数据包有更多的时间到达目的地, 从而提高了数据包的投递率。图 14(a) 和图 14(b) 的对比结果同样表明, HTD-IR 在不同  $TTL$  下的数据包投递率上也能适应车辆节点传输半径  $R$  的变化。

图 15 和图 16 为各种路由算法的网络收益率与车辆的传输半径  $R$  和数据包的生存时间 ( $TTL$ ) 之间的关系。HTD-IR 的网络收益率明显高于 QGrid-M、QGrid-G 和 W-PAGPSR, 特别是在  $R = 360$  m,  $TTL = 13$  跳时, HTD-IR 的网络收益率相较于 W-PAGPSR、QGrid-M、QGrid-G 分别提高了 51.81%、88.12%、64.69%。原因是 QGrid-M 和 QGrid-G 的丢包率高于 HTD-IR, 而且数据包转发的路径较长, 使得参与转发的车辆节点数较多, 因此网络收益

率较低. 尽管 W-PAGPSR 的平均跳数小于 HTD-IR, 但相差并不大, HTD-IR 的丢包率比 W-PAGPSR 小得多, 因而 HTD-IR 的性能更优.




图 14 不同数据包的生存时间 ( $TTL$ ) 下的数据包投递率




图 15 不同车辆节点的传输半径  $R$  下的网络收益率




图 16 不同数据包的生存时间 ( $TTL$ ) 下的网络收益率

图 15 显示了各种不同算法在车辆不同的传输半径  $R$  下网络收益率的仿真结果. 随着传输半径的增加, 平均跳数减小, 网络中参与数据包传输的车辆减少, 而数据包成功率逐渐增加, 因此网络收益率逐渐增大. 同样地, 图 15(a) 和图 15(b) 的对比也表明, HTD-IR 在数据包不同的生存时间 ( $TTL$ ) 下的网络收益率也优于其他 3 种协议.

图 16 显示了各种不同算法在数据包不同的生存时间 ( $TTL$ ) 下网络收益率的仿真结果. 随着数据包生存周期的增大, 数据包的投递率也随之升高, 使得成功的数据包数增多, 而跳数变化平缓, 因此网络收益率升高. 同样地, 图 16(a) 和图 16(b) 的对比也表明, HTD-IR 在车辆不同的传输半径  $R$  下的网络收益率也优于其他 3 种协议.

图 17 和图 18 为各种路由算法的平均成功发包开销与车辆的传输半径  $R$  和数据包生存时间 ( $TTL$ ) 之间的关系. HTD-IR 的平均成功发包开销低于对比算法. HTD-IR 对中继车辆的筛选比其他算法更加严格, 从多个角度考虑下一中继车辆, 进而选择性能较优的车辆, 提高车辆之间数据包传递的可靠性, 从而降低平均成功发包开销. 相比之下, W-PAGPSR 由于缺乏考虑节点运动轨迹的动态性, 导致丢包的可能性增大使得平均成功发包开销增大; 而 QGrid-G 和 QGrid-M 均未考虑车辆间通信链路的动态性, 导致数据包频繁丢失, 成功传递的数据包会很少, 使得平均成功发包开销较大.




图 17 不同车辆节点的传输半径  $R$  下的平均成功发包开销




图 18 不同数据包的生存时间 ( $TTL$ ) 下的平均成功发包开销

图 17 显示了各种不同算法在车辆不同的传输半径  $R$  下平均成功发包开销的仿真结果. 平均成功发包开销随着车辆传输半径  $R$  的增加而减小, 主要是因为随着传输半径  $R$  的增大, 包投递率增加, 从而使得平均成功发包开销减小. 同样地, 图 17(a) 和图 17(b) 的对比也表明, HTD-IR 在数据包生存时间 ( $TTL$ ) 变化的情况下也具有较低的平均成功发包开销.

图 18 为各种路由算法在数据包不同的生存时间 ( $TTL$ ) 条件下平均成功发包开销的仿真结果. 我们观察到平均成功发包开销随着不同数据包生存时间 ( $TTL$ ) 的增加而减小, 即以较少的数据包为开销完成不同的数据包传递. 图 18(a) 和图 18(b) 的对比也表明, HTD-IR 在平均成功发包开销上也能较好的适应车辆节点的传输半径  $R$  的变化.

4.3 算法在线性能评估与实验验证


为了评估 HTD-IR 在线阶段的性能, 我们将 HTD-IR 与对比算法在计算时间复杂度和空间复杂度两个方面进行了详细的对比分析, 以评估它们在不同网络规模下的执行性能. 其中表 1 和表 2 分别总结了各算法在计算时间和空间上复杂度情况, 图 19 和图 20 分别展示了不同路由算法的执行时间和内存空间占用情况随着车辆数量和传输范围变化的趋势.

表 1 各算法时间复杂度对比表


| 路由算法     | 时间复杂度      |
|----------|------------|
| HTD-IR   | $O( C' )$  |
| QGrid-M  | $O( VR' )$ |
| QGrid-G  | $O( VR' )$ |
| W-PAGPSR | $O( VR' )$ |

表 2 各算法空间复杂度对比表

| 路由算法     | 空间复杂度        |
|----------|--------------|
| HTD-IR   | $O(32 VR' )$ |
| QGrid-M  | $O(27 VR' )$ |
| QGrid-G  | $O(18 VR' )$ |
| W-PAGPSR | $O(23 VR' )$ |




(a) 不同车辆数量下的算法执行时间 ( $R=360$  m)




(b) 不同车辆传输半径  $R$  下的算法执行时间 (车辆总数为 600)

图 19 车辆数量与传输半径  $R$  对算法执行时间的影响



(a) 不同车辆数量下的算法内存资源占用 ( $R=360$  m)



(b) 不同车辆传输半径  $R$  下的算法内存资源占用 (车辆总数为 600)

图 20 车辆数量与传输半径  $R$  对算法内存资源占用的影响

如表 1 所示, 在时间复杂度方面, 3 个对比算法的时间复杂度均为  $O(|VR'|)$ , 这主要是因为, 对于 QGrid-M 来说, 需计算所有邻居的位置转移概率来选择最优的下一邻居, 所以, 时间复杂度约为  $O(|VR'|)$ . 对于 QGrid-G 和 W-PAGPSR 来说, 均需要计算所有邻居节点与目的地的距离来选择最优的下一邻居, 因此, 其时间复杂度亦为  $O(|VR'|)$ . 而由第 3.2.3 节计算时间复杂度分析可知, 本文算法 HTD-IR 的时间复杂度为  $O(|C'|)$ , 所以, 本文算法在线阶段的时间复杂度优于其他 3 种路由算法. 图 19 的仿真结果进一步验证了这一结论.

图 19 展示了不同车辆数量和传输半径  $R$  下, 各算法的执行时间变化趋势. 结果表明, 所有算法的执行时间均随车辆数量和传输半径的增加而上升. 这主要是因为, 如图 21 所示, 随着车辆数量的增加和传输半径的扩大, 每辆车的邻居数量增多, 从而导致了计算开销的增加. 由此可见, 如表 1 所示, 各算法的计算时间与邻居数量成正比.




图 21 车辆数量与传输半径  $R$  对邻居数量的影响

而且, 虽然各算法的计算时间都受邻居数量影响, 但本文 HTD-IR 在不同车辆数量和传输范围下表现最优, 其执行时间明显低于其他 3 种路由算法. 这是因为, 如图 21 所示, 本文算法 HTD-IR 在选择下一跳转发中继时, 实际执行转发代价计算的邻居数量  $|C'|$  要小于其他算法执行计算的邻居数量  $|VR'|$ .

此外, 其他 3 种算法虽然时间复杂度上均为  $O(|VR'|)$ , 但 W-PAGPSR 执行时间高于 QGrid-M 和 QGrid-G. 这主要是因为 QGrid-M 仅基于位置转移概率的大小来选择邻居, QGrid-G 虽然和 W-PAGPSR 一样都是基于距离来选择邻居, 但 QGrid-G 仅基于位置的欧氏距离来选择邻居, 而 W-PAGPSR 需要综合考虑多个因素 (如位置、邻居密度和通信链路质量等) 来计算邻居. 因此 QGrid-M 和 QGrid-G 计算量较小, 执行速度更快.

表 2 展示了各算法在线计算的空间复杂度情况. 与本文算法类似, 其他 3 种算法在选择下一中继节点时并无额外的数据结构引入, 其空间复杂度亦主要受输入的邻居表大小影响. 对于 QGrid-G 来说, 通过收集邻居的基本信息即可执行下一跳选择, 因此仅需维护图 7 所示邻居条目的基本信息字段, 其计算空间复杂度为  $O(18|VR'|)$ . W-PAGPSR 需扩展存储邻居车辆的速度、行驶方向角和邻居数量信息来计算邻居, 因此, W-PAGPSR 的空间复杂度为  $O(23|VR'|)$ . 对于 QGrid-M 来说, 除了需要维护邻居的基本信息外, 还需与本文一样扩展存储邻居的位置转移概率向量  $P_{\text{neigh}}$  信息, 因此, QGrid-M 的空间复杂度为  $O(27|VR'|)$ . 而如第 3.2.3 节空间复杂度分析可知本文算法 HTD-IR 的空间复杂度为  $O(32|VR'|)$ , 相较于其他 3 种算法所占空间最大.

图 20 展示了不同车辆数量和传输半径  $R$  下, 各算法执行在线计算时所占内存空间资源的变化趋势. 结果表明, 所有算法的邻居表所占空间资源均随车辆数量和传输半径的增加而上升. 这主要是因为, 随着车辆数量的增加和传输半径的扩大, 每辆车的邻居数量增多, 导致邻居表所占用的空间资源增加, 验证了如表 2 所示的各算法空间复杂度与其邻居表大小成正比.

此外, 由图 20 还可以看出, 虽然由于本文 HTD-IR 的邻居表需扩展更多的信息来支持下一跳, 其空间占用高于其他 3 种路由算法, 但增加的存储开销有限, 远低于现代车载终端的运行内存.

## 5 总 结

针对车载自组织网络中基础设施稀疏、车辆分布不均匀、车辆的高度动态性以及轨迹难以预测等问题, 本文提出一种基于历史交通数据驱动的 VANET 智能路由算法. 该算法将地理区域划分为大小一致的网格, 针对不同目的地计算出车辆从当前网格向不同方向的邻居网格移动的  $Q$  值, 每辆车存储由 Q-learning 计算得到的用于路径选择的转发表, 车辆通过查询转发表来选择下一路径, 然后根据车辆的位置代价、链路的生存性以及路由空洞得到的转发代价找到代价最小者作为下一中继车辆. 通过与现有方法进行实验对比, 研究结果表明: HTD-IR 在 VANET 中具有良好的路由性能, 表现出高投递率、低时延、高网络收益率和低开销的特点. 在未来的工作中, 我们将继续对算法进行优化, 如在 V2V 方式中对车辆选择策略进行优化, 在道路交叉口处考虑车辆的行驶方向和轨迹对未来数据包传输的贡献, 进一步提高算法效率.

## References:

- [1] Qazzaz MMH, Zaidi SAR, McLernon DC, Hayajneh AM, Salama A, Aldalahmeh SA. Non-terrestrial UAV clients for beyond 5G networks: A comprehensive survey. *Ad Hoc Networks*, 2024, 157: 103440. [doi: [10.1016/j.adhoc.2024.103440](https://doi.org/10.1016/j.adhoc.2024.103440)]
- [2] Hawbani A, Wang XF, Al-Dubai A, Zhao L, Busaileh O, Liu P, Al-Qaness MAA. A novel heuristic data routing for urban vehicular ad hoc networks. *IEEE Internet of Things Journal*, 2021, 8(11): 8976–8989. [doi: [10.1109/JIOT.2021.3055504](https://doi.org/10.1109/JIOT.2021.3055504)]
- [3] Tan HW, Zheng WY, Vijayakumar P, Sakurai K, Kumar N. An efficient vehicle-assisted aggregate authentication scheme for infrastructure-less vehicular networks. *IEEE Trans. on Intelligent Transportation Systems*, 2023, 24(12): 15590–15600. [doi: [10.1109/TITS.2022.3176406](https://doi.org/10.1109/TITS.2022.3176406)]
- [4] Rehman GU, Ghani A, Muhammad S, Singh M, Singh D. Selfishness in vehicular delay-tolerant networks: A review. *Sensors*, 2020, 20(10): 3000. [doi: [10.3390/s20103000](https://doi.org/10.3390/s20103000)]
- [5] Rui LL, Yan ZB, Tan ZY, Gao ZP, Yang Y, Chen XY, Liu HY. An intersection-based QoS routing for vehicular ad hoc networks with reinforcement learning. *IEEE Trans. on Intelligent Transportation Systems*, 2023, 24(9): 9068–9083. [doi: [10.1109/TITS.2023.3271456](https://doi.org/10.1109/TITS.2023.3271456)]
- [6] Zhou MM, Liu L, Sun YS, Wang K, Dong MX, Atiquzzaman M, Dustdar S. On vehicular ad-hoc networks with full-duplex radios: An end-to-end delay perspective. *IEEE Trans. on Intelligent Transportation Systems*, 2023, 24(10): 10912–10922. [doi: [10.1109/TITS.2023.3279322](https://doi.org/10.1109/TITS.2023.3279322)]
- [7] Chithaluru P, Uyyala R, Singh A, Alfarraj O, Lopez LA, Khatak S, Alkhayyat AH. A lightweight energy-efficient routing scheme for real-time WSN-VANET-based applications. *IEEE Trans. on Consumer Electronics*, 2024, 70(1): 3820–3826. [doi: [10.1109/TCE.2024.3371230](https://doi.org/10.1109/TCE.2024.3371230)]
- [8] Khan Z, Koubaa A, Benjdira B. A heuristic route planning scheme in scalable VANET-oriented evolving grid graph (S-VoEGG). *IEEE Trans. on Network Science and Engineering*, 2024, 11(4): 3851–3865. [doi: [10.1109/TNSE.2024.3389657](https://doi.org/10.1109/TNSE.2024.3389657)]
- [9] Zhang DG, Wang JX, Zhang J, Zhang T, Yang C, Jiang KW. A new method of fuzzy multicriteria routing in vehicle ad hoc network. *IEEE Trans. on Computational Social Systems*, 2023, 10(6): 3181–3193. [doi: [10.1109/TCSS.2022.3193739](https://doi.org/10.1109/TCSS.2022.3193739)]
- [10] Xia YJ, Liu XJ, Ou J, Ma OB. RLID-V: Reinforcement learning-based information dissemination policy generation in VANETs. *IEEE Trans. on Intelligent Transportation Systems*, 2023, 24(12): 14151–14161. [doi: [10.1109/TITS.2023.3300948](https://doi.org/10.1109/TITS.2023.3300948)]
- [11] Yu CM, Ku ML, Wang LC. Joint topology construction and hybrid routing strategy on load balancing for bluetooth low energy networks. *IEEE Internet of Things Journal*, 2021, 8(8): 7101–7102. [doi: [10.1109/JIOT.2021.3051561](https://doi.org/10.1109/JIOT.2021.3051561)]
- [12] Sun MT, Chu CH, Wu EHK, Hsiao CS, Jeng AAK. Distributed topology control for energy-efficient and reliable wireless communications. *IEEE Systems Journal*, 2018, 12(3): 2152–2161. [doi: [10.1109/JSYST.2017.2673830](https://doi.org/10.1109/JSYST.2017.2673830)]
- [13] Adil M, Song HB, Ali J, Jan MA, Attique M, Abbas S, Farouk A. Enhanced-AODV: A robust three phase priority-based traffic load balancing scheme for Internet of Things. *IEEE Internet of Things Journal*, 2022, 9(16): 14426–14437. [doi: [10.1109/JIOT.2021.3072984](https://doi.org/10.1109/JIOT.2021.3072984)]
- [14] Awais M, Ali I, Alghamdi TA, Ramzan M, Tahir M, Akbar M, Javaid N. Towards void hole alleviation: Enhanced geographic and opportunistic routing protocols in harsh underwater WSNs. *IEEE Access*, 2020, 8: 96592–96605. [doi: [10.1109/ACCESS.2020.2996367](https://doi.org/10.1109/ACCESS.2020.2996367)]
- [15] Torrieri D, Talarico S, Valenti MC. Performance comparisons of geographic routing protocols in mobile ad hoc networks. *IEEE Trans. on Communications*, 2015, 63(11): 4276–4286. [doi: [10.1109/TCOMM.2015.2477337](https://doi.org/10.1109/TCOMM.2015.2477337)]
- [16] Huang HJ, Yin H, Min GY, Zhang JB, Wu YL, Zhang X. Energy-aware dual-path geographic routing to bypass routing holes in wireless sensor networks. *IEEE Trans. on Mobile Computing*, 2018, 17(6): 1339–1352. [doi: [10.1109/TMC.2017.2771424](https://doi.org/10.1109/TMC.2017.2771424)]
- [17] Huang HJ, Yin H, Min GY, Zhang X, Zhu WX, Wu YL. Coordinate-assisted routing approach to bypass routing holes in wireless sensor

- networks. *IEEE Communications Magazine*, 2017, 55(7): 180–185. [doi: [10.1109/MCOM.2017.1600348](https://doi.org/10.1109/MCOM.2017.1600348)]
- [18] Zhang WZ, Jiang LL, Song X, Shao ZY. Weight-based PA-GPSR protocol improvement method in VANET. *Sensors*, 2023, 23(13): 5991. [doi: [10.3390/s23135991](https://doi.org/10.3390/s23135991)]
- [19] Wang ZL, Yao HP, Mai TL, Xiong ZH, Wu XH, Wu D, Guo S. Learning to routing in UAV swarm network: A multi-agent reinforcement learning approach. *IEEE Trans. on Vehicular Technology*, 2023, 72(5): 6611–6624. [doi: [10.1109/TVT.2022.3232815](https://doi.org/10.1109/TVT.2022.3232815)]
- [20] Kumar M, Raw RS. RC-LAHR: Road-side-unit-assisted cloud-based location-aware hybrid routing for software-defined vehicular ad hoc networks. *Sensors*, 2024, 24(4): 1045. [doi: [10.3390/s24041045](https://doi.org/10.3390/s24041045)]
- [21] Nguyen KV, Nguyen PL, Vu QH, Do TV. An energy efficient and load balanced distributed routing scheme for wireless sensor networks with holes. *Journal of Systems and Software*, 2017, 123: 92–105. [doi: [10.1016/j.jss.2016.10.004](https://doi.org/10.1016/j.jss.2016.10.004)]
- [22] Harayama M, Mishioka M. Link quality-aware geographic predictive routing for V2V network based on GPSR. In: *Proc. of the 2023 Int'l Technical Conf. on Circuits/Systems, Computers, and Communications (ITC-CSCC)*. Jeju: IEEE, 2023. 1–6. [doi: [10.1109/ITC-CSCC58803.2023.10212525](https://doi.org/10.1109/ITC-CSCC58803.2023.10212525)]
- [23] Elgaroui L, Pierre S, Chamberland S. New routing protocol for reliability to intelligent transportation communication. *IEEE Trans. on Mobile Computing*, 2023, 22(4): 2281–2294. [doi: [10.1109/TMC.2021.3116157](https://doi.org/10.1109/TMC.2021.3116157)]
- [24] Liu BY, Sheng Y, Shao X, Ji YS, Han WZ, Wang ES, Xiong SW. Collaborative intelligence enabled routing in green IoV: A grid and vehicle density prediction-based protocol. *IEEE Trans. on Green Communications and Networking*, 2023, 7(2): 1012–1022. [doi: [10.1109/TGCN.2022.3188026](https://doi.org/10.1109/TGCN.2022.3188026)]
- [25] Cheng JJ, Yuan GY, Zhou MC, Gao SC, Huang ZH, Liu C. A connectivity-prediction-based dynamic clustering model for VANET in an urban scene. *IEEE Internet of Things Journal*, 2020, 7(9): 8410–8418. [doi: [10.1109/JIOT.2020.2990935](https://doi.org/10.1109/JIOT.2020.2990935)]
- [26] Chen KS, Li HK, Ruan YL, Wang SH. Improved AODV routing protocol based on local neighbor nodes and link weights. *Ruan Jian Xue Bao/Journal of Software*, 2021, 32(4): 1186–1200 (in Chinese with English abstract). <http://www.jos.org.cn/1000-9825/5970.htm> [doi: [10.13328/j.cnki.jos.005970](https://doi.org/10.13328/j.cnki.jos.005970)]
- [27] Yang Q, Yoo SJ. Hierarchical reinforcement learning-based routing algorithm with grouped RSU in urban VANETs. *IEEE Trans. on Intelligent Transportation Systems*, 2024, 25(8): 10131–10146. [doi: [10.1109/TITS.2024.3353258](https://doi.org/10.1109/TITS.2024.3353258)]
- [28] Casas-Velasco DM, Rendon OMC, da Fonseca NLS. DRSIR: A deep reinforcement learning approach for routing in software-defined networking. *IEEE Trans. on Network and Service Management*, 2022, 19(4): 4807–4820. [doi: [10.1109/TNSM.2021.3132491](https://doi.org/10.1109/TNSM.2021.3132491)]
- [29] Liu JR, Zhu H, Zhang GA. Geographic location routing protocol based on Q-learning in Internet of vehicles. *Telecommunication Engineering*, 2023, 63(10): 1472–1478 (in Chinese with English abstract). [doi: [10.20079/j.issn.1001-893x.220514002](https://doi.org/10.20079/j.issn.1001-893x.220514002)]
- [30] Li F, Song XY, Chen HJ, Li X, Wang Y. Hierarchical routing for vehicular ad hoc networks via reinforcement learning. *IEEE Trans. on Vehicular Technology*, 2019, 68(2): 1852–1865. [doi: [10.1109/TVT.2018.2887282](https://doi.org/10.1109/TVT.2018.2887282)]
- [31] Wu CLMG, Liu Z, Liu FQ, Yoshinaga T, Ji YS, Li J. Collaborative learning of communication routes in edge-enabled multi-access vehicular environment. *IEEE Trans. on Cognitive Communications and Networking*, 2020, 6(4): 1155–1165. [doi: [10.1109/TCCN.2020.3002253](https://doi.org/10.1109/TCCN.2020.3002253)]
- [32] Luo L, Sheng L, Yu HF, Sun G. Intersection-based V2X routing via reinforcement learning in vehicular ad hoc networks. *IEEE Trans. on Intelligent Transportation Systems*, 2022, 23(6): 5446–5459. [doi: [10.1109/TITS.2021.3053958](https://doi.org/10.1109/TITS.2021.3053958)]
- [33] Shan AXD, Fan XM, Chen XF, Ji YS, Wu CLMG. A reinforcement learning-based incentive scheme for multi-hop communications in vehicular networks. *IEEE Trans. on Cognitive Communications and Networking*, 2024, 10(1): 335–347. [doi: [10.1109/TCCN.2023.3316644](https://doi.org/10.1109/TCCN.2023.3316644)]
- [34] Jiang Y, Zhu JL, Yang KX. Environment-aware adaptive reinforcement learning-based routing for vehicular ad hoc networks. *Sensors*, 2023, 24(1): 40. [doi: [10.3390/s24010040](https://doi.org/10.3390/s24010040)]
- [35] Zhu RX, Jiang QH, Huang XD, Li DS, Yang QL. A reinforcement-learning-based opportunistic routing protocol for energy-efficient and void-avoided UASNs. *IEEE Sensors Journal*, 2022, 22(13): 13589–13601. [doi: [10.1109/JSEN.2022.3175994](https://doi.org/10.1109/JSEN.2022.3175994)]
- [36] Wang C, Shen XH, Wang HY, Zhang HW, Mei HD. Reinforcement learning-based opportunistic routing protocol using depth information for energy-efficient underwater wireless sensor networks. *IEEE Sensors Journal*, 2023, 23(15): 17771–17783. [doi: [10.1109/JSEN.2023.3285751](https://doi.org/10.1109/JSEN.2023.3285751)]
- [37] Qiang M, Chen XJ, Yin XY, Jia RZ, Xu D, Tang ZY, Fang DY. Data transmission for joint optimization of flow scheduling and path selection in VANETs. *Ruan Jian Xue Bao/Journal of Software*, 2019, 30(2): 346–361 (in Chinese with English abstract). <http://www.jos.org.cn/1000-9825/5384.htm> [doi: [10.13328/j.cnki.jos.005384](https://doi.org/10.13328/j.cnki.jos.005384)]
- [38] Abbasi HI, Voicu RC, Copeland JA, Chang YS. Cooperative BSM architecture to improve transportation safety in VANETs. In: *Proc. of the 13th Int'l Wireless Communications and Mobile Computing Conf. (IWCMC)*. Valencia: IEEE, 2017. 1016–1022. [doi: [10.1109/IWCMC.2017.8262582](https://doi.org/10.1109/IWCMC.2017.8262582)]

[39] IWC MC.2017.7986425]

[39] V2X Communications Message Set Dictionary J2735\_202007. 2020. [https://www.sae.org/standards/content/j2735\\_202007/](https://www.sae.org/standards/content/j2735_202007/)

[40] Alotaibi MM, Mouftah HT. Relay selection for heterogeneous transmission powers in VANETs. IEEE Access, 2017, 5: 4870–4886. [doi: 10.1109/ACCESS.2017.2679606]

附中文参考文献:

[26] 陈侃松, 李豪科, 阮玉龙, 王时绘. 基于局部邻居节点和链路权值的改进 AODV 路由协议. 软件学报, 2021, 32(4): 1186–1200. <http://www.jos.org.cn/1000-9825/5970.htm> [doi: 10.13328/j.cnki.jos.005970]

[29] 刘静茹, 朱浩, 章国安. 车联网中基于 Q 学习的地理位置路由协议. 电讯技术, 2023, 63(10): 1472–1478. [doi: 10.20079/j.issn.1001-893x.220514002]

[37] 强敏, 陈晓江, 尹小燕, 贾茹昭, 徐丹, 汤战勇, 房鼎益. VANET 中流调度与路径选择联合优化的传输策略. 软件学报, 2019, 30(2): 346–361. <http://www.jos.org.cn/1000-9825/5384.htm> [doi: 10.13328/j.cnki.jos.005384]



李洁(1988—), 女, 博士, 讲师, 主要研究领域为未来互联网技术, 自组织网络.



陈侃松(1972—), 男, 博士, 教授, 博士生导师, 主要研究领域为物联网, 计算机视觉, 人工智能.



陈青(1999—), 女, 硕士生, 主要研究领域为无线传感器网络.