

车路协同系统关键技术研究进展

林泓熠¹ 刘洋^{1†} 李深^{2†} 曲小波¹

(1. 清华大学车辆与运载学院, 北京 100084; 2. 清华大学土木水利学院, 北京 100084)

摘要: 随着城市汽车保有量的稳步增长, 道路交通拥堵问题日益凸显, 给城市发展带来了巨大压力。为了有效应对这一挑战, 开发能够提高交通效率并降低能源消耗的方法显得至关重要。在当前环境下, 车路协同系统作为实现绿色智慧交通系统的一种理想选择, 可通过整合和优化各种交通资源, 实现交通效率的提升和能源消耗的降低, 进而为实现“双碳”目标提供了重要技术支持, 已成为交通领域研究和实践的重要方向。本文详细解析了车路协同的基本概念、研究方法和应用场景, 并深入讨论了其4个核心技术模块: 融合感知、驾驶认知、自主决策和协同控制。文章回顾并总结了这些模块中从传统方法到最新的深度强化学习方法的研究成果, 并深入探讨了这些技术和方法在提升交通效率、降低能源消耗和增强道路安全性方面的应用潜力。最后, 文章剖析了车路协同系统在实际应用中可能遇到的诸多挑战, 如信息传输的安全性、系统的稳定性、环境的复杂性等。为了克服这些挑战, 文章从开发整合车端和路端信息的数据集、提升多源感知信息的融合精度、增强车路协同系统的实时性和安全性与优化复杂条件下多车协同决策控制的方法等4个方面展望了未来的发展方向。因此, 本文不仅对于车路协同技术的进一步发展具有重要的参考价值, 也对于城市交通系统的未来规划和建设具有重要的指导意义。

关键词: 车路协同系统; 融合感知; 驾驶认知; 自主决策; 协同控制

中图分类号: U495

文章编号: 1000-565X(2023)10-0046-22

随着全球气候变化问题的日益突出以及环保意识的持续提升, 各国正共同致力于减少碳排放。然而, 作为碳排放的主要来源之一, 大城市中的道路交通面临着严峻的挑战。频繁的交通拥堵、漫长的路口等待时间以及人工驾驶导致的启动延误和随机性等问题, 不仅使交通效率下降, 能耗增加, 更对城市的运营和环保构成了严重挑战, 进一步妨碍了实现减碳目标^[1]。因此, 构建绿色智能交通系统已经成为支持我国实现“双碳”目标的重要保障。

尽管有许多研究致力于提升交通效率和减少能源消耗, 但目前的改进效果仍然有限。近年来, 人工智能技术取得了突破性进展, 其在交通领域的研究和应用也迎来了新的机遇^[2]。在辅助驾驶技术广泛应用和计算能力显著提升的帮助下, 车路协同系统(CVIS)已经成为了解决交通问题的一个重要方案。车路协同系统利用全局视角的协同控制, 实现了车辆与道路信号的联动, 从而最大化地提高了交通效率, 降低了能源消耗, 提升了道路交通安全。

收稿日期: 2023-04-09

基金项目: 国家自然科学基金资助项目(52220105001, 52221005, 52272420)

Foundation items: Supported by the National Natural Science Foundation of China (52220105001, 52221005, 52272420)

作者简介: 林泓熠(1999-), 男, 博士生, 主要从事智慧车辆与智能交通系统研究。E-mail: hy-lin22@mails.tsinghua.edu.cn

†通信作者: 刘洋(1991-), 男, 博士, 助理研究员, 主要从事机器学习与智能交通系统研究。E-mail: thu_ets_lab@tsinghua.edu.cn

†通信作者: 李深(1989-), 男, 博士, 助理研究员, 主要从事智能交通系统与智能车辆研究。E-mail: sli299@tsinghua.edu.cn

车路协同系统在美国、欧洲和日本已经得到广泛研究,并形成了各自的特点和应用模式。在美国, CVIS 主要侧重于预防交通事故、提高车辆安全性以及减少人员伤亡等。主要的研究对象是预警系统,如车道偏离和追尾警告、瞌睡警告、十字路口信号警告、左转路线建议和横向间距建议等。此外,智能汽车项目(IVI)、协同式交叉路口碰撞防止系统(CICAS)和智能驾驶项目(IntelliDrive)等项目也推动了美国在车路协同技术方面的研究。欧洲的 CVIS 主要研究内容是利用先进的信息通信技术,推动安全系统的研发和综合应用,重点是通信标准和接口标准化的研究。其中,电子安全计划(eSafety)与主动防护和安全项目(PReVENT)大大推动了欧洲 CVIS 的研究进展。同时,欧洲智能交通协会与电信标准化协会共同制定了 CVIS 集成的标准,支持车对车(V2V)、车对基础设施(V2I)之间的通信,基本满足现有通信系统的兼容性。日本采用红外信标作为常规探测器对 CVIS 的补充,其应用主要集中在信息服务、交通拥堵缓解、辅助驾驶、道路辅助和停车电子支付等方面。同时,日本还进行了不停车电子收费系统(ETC)以及自动车研究(JARI)等项目的研究,极大地增强了交通信息系统的研究深度。

中国车路协同系统的研发起步相对较晚,直到 2000 年国家智能交通系统工程技术中心才启动了国内首个智能车路协同技术的相关研究。在 2001 年至 2010 年期间,我国明确了“人、车、路三位一体协调发展”的指导思想,各类研究机构 and 高等院校逐渐开始了车路协同技术的基础性研究。在此期间,清华大学、同济大学、华南理工大学等高校针对智能网联汽车的关键技术,如车辆安全辅助驾驶、驾驶员状态识别和车辆运行状态监控等进行了系统研究。同时,V2V/V2I 通信、基础交通信息采集、交通图像处理 and 实时高精度地图与车载定位导航等领域也取得了许多突破,为后续车路协同系统的研究提供了强有力的技术支持。2011 年,中国启动了“十二五”规划下的智能车辆-基础设施协同(CVIS)关键技术研究项目,该项目重点研究了车路协同的关键技术,并提出了智能车辆与基础设施协同技术标准体系。研究成果包括理论方法、信息获取与交互技术、信息综合集成与服务技术以及协同控制技术等,大大推动了我国智能交通的发展。

目前,许多研究已经探索了混合交通协同问题,但对路侧信息在提升交通管控性能中的作用关

注较少。尽管我国在车路协同系统建设方面已经积累了一定优势,但在实际应用中仍面临着许多难题。在早期阶段,共享信息主要集中在道路交通系统信息上,然而这并未带来显著的出行体验改善,也未带来明显的社会效益。为了改善这一状况,需要更深入地理解智能车路协同的本质,提高系统服务的用户体验,并适当扩大应用规模^[3]。车路协同系统作为未来道路交通系统的基础性公共平台,可以实现大范围的车辆协同安全驾驶和道路交通协同管控,从而最大限度地提升交通效率并降低能耗。在自动驾驶发展面临瓶颈的阶段以及实现“双碳”目标的关键时期,对车路协同关键技术进行综述是非常必要的。

本文旨在综述车路协同系统的各项关键技术。首先,概述了车路协同的基本原理、研究方法和应用场景。其次,深入分析了车路协同的 4 个核心技术模块:融合感知、驾驶认知、自主决策和协同控制,以及它们在提高交通效率、降低能源消耗和增强道路安全性方面的贡献。最后,总结了车路协同技术所面临的挑战、潜在研究方向和未来发展趋势,为绿色智慧交通系统的进一步发展提供了参考。同时,希望本文能够给相关领域的研究学者和技术人员提供启发,推动车路协同技术的不断发展和实际应用。

1 车路协同的基本原理与应用

1.1 车路协同的原理与架构

车路协同系统通过实时通信与协作,将车辆、道路设施和其他交通参与者连接在一起,从而实现整个交通系统的优化。其中,车路协同通信包括车对车(V2V)、车对基础设施(V2I)和车对行人(V2P)等模式。CVIS 依托大数据、人工智能、云计算和无线通信技术,实现车辆、道路和行人之间全面的实时信息交流,为动态交通信息的全时空采集和整合提供支持^[4]。图 1 展示了 CVIS 中一个典型的智能网联环境。

CVIS 的核心包括智能车载系统、智能路侧系统以及 V2V/V2I 协同信息交互技术。图 2 展示了 CVIS 的基本结构。在这个系统中,路侧单元(RSU)是一种车辆环境下的无线接入设备,仅在静止状态下支持与车载单元及其他 RSU 进行信息交换。这类设备通常安装在道路周围的区域。车载单元(OBU)是一种可移动的便携式无线接入设备,常见于智能汽车中。OBU 能够在移动过程中与 RSU 和其他




图1 CVIS中典型的智能网联环境

Fig. 1 Typical intelligent connected environment in CVIS




图2 CVIS的基本结构

Fig. 2 Basic structure of CVIS

OBU 进行信息交换。通过这种方式, CVIS 实现了车辆与基础设施之间的实时通信, 从而提升了交通系统的智能化程度。

从图2可以看出, 智能路侧系统通过多种途径(如视频检测、雷达、激光、线圈等)获取交通环境信息, 如交通流量、人流密度、交叉口信息和路况信息等。随后, RSU 对这些信息进行处理和分析, 并通过 V2I 通信的方式发送给车辆。同时, 它将交通环境信息发送到其它 RSU, 并接收来自 OBU 或其他 RSU 的信息。智能车载系统则获取车辆自身的

运行状态信息和周围驾驶环境感知信息, 如定位、加速度、制动、方向盘角度、航向角度、道路走向信息、路况信息、行人和目标车辆等。这些信息可通过 GPS、GIS、雷达、视觉传感器、红外摄像传感器、视频检测、ABS 系统、车载陀螺仪、加速度传感器和方向盘转向传感器等来获取。接着, OBU 对这些数据进行处理和分析, 并以 V2V 通信的形式发送给其他车辆。同时, 它会获取来自路侧设备的信息, 并接收其他车辆发送的信息。通过对这些信息的综合计算, CVIS 可以为驾驶员提供驾驶指导

和建议。

因此，在传感器技术、车载通信技术和智能控制技术的深度融合下，实现更高效、安全、节能的智能驾驶成为可能。在这一系统中，4个核心技术模块：融合感知、驾驶认知、自主决策和协同控制扮演着关键角色，共同为提高交通效率、降低能源消耗和提高道路安全性做出贡献^[5]。第2节将详细探讨这4个核心技术模块在车路协同系统中的发展与应用。

1.2 车路协同的研究方法

从宏观角度来看，CVIS的研究主要基于实验室模拟和实际测试。在实验室环境中建立接近真实环境的CVIS模拟系统可以降低实验成本和风险，还能自由调整驾驶参数，为实际CVIS研究提供强有力的理论支持和技术储备。目前，比较成熟的协同仿真平台包括CORSIM、OPENET、NEMIS、PARAMICS、VISSIM、NS、GloMoSim和NCTUms等。近年来，硬件在环仿真技术通过将实际物体接入仿真系统，取代对应的数学模型，荷兰应用科学研究机构TNO建立的智能车辆和交通仿真测试系统VEHIL、德国柏林交通系统研究所的SUMO仿真平台、德国PTV集团的VISSIM仿真平台等都是这种模式的例子。

在实际测试方面，美国、日本和欧盟的一些国家进行了与CVIS相关的主动安全和辅助安全驾驶的测试，并已在小范围内应用。中国许多大学和科研机构也建立了智能车辆和道路协同测试的平台和场地，例如清华大学建立的中国首个智能CVIS集成测试与验证实验系统、同济大学建立的CVIS实验系统、交通运输部公路科学研究院建立的北京试验场以及长安大学建立的CVIS试验场等。

1.3 车路协同的应用场景

CVIS展现了在智能交通系统中的广泛应用前景，主要包括提升交通安全性、提高交通效率以及增强信息服务等方面。CVIS能够实现车道变换辅助、前向碰撞预警、紧急车辆警告、错误驾驶警告和交通情况警告等功能，这些功能可以提前预警，降低交通事故的可能性。利用速度管理、协同导航以及提供本地信息和地图等手段，CVIS可以全局规划，从而提高车辆的通行效率和交通协调能力，最大程度地缓解交通拥堵。此外，CVIS还能够提供集成的本地服务和互联网服务，例如通过V2V通信实现交叉口车辆避撞、车辆跟驰、车道变换、异

常车道占用警告、紧急制动、电子刹车灯警告和交通优化等功能，或基于V2I通信实现车辆安全辅助驾驶信息服务、交通协调控制、障碍物碰撞警告、自适应速度控制、车辆定位和交叉口速度引导等功能。CVIS的其他典型应用还包括车辆合作变道、行人目标信息融合、协同交通流检测、资源分配和交通指导等^[6]。

在智能交通系统中，CVIS可以通过实时、有效的信息交互(即V2V和V2I通信)，改善驾驶策略以确保驾驶安全，从而降低交通事故发生的概率并提高交通协调能力^[7]。这是CVIS研究的重点，也是指导CVIS应用实际运营的关键。通过这些技术应用于智能交通系统，可以实现更高效、环保和安全的道路交通环境，从而改善城市交通状况，降低能源消耗并减少环境污染。

2 车路协同关键技术的研究现状

车路协同关键技术通常可分为4个部分：融合感知、驾驶认知、自主决策和协同控制^[5]。这4个关键技术相互协作，为实现智能驾驶和道路协同管理提供强有力的支持。本章分别对这4个关键技术进行详细介绍，各部分的主要研究内容如图3所示。

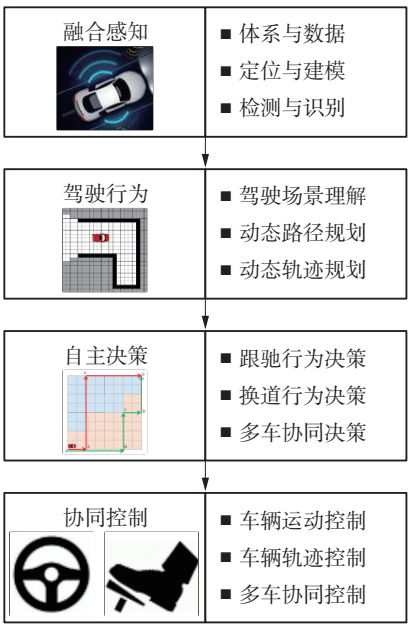


图3 车路协同各关键技术及主要研究内容

Fig. 3 Key technologies and main research contents in CVIS

2.1 融合感知技术

融合感知技术是车路协同系统中获取和处理环境信息的基础。该技术采用多种传感器(如雷达、激光雷达、摄像头等)对车辆周围环境进行感知，

实现对交通参与者、道路条件和交通信号等信息的实时捕获和处理。通过融合多源信息，融合感知技术为后续的驾驶认知和自主决策提供精确的输入数据。该部分的主要研究内容包含感知体系与数据、融合定位与建模以及融合检测与识别。

2.1.1 感知体系与数据

车路协同感知体系是基于车辆对一切通信(C-V2X)的数据传输技术构建的。它通过协同工作的车载设备、路侧设备以及其他传感器收集、分析和共享信息，以实现对交通环境的全面感知。尽管传统的智能交通系统已利用视频、雷达等检测器对交通参数进行检测，但这些方法难以迅速、全面地掌握动态交通环境。相较之下，车路协同融合感知系统在现有智能交通感知设备的基础上，整合了更加精确的路侧感知设备、车载感知设备以及5G大数据技术，能够实现对车辆周围环境的高精度感知。

车路协同感知体系与传统的智能交通感知系统相比，有显著的优势。智能交通感知系统通常依赖于车载设备和传感器获取车辆和路况信息，而车路协同感知体系则通过整合精确的路侧感知设备、车载感知设备以及5G大数据技术，实现对车辆周围环境的高精度感知。路侧感知设备主要包括激光雷达、毫米波雷达和摄像头，车载感知设备则包括传感器和自动驾驶车辆能获取到的参数，这些数据经路侧单元实时传输至边缘计算节点。通过这一体系，能有效应对道路交通环境的复杂性和多变性，为实现高效、安全的道路交通提供坚实保障。图4展示了车路协同融合感知的体系架构。




图4 车路协同融合感知的体系架构
Fig. 4 Architecture of the fusion perception system in CVIS

在车路协同感知体系中，数据融合方法一般可分为3类：前融合、中间融合和后融合，分别也被称为数据级融合、特征级融合和决策级融合^[8]。有许多学者分别对3种融合方式进行了尝试，并总结了各种方式的优劣。其中，特征级融合常用的方法包括贝叶斯模型、聚类模型和D-S方法等。这些方法首先对需要融合的数据进行特征提取，然后进行

分析融合处理，最后将融合后的信息进行压缩并统计分类，但当存在多个同类传感器或多个同质的辅助检测目标时，其精确度较低。另外，决策级融合属于3种融合方法的最高阶段，其成本较低且稳定性较强，充分整合了每个感知单元，如基于车路协同融合感知的OBU和RSU等进行初步融合决策，并根据融合规则将全方位的感知信息进行深度融合。例如，Kim等^[9]设计了一种决策级融合模型，通过将图像和点云的两个数据分支单元基于提取的区域建议进行融合回归，最后生成目标检测框。然而，多感知单元的通信延时较大且多目标融合时的计算量巨大，这可能导致目标位置存在时延内的误差。

另一方面，车路协同技术的发展需要大量的数据支持，以保证感知信息的准确性和完整性。这些数据可以应用于车辆控制、路况分析、路径规划、交通拥堵预测和智能交通管理等领域的研究。为此，建立和开放高质量的车路协同数据集非常重要，这可以为算法的训练和验证提供充足的数据支持，并促进学术界和产业界的技术创新和发展，提高车路协同系统的效率和安全性。

目前，国内外已经建立了许多车路协同相关的数据集，如Waymo Open、KITTI、ApolloScape、nuScenes和Lyft L5等。通过安装在车辆上的传感器可以采集车端数据，包括车辆周围环境的三维点云、图像与物体检测信息等。然而，由于车载传感器存在遮挡盲区且中远距离感知不稳定，这会阻碍自动驾驶系统的完善和落地应用。为了更好地理解道路环境，可以通过路侧设施和交通信号灯等设备来补充路端数据(如交通流量、车速和排队长度等)并提供给车辆。此外，路侧设施还可以采集周边车辆的数据，如车辆型号、速度和位置等信息，并通过车路协同系统发送给车端。

然而，现有的路侧智能系统还无法全面满足自动驾驶车辆在各种复杂场景下的需求。鉴于此，建立高质量的车路协同数据集是一项紧迫的需求，但目前融合车端和路端信息的数据集仍然十分匮乏，2022年才由清华大学智能产业研究院推出全球首个车路协同自动驾驶数据集——DAIR-V2X。该数据集包含融合后的车端和路端数据，可以用于车端、路端和车路协同的3D检测以及车路协同轨迹预测等相关研究^[10]。

2.1.2 融合定位与建模

在自动驾驶汽车的感知系统中，传感器数据的

准确性和实时性对车辆的安全性和可靠性具有举足轻重的影响。融合定位技术通过整合不同传感器收集的数据,提高了感知系统的精确度和鲁棒性,对于实现高精度的车辆定位和路径规划具有重大意义。目前,自动驾驶汽车的定位方法主要有激光雷达定位、激光雷达与摄像头融合定位以及摄像头定位等。

其中,基于激光雷达的定位使用三维点云地图和激光雷达数据来估计车辆的位置。通过对三维点云地图和激光雷达数据的匹配,可以计算出车辆在地图中的位置,这种方法具有较高的精度和稳定性,可以有效应对各种道路和天气条件。例如,Veronese 等^[11]提出了一种基于 MCL 算法的定位方法,其横、纵向位置误差均小于 30 cm。另外,基于激光雷达和摄像头的融合定位方式通过激光雷达数据建立地图,并利用摄像头数据估计车辆相对于地图的位置。例如,Xu 等^[12]提出了一种立体图像与三维点云地图配准的定位策略,将车载摄像头捕获的图像与从 3D 点云地图中提取的图像进行对比,从而估算出汽车的位置。再有,基于摄像头的定位方式是一种主要依靠图像数据来定位车辆的方式。例如,Brubaker 等^[13]提出了一种基于视距和道路地图的定位方法,利用 OpenStreetMap 建立了一个概率模型,实现了汽车在图形中的精确定位。

尽管车载传感器在自动驾驶汽车的定位中起了关键作用,但由于它们容易受到遮挡、信号干扰和网络传输等因素的限制,仅依赖车辆传感器进行定位存在一定的局限性。因此,为了提高自动驾驶汽车的定位精度和鲁棒性,我们通常需要将车端信息与路侧信息结合起来,实现车路协同融合定位。在这种定位模式下,离线高精度地图和道路建模可以提供更精确的地理信息和道路情况信息,从而实现更准确的定位。

离线高精度地图可以通过地图匹配的方式解决传统 GPS 定位不准确的问题,从而将车辆精确地定位在道路上。除了提供道路信息,离线高精度地图还包含障碍物地图子系统,当车载传感器无法感知全方位的信息时,该子系统辅助车辆感知周围环境,并为传感器无法探测到的部分提供补充信息,实现实时状态监测和外部信息反馈。此外,在路径规划方面,高精度地图还能自动驾驶车辆提供最新的路况信息,帮助车辆制定最佳路径。障碍物地图还包含相关信息,对无法导航到的位置进行区分,并将自由空间与占用空间区分开来,以确保汽

车始终在安全区域内行驶。

道路地图子系统主要包括地图表示和地图创建两部分,它负责收集道路和车道信息,并在地图中进行表示。地图表示通常分为度量地图和拓扑地图:度量地图以网格图形式简化地图表示,而拓扑地图则采用图形模型描述环境,包含复杂的道路信息,如多车道、交叉口和合并区域。创建道路地图的方法包括手动注释和自动生成:手动注释方法从卫星图像中提取道路形状,但可能存在全局定位不准确的问题;自动生成方法则通过技术手段从卫星图像中提取道路信息。有学者如 Carneiro 等^[14]使用深度神经网络来推断车辆在水平信号不良或无水平信号的车道中的位置和相关特性。为了解析道路分割、提取拓扑结构和构建路线图,Bastani 等^[15]提出了道路追踪方法,利用此方法进行的逐点匹配检验平均误差仅为 5%。

2.1.3 融合检测与识别

由于车载传感器在环境感知能力上存在局限性,自动驾驶车辆在高速行驶、恶劣天气(如雨、雪、雾、强光等)以及隧道、桥梁等特殊场景中会面临较大的挑战,可能难以在有限时间内做出准确的决策。此外,在交通场景中,单车自动驾驶车辆可能遇到“视觉盲区”,例如被大型车辆遮挡、转弯时被建筑物遮挡以及突然出现的行人等。为解决这些问题,车路协同方案可以提供“超视距感知”,通过路侧感知设备将数据实时传输至边缘计算单元处理,并通过路侧智能终端传输给过往车辆和行人,以确保道路交通安全。这种多源数据融合感知策略有助于提高自动驾驶车辆在复杂场景中的安全性和可靠性。

多源数据融合的基本原理类似于大脑对外界环境信息的综合处理过程。人类通过视觉、听觉等系统感知外界的环境信息,将信息传递给前额叶皮层、运动皮层、小脑等进行行为决策,然后根据决策信息和综合认知对正在发生的事情做出快速准确的评估和行动。同样地,多源数据融合是一个多层面的处理过程,对来自多个感知设备的数据进行自动检测、关联和估计。根据系统的成本、安全性和可维护性等需求以及环境因素,车路协同的多源数据融合体系架构可以分为分布式、集中式和混合式^[16]。

利用车路协同的多源融合感知,车辆可以更准确地检测和识别交通信息。在交通灯检测与识别的任务中,端到端(无需人为制作特征)的方法受到了

研究者的青睐。例如, Fernandes等^[17]利用GPS数据和红绿灯位置数据来识别图像中的区域, 并采用卷积神经网络(CNN)来识别红绿灯状态。此外, 通用物体检测器也已成功应用于红绿灯检测, 相比于基于模型的方法, 这些深度检测器通常在过曝、颜色失真和遮挡等方面表现得更为稳定。例如, Jensen等^[18]将YOLO应用于LISA数据集, 当使用LISA训练集时实现了90.49%的准确度。然而, 目前采用深度学习的方法需要大量带有标签的数据, 未来的研究重点是探索如何利用大型带注释数据库提高深度学习方法的性能, 并克服过曝、颜色失真和遮挡等问题。

在车路协同中, 准确检测和识别交通标志和标线也是至关重要的。然而, 由于缺乏广泛使用的数据库和对研究人员应关注哪些标志的共识, 大多数研究都只考虑单一类型的路面标志。有些研究者通过融合车端与路端信息, 并利用CNN进行识别。针对车道线检测, Gurchian等^[19]将横向距离估计建模为分类问题, 使用CNN实现了亚厘米精度检测。同时, 许多基于几何和光度特征的车道检测方法也被尝试用于交通标志检测^[20]。在道路标志检测与识别方法中, 反向透视映射得到了广泛应用, 因为它能减少透视效应, 从而提升结果的准确性。对于交叉口行人检测, 大多数行人横道检测方法是利用横道的规则形状和黑白图案^[21]。然而, Berriel等^[22]提出了一种基于深度学习的系统来检测图像中人行横道的存在, 并提供了可直接应用于这项任务的预训练模型。针对特定类型的道路标志, 研究人员还采用了其他技术, 如最大稳定极值区域, 以开发特定的检测和识别方法。

为了满足车路协同在实际应用中不断增长的需求, 未来融合感知的研究还需要继续提高检测和识别的准确性和实时性。通过优化多源融合感知技术, 为自动驾驶系统提供更可靠的交通信息, 从而提高道路交通安全性。

2.2 驾驶认知技术

驾驶认知技术对融合感知模块收集到的数据进行深入理解和解释, 包括识别行驶环境中的重要对象和事件、预测其他交通参与者的行为以及评估可能的风险和机会。驾驶认知技术还能整合场景理解和融合定位的结果规划最优路径, 为自主决策和协同控制提供准确的环境分析和理解。该部分的主要研究内容包含驾驶场景理解、车辆动态路径规划以及车辆动态轨迹规划。

2.2.1 驾驶场景理解

车路协同的基本要求之一是使车辆充分了解其周围环境, 尤其是在复杂的交通场景中。因此, 驾驶场景理解的重要性不言而喻, 它涉及的子任务包括场景分类、关键场景定义和驾驶风格识别等。这些任务的联合建模能够帮助揭示场景中不同元素之间的复杂联系, 从而获得对场景的全面理解。

场景理解的关键是获得一个充分且紧凑的场景表示, 这需要提供场景的所有元素, 如交通环境、交通参与者及其相互关系等。Menzel等^[23]将场景表示分为3个抽象层次: 功能场景(描述场景的功能, 例如是一个交叉口或者停车场)、逻辑场景(描述场景中的元素及其关系)和具体场景(描述场景的具体视觉特征)。

关键场景, 有时也被称为边缘情况或角落情况, 通常指的是那些在驾驶过程中可能带来潜在风险的场景。根据ISO 26262, 场景的风险性是根据场景发生的可能性和随之产生危害的严重程度来评估的。在此背景下, 将所有可能导致危害的场景视为关键场景。为了识别这些场景, 可以参照ISO/PAS 21448的标准。为了应对未知的关键场景, 场景条件通常被建模为多个影响场景因素的组合, 这样未知的关键场景也可以由不同的场景因素进行组合, 以最大限度地减少未知关键场景的数量。

驾驶风格识别在驾驶行为理解中起着重要的作用。车路协同系统能够根据不同的驾驶风格进行调整, 从而提高道路交通安全性。特别是在自动驾驶汽车与其他驾驶员驾驶的车辆共同行驶时, 驾驶风格的差异可能导致安全隐患。因此, 车辆需要通过驾驶风格识别来准确预测其他车辆的行为, 以确保安全行驶。驾驶风格的定义在不同的文献中略有不同, 但通常是根据驾驶的攻击性或油耗等指标进行分类。例如, Murphey等^[24]提出了一个基于规则的模型, 通过一系列的规则和触发阈值来判断驾驶行为是激进还是平稳。

在传统的驾驶风格识别方法中, 驾驶风格的类别和含义通常是预定义的, 大多数文献使用两个或三个类别。然而, 近年来, 随着基于机器学习的方法在驾驶风格识别中的广泛应用, 数据驱动的驾驶风格识别逐渐成为主流。例如, Constantinescu等^[25]采用主成分分析进行无监督学习, 成功地检测出了5种不同的驾驶类别。Bolovinou等^[26]对汽车的跟随行为和踏板操作行为进行了研究, 并提出了基于高

斯混合模型的驾驶风格识别模型，用于电动汽车的行驶里程预测。Yurtsever 等^[27]使用堆叠式自编码器提取不同驾驶员的驾驶特征，然后通过聚类找到驾驶风格的中心。同样，Sama 等^[28]使用另一个自动编码器网络提取了在不同道路类型上的特定驾驶特征。尽管在驾驶风格识别领域已经取得了一些进展，但是我们仍然需要继续探索和优化这些技术，以便更好地应用到实际的自动驾驶系统和车路协同环境中，提供更加安全、有效和顺畅的道路交通体验。

2.2.2 车辆动态路径规划

在车路协同环境下，智能网联车辆通过应用定位和导航技术，获取从当前位置到目标位置的全局最优路径，同时，通过感知周围环境的信息，互动生成局部最优路径。因此，车辆路径规划在车路协同中的主要任务就是寻找一系列满足空间要求的路

径点，从而构建车辆可以行驶的路径。在确定车辆起始位置和目标位置后，车路协同系统基于全局地图定位，为智能网联车辆制定多个可选的全局路径。与此同时，借助车路协同云端信息，车路协同系统能获取不同路径下的实时道路数据。对于智能网联车辆的微观行为决策，例如换道、交叉口左转和环岛跟车等，车辆可以通过感知信息和路径规划算法，在局部地图环境下实现路径规划，从而避开行驶过程中的交通障碍物。目前的研究表明，在车辆动态路径规划领域，其主要目标在于规划车辆在空间序列上的行驶路径，其方法可以大致分类为传统方法和机器学习方法。传统方法主要包括图搜索法、曲线插值法、人工势场法和群体智能优化法等；而机器学习方法则主要包括直接策略学习法、强化学习法、并行学习法等。各方法的优缺点如表 1 所示。

表 1 车辆路径规划方法的优缺点
Table 1 Advantages and disadvantages of vehicle path planning methods

算法类别	算法名称	优点	缺点
传统算法	图搜索法	适合全局路径规划	环境建模复杂,算法收敛速度慢
	曲线插值法	规划的路径较平滑且曲率连续	评价函数的求解速度较慢
	人工势场法	规划的路径平滑且安全	易陷入局部最优,难以描述复杂环境
	群体智能优化法	寻找全局最优的能力强	收敛速度慢,易陷入局部最优
机器学习算法	直接策略学习法	可缓解数据不足导致的各类限制,可修复当前错误	查询效率低,数据收集器不准确,泛化能力较差
	强化学习法	可从反馈中进行连续学习和优化,生成能够适应复杂环境的路径规划策略	需要大量的计算资源和训练时间
	并行学习法	能在虚拟和真实环境中同时进行学习,学习效率高,决策速度快	需要复杂的计算架构和算法设计

在传统方法中，图搜索法是在图中搜索路径的算法类别，常用于移动机器人领域的路径规划，并已逐步应用于自动驾驶领域。这类算法能够在图中找到从车辆起点到终点的一条路径，或者在图中找到满足特定条件的所有路径。常见的图搜索算法包括深度优先搜索、广度优先搜索、Dijkstra 算法和 A* 算法等，这些算法具有不同特点和适用场景，选择合适的算法可以提高搜索效率。深度优先搜索和广度优先搜索是最基础的图搜索算法，其他算法在它们的基础上发展而来。以动态路径规划中的 D* 算法为例，其是一种增量式路径规划算法，采用从目标位置向起始位置的反向搜索策略。智能网联车辆首先基于当前交通状态信息确定部分道路情况，对于未知的交通状况进行假设，并在这些假设下规划当前位置到目标位置的最短路径。当行进过程中首次规划的路径被动态障碍阻塞（即地图信息

发生了动态更新）时，车辆将基于 V2X 通信重新更新路况信息。由于后续各节点到目标点的最短路径未受影响，只需在障碍物附近重新规划并更新起点到障碍处各节点的信息，当路径绕过障碍后，车辆即可重新利用先前规划的最短路径。

曲线插值法是一种数学方法，用于生成平滑、连续的车辆行驶路径。该方法基于车辆运动学和控制理论，利用已知的车辆位置和姿态信息，通过数学插值对车辆轨迹进行预测和规划，从而生成符合车辆控制要求的平滑轨迹。具体来说，曲线插值法首先将已知的车辆位置和姿态信息离散化为一系列路径点，然后使用插值算法在这些路径点之间生成连续的曲线。插值算法的选择通常取决于车辆行驶环境和要求，常见的算法包括贝塞尔曲线和 B 样条曲线等。

人工势场法是一种基于物理学势能原理的路径

规划算法。在人工定义的势场中,车辆被视为一个粒子,并受到引力和斥力两种类型的力的作用。引力来自车辆与目标位置之间的势能,斥力来自车辆与周围环境中障碍物之间的势能。在引力和斥力的合力作用下,车辆沿着梯度下降的方向,最小化车辆与目标位置和障碍物之间的总势能。目前,人工势能法不仅能应用于车辆的局部路径规划,还能应用于车辆的速度规划。

群体智能优化法是一类模拟生物学启发式的方法,具有一定的随机性和特定性,广泛应用于全局路径规划,并搜索全局地图下车辆避障的最短路径。常见的算法包括蚁群算法、鱼群算法和遗传算法等。这些算法通过模拟动物群体的觅食行为,使群体中个体能学习自身经验与其他成员的经验来不断改变路径方向。

然而,传统的路径规划方法尽管在一些应用场景中已经取得了显著的效果,但在处理复杂的、动态的和不确定交通环境时仍然面临一些挑战。为了解决这些挑战,近年来,研究者开始探索将机器学习方法应用于车辆路径规划中。其中,直接策略学习在车辆路径规划中发挥着关键作用,它是一种基于行为克隆的训练方法,通过评估当前策略并使用更合适的训练数据进行自优化。其主要优势在于可缓解由于数据不足导致的各类限制。在直接策略学习的发展历程中,Ross等^[29]提出的数据集聚合(DAgger)方法被广泛引用。DAgger是一种基于跟驰算法的主动学习方法,但可能会由于策略空间和学习空间之间的距离过大而在学习效率上受到限制。为解决这一问题,He等^[30]进一步提出了DAgger by Coaching算法,通过设定一个指导策略提供易于学习的路径,随后逐渐收敛至目标。这个“指导策略”虽然提升效果有限,但比一般的DAgger方法有所改进。Zhang等^[31]提出了SafeDAgger算法,提高了DAgger的查询效率并降低了对标签准确性的依赖。另一方面,Hoque等^[32]提出了ThriftyDAgger模型,集成了人类对边角情况的反馈。同样,Yan等^[33]也为无地图场景下的导航任务提出了一种新的训练方案,提高了模型的泛化能力和鲁棒性,进一步推动了直接策略学习在车辆路径规划中的应用。

强化学习在车辆路径规划中也表现出了显著的潜力。为了应对拥堵道路上自动驾驶的挑战,Ye等^[34]通过采用近端策略优化方法,以自车及其周围车辆的状态为输入,使智能体学会根据即时状

态进行路径规划。然而,从头开始训练强化学习策略通常十分困难,结合模仿学习和课程学习等方法,可能为训练提供有效的解决方案。Wu等^[35]将模仿学习与深度确定性策略梯度方法结合,引入一个可调节的门控机制,选择性地激活四个不同的控制信号,使得模型可以由中央控制信号进行控制,提高了连续空间探索的效率。为了解决学习效率的限制,Huang等^[36]设计了一种新方法,将人类的先验知识引入到强化学习方法中,可以提升车辆路径规划的表现。

然而,无论是传统方法还是直接策略学习或是强化学习方法均存在计算效率低、泛化能力弱或计算资源需求量大等问题,并行计算的方法能提供有效的解决方案。作为并行驱动实现的具体例子,Chen等^[37]提出了一个端到端的并行规划框架,专门设计了两种方法,用于处理特定场景中的应急规划问题。针对数据稀缺问题,利用人工交通场景并借助现实预训练知识生成特定路径。针对非鲁棒性问题,利用变分自动编码器(VAE)和生成对抗网络(GAN)从人工交通场景生成的虚拟紧急情况进行学习。对于学习效率低下的问题,采用并行规划的方式,从虚拟和真实场景中同时学习策略,并通过分析真实观察结果来确定最终决策。当出现紧急情况时,并行规划方法能够在无需大量计算负担的情况下,做出合理的决策。这些方法利用并行计算的优势,实现了从虚拟和真实场景中同时学习,通过快速分析真实观察结果进行决策,在处理紧急规划问题时具有显著的优势。

2.2.3 车辆动态轨迹规划

动态轨迹规划是在局部路径规划的基础上,根据车辆的横纵向运动学模型、动力学模型以及交通环境信息等因素,规划出车辆从当前状态到下一目标状态的运动轨迹。这其中,车辆的状态信息包括速度、加速度以及转向等时间函数。当车辆的路径点信息加入了相应的时间约束后,这些点便可称为轨迹点。当轨迹点满足车辆的运动学和动力学约束时,即可实现车路协同中车辆的轨迹规划。相较于路径规划仅生成满足车辆和道路空间约束条件的几何曲线,轨迹规划不能忽略与时间相关的约束条件,因此具有更高的难度和丰富性。

通常,智能网联车辆接收的是路径规划信息,而轨迹规划被分解为路径规划与运动配时两阶段。这意味着规划模块首先为车辆生成满足空间约束的几何运动曲线,然后为该运动曲线规划相应的行驶

速度和加速度。针对轨迹规划的时空性特点，车路协同中车辆的轨迹规划方法可分为采样方法、曲线插值法、数值优化法和深度强化学习法等，各方法的优缺点如表 2 所示。

表 2 车辆轨迹规划方法的优缺点
Table 2 Advantages and disadvantages of vehicle trajectory planning methods

算法	优点	缺点
采样方法	适用于高维度非线性问题,不需全局信息和先验知识	需大量采样点,其数量和质量对结果影响大,计算成本高
曲线插值法	可调整路径的形状,计算成本低,适用于实时规划	难处理复杂环境下的规划,依赖初始路径,易出现局部最优解
数值优化法	可处理复杂环境下的路径规划问题,并满足特定需求	计算成本高,不适用于实时规划,对初值的选择较敏感
深度强化学习法	可适应多种环境和任务,结合传感器信息和周围环境来进行规划	需大量数据和计算资源,会出现数据偏差和模型不可解释等问题

采样方法是指在规划空间内获取一组有限的离散点，以实现车辆从当前状态到下一个目标状态的连接。这些离散点通常称为“采样点”或“采样集合”，代表车辆在规划空间中的可能位置。通过特定的采样策略计算每一时刻下车辆的具体位置和速度状态，可以串联得到安全、有效的行驶轨迹。采样方法可分为随机采样和固定采样。常见的随机采样方法如快速搜索随机树算法的基本思路是：从车辆的起始点出发，不断扩展树形结构，在规划空间中通过随机函数采样并生成随机节点；经过碰撞检测后，选择是否将新节点连接到已有的树中，最终在多次探索与扩展下得到完整轨迹。固定采样则是根据特定的规则生成一系列待选采样点，并通过指标筛选得到其中质量最佳的轨迹采样点。由于规则设定的不同，不同研究中的固定采样方法也不尽相同。例如，郭奕瑾等^[38]将泊车中的轨迹规划问题解耦为路径规划和速度规划，提出了改进动态窗口的方法，并根据“绕墙走”策略生成了车辆的垂直泊车轨迹。

在车辆轨迹规划中，曲线插值法与路径规划中的方法相似，通过为相关曲线添加时间维度和速度维度的约束，以获取车辆在不同时刻下的运动姿态。除了路径规划中的插值曲线外，常见用于轨迹规划的插值曲线为多项式曲线。其中，不同项次的多项式可以表征车辆不同的运动约束，三次多项式最高可以对车辆速度进行约束，而五次多项式能进一步规划车辆加速度。项次的增加代表约束的精准性，但也加大了求解的复杂性。目前，主流曲线插值下的轨迹方法以五次多项式为主^[39]。但由于车辆纵向规划在空间和速度上比横向规划更具不确定性，越来越多的研究开始采用六次多项式来描述车辆的纵向轨迹规划行为^[40]。

数值优化方法通过构建车辆的运动学和动力学

约束以及环境约束条件，将车辆的轨迹规划问题近似成动态优化问题，并搜索车辆在可行域内的全局最优轨迹，从而将约束变量的函数最小化或最大化。车辆轨迹规划中常见的数值优化方法包括非线性规划和二次规划等。需要注意的是，在实际的自动驾驶场景中，通常需要考虑多个约束条件，如障碍物避障、速度限制和安全距离等。因此，综合考虑不同的数值优化方法，设计适合实际应用的轨迹规划算法是一个重要的研究方向。

此外，许多研究人员提出了基于深度强化学习的方法来进行车辆轨迹规划，其中，CNN 和循环神经网络(RNN)是两种最广泛使用的方法。近年来，许多学者基于 CNN 和 RNN 来提升车辆动态轨迹规划的性能。其中，ARNN^[41]是对原始 RNN 的改进模型，它通过结合自注意机制，进一步获取轨迹数据中的长期依赖性，利用历史轨迹信息和当前交通状态之间的交互来提高预测性能；S2TNet^[42]则利用多头注意力机制将历史轨迹的空间和时间特征融合在一起，取得了一定程度的提升。车辆轨迹规划本质上是一项时间序列预测任务，所以许多学者采用递归神经网络及其变体——长短时记忆(LSTM)进行预测。其中，为了获取车辆运动的顺序特征，Mo 等^[43]基于动态的 3×3 网格，提出了一个 CNN 和 LSTM 结合的交互提取器，以全面地表示车辆之间的影响。

然而，以上方法对几何结构的表示能力有限，不能全面地描绘车辆间的复杂关系。因此，越来越多的研究开始利用图神经网络(GNN)来解决这个问题。其中，Chandra 等^[44]结合 GNN 与 LSTM 来获取车辆的时空运动模式，基于光谱正则化，模式的融合可转化为车辆未来的轨迹；SCALE-Net^[45]设计了一种可增强图之间边的注意力机制，为不同的车辆分配不同权重，整合特征并预测车辆轨迹；Gao 等^[46]

提出了一个新的层次框架来放大交互建模,第1层由多个子图组成,每个子图对应一辆特定的车,第2层将所有子图结合起来,并通过1个全连接图来表示相互依赖性。在最近的研究中,Lu等^[47]研究了车辆历史轨迹和驾驶环境中固有环境之间的关系,提出了一种基于深度学习的架构来强调车辆流动性的时空表示和预测。

2.3 自主决策技术

车路协同中的自主决策技术是感知和规划模块之间的桥梁,其基于融合感知和驾驶认知技术获取数据,利用人工智能和机器学习等先进算法,综合考虑车辆行驶状态、交通环境和驾驶员意图等因素,为车辆制定合适的驾驶策略。通过自主决策技术,车辆可以实现自主避障、自适应巡航与自动泊车等功能,从而提高道路交通安全性和效率。该部分的主要研究内容包含车辆跟驰行为决策、车辆换道行为决策以及多车协同决策。

2.3.1 车辆跟驰行为决策

跟驰行为作为车辆最基本的驾驶行为,一直是微观交通流领域内的研究重点。跟驰指的是车辆在道路上行驶时,根据同一车道内前方车辆的位置和速度等信息调整自身的速度,以保持与前方车辆的安全距离,实现安全、平稳且高效的车流。具体而言,车路协同中的跟驰行为需要考虑以下几个方面:前方车辆的位置、速度、加速度以及安全距离和状态反馈。在车路协同环境下,各车辆会将自身的数据上传至车路信息融合云控中心,同时路侧单元会收集并上传当前道路的车流信号数据,实现车流队列的决策引导。以图5所示的车辆协同跟驰场景为例,跟驰队列中的车辆信息通过自身的云服务与路侧单元进行交互,将车辆数据与道路数据上传至云控中心,进而针对跟驰队列进行决策引导。

许多学者对车辆微观行为决策进行了深入研究。贾洪飞等^[48]首先采用人工神经网络构建了车辆的跟驰模型,并对车辆的跟驰行为决策(加速或减速或无动作)进行输出。随后,Chen等^[49]基于CNN提出了一种端到端的车道保持模型,该模型使用Comma AI数据集进行训练和评估,通过前视图像帧和在道路上行驶时捕获的转向角数据来实现车辆的车道保持功能。Ye等^[50]提出了一个基于深度强化学习的车辆决策培训和学习框架,并在虚拟仿真场景中验证了车辆跟驰效率的提高。此外,Yu等^[51]提出了利用多智能体强化学习技术来解决车路协同环境下自动驾驶车辆的协调问题,将协调问题视作




图5 车辆协同跟驰场景

Fig. 5 Cooperative car-following scenario

一个分解的马尔可夫决策过程问题,实现了高速公路自动驾驶车辆队列跟随和超车的决策建模。Gao等^[52]提出了一个奖励函数矩阵用于训练各种决策模式,通过图形模型对交通场景进行建模,表示车辆之间的交互,并采用图形卷积网络提取图形结构特征,以帮助自动驾驶车辆直接执行决策。Dai等^[53]基于马尔可夫博弈和最佳响应动力学,提出了一个多智能体计算框架,并对智能车辆的微观决策和战略交互进行了建模,从而更有效地模拟人类驾驶行为。

在车路协同系统中,用于车辆跟驰行为决策的两种经典算法分别是深度Q网络(DQN)和深度确定性策略梯度算法(DDPG)。这两种算法在车路协同中具有广泛的应用和研究价值。首先,DQN是一种结合深度学习和Q学习的强化学习算法。它利用深度神经网络作为函数逼近器,用于估计状态-动作对的Q值。通过不断更新网络权重,DQN能够学习到一个策略,从而指导车辆在复杂的道路环境中做出合理的跟驰行为决策。例如,Chae等^[54]提出了一种基于深度Q网络的自动制动决策系统,旨在避免车辆与行人之间的碰撞。然而,DDPG是一种连续动作空间中的强化学习算法,它采用了确定性策略梯度方法,通过深度神经网络学习一个连续的动作值函数^[55]。DDPG使用了两个网络,一个是用于估计状态-动作对的Q值的评价网络,另一个是用于生成确定性策略的行动网络。通过协同训练这两个网络,DDPG能够在连续动作空间中高效地学习一个优化策略,从而为车辆跟驰行为提供精确的决策依据。

近年来,随着自动驾驶车辆在部分地区的投入运行,已经可以预见到在未来一段时间里,自动驾

驶车辆与人工驾驶车辆将会长期共存。然而，由于自动驾驶车辆和人工驾驶车辆在行为决策上存在显著差异，混合交通环境下的车辆跟驰决策问题值得深入研究。一方面，一些学者通过仿真或数值模拟的方式来开展研究，例如 Wang 等^[56]利用最优控制策略研究了混合交通流中的车辆跟驰决策，尤其是车辆在匝道区试图合流时的跟驰问题；Ma 等^[57]考虑到了车辆的运动状态、混合比例、最大速度和长度等因素对车辆排放的影响，运用混合交通流模型进行了排放研究，结果显示，在不同的交通状态下，跟驰决策会对排放产生显著影响。此外，Papadoulis 等^[58]通过在 VISSIM 中开发一个决策型的控制逻辑，分析了混合交通流中加入自动驾驶车辆的效果；Zheng 等^[59]考虑了人工驾驶车辆的随机行为和自动驾驶车辆的确定性行为，提出了随机 Lagrangian 模型来评估混合交通流中人工驾驶车辆和自动驾驶车辆之间的交互。另一方面，也有研究采用了现场实验的方法，例如 Rahmati 等^[60]招募了 9 名驾驶员，提取到了人工驾驶车辆跟随自动驾驶车辆和人工驾驶车辆跟随人工驾驶车辆场景之间的差异。实验结果表明，当驾驶员跟随自动驾驶车辆时，其驾驶行为更加平稳；但 Zhao 等^[61]的研究却发现如果无法在外观上区分自动驾驶车辆和人工驾驶车辆，驾驶员对前方自动驾驶车辆的反应是由其对自动驾驶技术的信任程度决定的。

然而，对于仿真或数值模拟的方式，复杂的交通流和随机的驾驶行为可能会被简化，而现场测试的方法通常在专用测试场地进行，招募的驾驶员数量有限，无法模拟复杂的混合交通流，这些因素都会对实验结果产生影响。一些最新的研究正在致力于解决这些问题，如 Wen 等^[62]就从驾驶波动性、车头时距和碰撞时间等方面研究了自动驾驶车辆与人工驾驶车辆在跟驰中的不同特性，并开发了一个框架，以全面理解自动驾驶车辆典型的跟驰风格。

2.3.2 车辆换道行为决策

换道行为相较于跟驰行为更为复杂和多变，因为换道过程中需要考虑车辆的横向运动，涉及到多车道和多车之间的交互^[63]。换道场景可以根据驾驶员的需求和交通条件分为自由换道和强制换道。自由换道是驾驶员主动选择的换道行为，以提高行驶效率或满足个人偏好，例如超车；强制换道则是驾驶员为遵守交通规则或应对紧急情况而被动进行的换道行为，例如车道合流。车辆换道决策目的是为单车道或相邻两车道的换道行为制定一个或多个

参考轨迹，以实现安全驾驶并降低燃油消耗等。如图 6 的车辆换道决策场景所示，自动驾驶车辆在混合交通道路环境中换道时，需要通过 V2I 和 V2V 通信与路侧单元和周围车辆实现信息交互，从而对当前车道和目标车道的交通状态做出精确判断，并做出安全有效的换道决策。车辆换道决策方法主要可以分为 4 种：基于搜索的换道决策、基于特定函数的换道决策、基于人工势场的换道决策和基于深度学习的换道决策。这些方法在不同场景下具有各自的优势，为实现安全、高效的换道行为提供了多种途径。




图 6 车辆换道决策场景

Fig. 6 Vehicle lane-changing decision scenario

其中，在低速行驶的条件下，基于搜索的轨迹规划方法对于规划车辆换道轨迹十分有效。例如，Lan 等^[64]设计了一种依赖于快速扩展随机树的智能网联车辆换道轨迹规划模型，而 Yang 等^[65]应用改进的 Dijkstra 算法确定了最佳换道路径。其次，基于特定函数的轨迹规划方法在移动障碍环境中得到了广泛应用，它将换道问题转换为相应的约束优化问题。例如，Luo 等^[66]对智能网联车辆的换道问题进行了约束优化处理。另外，人工势场法通过为障碍物、道路结构和目标点分配合适的势场函数来实现车辆换道轨迹规划。例如，Huang 等^[67]利用人工势场法描述了车辆与周围环境的互动和协同特性，而 Xu 等^[68]则运用这种方法提出了一个驾驶员横向加速度决策模型，以引导换道轨迹规划。

值得重点关注的是车路协同决策中的深度学习方法，Zhang 等^[69]使用人工神经网络模型来捕捉车道变化的复杂性，并利用大量轨迹数据对模型进行了估计和验证。通过对模型的灵敏度分析，定量评估了重型车辆对驾驶员换道决策的影响。Xie 等^[70]采用深度置信网络对换道决策过程进行建模，指出了目标车道前车是影响车辆自主换道的最重要因素。Codevilla 等^[71]则提出了一种有条件的模仿学习方法，将生成的驾驶策略以类人的形式处理，有助

于对导航命令的持续响应做出决策。这些决策方法充分利用了深度学习的显著优势,即直接映射传感器输入和模型输出之间的关系,但深度学习的方法都需要大量的数据进行训练和测试,依赖于丰富的数据信息。

为了解决此问题,一种方法是利用深度强化学习,结合深度学习和强化学习,利用深度神经网络表示策略或值函数,并通过反向传播算法优化目标函数。相比深度学习方法,基于深度强化学习的方法能够减少对大量数据的依赖。这意味着在车路协同环境下,车辆对道路历史数据的需求降低,仅依赖当前实时传输的车路状态信息,就能为车辆快速制定安全有效的决策。Zhao等^[72]通过设置动作集(如换道和加减速等行为)和状态集(包括周围车辆的横纵向位置和速度信息),利用DDQN方法对公路行驶中车辆间的决策和交互进行建模。为了进一步提高驾驶安全性和舒适性,Schulman等^[73]介绍了一种近端策略优化的换道机制,这种创新的方法可以在单车或多辆车上执行,有助于顺利变道。

由于自动驾驶汽车在决策过程中尚未能够完全模仿人类的驾驶思维,在自动驾驶汽车与人工驾驶汽车混行的环境中,换道决策显得尤为重要。Muhammad等^[74]的研究从信息更新的角度考虑了这个问题,构建了一个由基站服务多个实时流量流的无线网络模型,该模型将信息更新发送到目的地,以维持时间关键应用的信息新鲜度,为车辆的换道决策提供了重要的信息支持。另外,Xu等^[75]则尝试从游戏理论的角度出发,模拟自动驾驶汽车的换道决策,将自动驾驶汽车的换道决策视为完全信息下的非合作静态游戏,并建立一种融合驾驶风格的游戏理论换道模型(GLCD模型)。这种模型试图更准确地反映出自动驾驶汽车在混行环境中的换道决策行为,提升其在实际道路交通环境中的行驶安全性和效率。这些研究都展示了在混行交通环境下,深入研究自动驾驶汽车的换道决策的重要性。

2.3.3 多车协同决策

车路协同技术在多车协同决策领域拥有极大的潜力,尤其是通过运用先进的人工智能方法来实现高效的联合决策。多智能体强化学习作为强化学习的一种扩展,为自动驾驶车辆在协作和竞争环境中做出决策提供了一种有效的方法。在这种方法中,车辆被视为具有自主性、互动性和适应性的智能体,能够通过相互作用并根据环境的反馈进行学习。因此,多智能体系统理论可以为车辆间的合作

提供协调机制,从而提高交通流畅性和安全性。

多智能体决策技术在复杂的交通决策环境中被广泛应用,这种方法结合车联网环境中的多车交互,能够做出更加安全高效的决策。当前的研究主要集中在深度强化学习领域,例如Liu等^[76]将图形神经网络与深度强化学习方法相结合,提出了基于图形强化学习的决策模型,并验证了其在匝道环境下的换道决策性能。在车路协同技术的支持下,自动驾驶车辆可以通过V2X通信获取大量实时交通数据,从而进行实时决策。这意味着多智能体决策技术在提高换道行为的决策性能方面具有显著优势。因此,多车协同决策方法在车路协同领域的发展,特别是联合决策的潜力,为实现安全和高效的自动驾驶系统提供了强有力的支持。

在车路协同中,多车协同决策可以分为集中式和分布式两种类型。其中,集中式车辆群体协同决策方法通常面临计算复杂度高的问题。然而,最新研究表明,基于优化的集中式车辆群体协同决策方法能够实现在线计算,同时确保最优解的获得。例如,Pei等^[77]提出了基于动态规划的协同决策方法,有效降低了解空间的规模,并在较短的计算时间内得到了最优解,提高了自动驾驶系统在复杂交通场景中决策的实时性。然而,尽管这些方法可以实现实时计算,但在保证协调效果方面仍存在挑战,特别是在交通需求高的场景中。为了解决这一问题,Li等^[78]在路网通行场景中提出了一种因果环消解规则,但其在提高交通效率和缓解拥堵方面的潜力尚未得到充分发挥。近年来,一些研究者发现,基于启发式算法的集中式车辆群决策的方法可以在较短时间内获得接近全局最优解的结果,有助于更有效地运用车辆群体协同决策机制来改善交通状况。

另一方面,分布式车辆群体协同决策在优化车辆时空轨迹和提高通行效率方面展现出了潜力。对于路口通行场景,部分学者已采用分布式方法构建了最优控制模型以优化车辆的时空轨迹,但提升通行效率仍面临一些挑战。对于路网通行场景,Wang^[79]等将附近冲突区的车辆协同决策问题转化为单一的调度优化问题,从多个角度探讨了车辆协同决策的问题。此外,研究者已经提出了基于启发式的分布式车辆群体协同决策方法,例如Ntousakis等^[80]提出的分布式合流算法保证了车辆的安全汇流,Xu等^[81]则通过基于图结构的方法解决了冲突区的碰撞风险。在路段通行场景中,Ding等^[82]提出了一种分布式决策方法,使车辆能实现自适应巡

航。而在路网通行场景中, Pei 等^[83]提出了一种新型分布式车辆群体协同决策方法, 有效地在协调性能和计算效率之间取得了平衡。

然而, 无论是集中式还是分布式的多车协同决策方法, 在协调多车辆时都可能遇到困难, 可能导致决策不成功。最新的研究表明, 强化学习在多车协同决策方面有巨大潜力, 如编队控制和协同自适应巡航控制(CACC)等策略。例如, Wang 等^[84]提出了一个服务于整个车队的 Eco-CACC 系统, 该系统在 CACC 操作的所有阶段都能最小化能源消耗和污染物排放。同样, Guo 等^[85]提出了一种分布式轨迹优化和控制方法, 利用二次间隔策略和 PID 类型的滑模控制器, 通过数值模拟证明了其能实现稳定的交通流; 还提出了一种基于强化学习的协同纵向控制策略, 以应对不同交通条件下的挑战。

2.4 协同控制技术

协同控制技术通过车辆与其他车辆、基础设施以及云端系统的通信实现整个交通系统的实时监控和优化调度。车辆能够根据实时路况、交通信号和其他交通参与者的行为做出相应的调整, 提高道路通行能力、降低拥堵并减少交通事故。该部分的主要研究内容包含车辆运动控制、车辆轨迹控制以及多车协同控制。

2.4.1 车辆运动控制

在车路协同控制领域, 车辆运动控制的关键任务是根据周围环境、车辆位置、姿态和速度等信息, 遵循特定规则进行决策, 并将控制指令传递给车辆的执行系统。由于参数的不确定性、时延以及高度非线性的动态特性, 智能网联汽车被认为是一个典型的多输入多输出的复杂耦合动力学系统。开发能够处理时延和高度非线性特性的运动控制方法对于实现智能网联汽车的自动驾驶是至关重要的, 并且一直是车路协同研究领域的焦点。

车辆运动控制在车路协同中主要涉及两个方面: 横向控制和纵向控制。横向控制主要关注车辆的路径跟踪能力, 即研究如何让车辆沿预设路线行驶, 同时保证安全、稳定性和舒适度。根据传感器配置的不同, 横向运动控制可分为预瞄式和非预瞄式。而纵向控制专注于车辆的速度控制能力, 通过采用特定控制方法来调整车辆的纵向运动状态。然而, 纯粹的横向和纵向控制各自存在一定的局限性。因此, 考虑到智能车辆横纵向动力学之间的耦合和关联性, 部分研究者已经研究出了车辆横纵向运动综合控制方法, 主要可以分为分解式和集

中式。

分解式协同控制通过解耦横纵向动力学, 分别设计横向和纵向的控制规则, 同时设计用于协调横向与纵向运动的控制逻辑。例如, 针对智能车辆编队行驶中的自动插入和退出控制问题, Rajamani 等^[86]设计了一个包括横向控制器、纵向控制器和监督器的综合横纵向控制系统。在车辆自动驾驶系统的横纵向运动控制研究中, 冀杰等^[87]分别设计了横向和纵向控制的“前馈+反馈”策略, 以及横纵向运动控制执行系统的协调方法。然而, 这种分解式协同控制方法本质上并未克服横纵向动力学的耦合特性, 而只是协调了横纵向控制规则的执行。

相比之下, 集中式协同控制通过直接对车辆横纵向耦合动力学模型进行控制求解, 从而得到横纵向运动的控制规则。Lee 等^[88]采用鲁棒自适应控制理论设计了横纵向运动控制协调算法, 并通过仿真对比实验展示了智能车辆横纵向协同控制的优势。此外, 一些研究人员构建了基于径向基函数神经网络的自适应横纵向协同控制策略, 并通过 Lyapunov 理论分析了该控制系统的稳定性^[89]。为了应对智能网联车辆在非匹配、不确定性和冗余方面的特点, 郭景华等^[90]提出了一种纵横向协调与重构控制方法, 实现了跟踪误差一致有界收敛性的保证。尽管集中式协同控制在理论上具有优势, 但在实际应用中仍面临一定的挑战, 如实时性要求高、计算量大以及对传感器和执行器性能要求较高等。为了更加深入地理解车路协同的动态性和复杂性, 研究人员还在探索更加先进和全面的控制策略, 如深度学习、强化学习和博弈论等, 这些方法有可能在未来更好地解决车路协同中运动控制的难题。

2.4.2 车辆轨迹控制

车辆轨迹控制在车路协同控制领域扮演着关键的角色, 主要任务包括路径稳定和轨迹跟踪控制, 使智能网联汽车能够沿预定的轨迹稳定行驶。路径稳定关注如何在各种驾驶环境下保持车辆沿规划路径的稳定性, 而轨迹跟踪控制则强调通过实时调整车辆状态, 使其准确遵循预定轨迹。为应对复杂的道路环境, 智能网联汽车需实现精确轨迹控制, 因此对控制算法和硬件设备的性能有极高的要求。

基于运动学模型的路径稳定方法提供了多种技术选择, 有助于提升车辆控制性能, 使智能网联汽车能够沿预定路径精确行驶。其中, 纯追踪算法是最早提出的路径跟踪策略之一, 因其实现简单且性

能优越而受到广泛的关注,例如 DARPA 大挑战和城市挑战的参赛车辆都采用了纯追踪器^[91]。此外,后轮反馈控制利用后轮位置作为输出,以实现车辆沿预定的后轮路径稳定行驶。Samson 等^[92]对参考路径和有限域的假设进行了详细描述,为车辆路径稳定提供了有效的解决方案。前轮反馈控制将前轮位置作为控制变量,成功应用在斯坦福大学参加 2005 年 DARPA 大挑战的项目中^[93]。这种方法能够在路径连续可微分的条件下实现车辆在具有可变曲率的路径上的局部指数稳定,但由于其在倒车时的不稳定性,此方法并不适合处理泊车任务。

许多轨迹跟踪的控制方法为车路协同系统中的车辆精确行驶提供了有效的技术支持。例如,Kanayama 等^[94]基于控制李雅普诺夫函数的设计方法在汽车坐标系中定义了跟踪误差,并实现了控制的局部指数稳定性。不久后,有学者利用反推设计方法设计了一款控制器,在具有时变参考的有限域上实现了一致局部指数稳定性,在较高车速情况下表现出了优越性能^[95]。在这种情况下,实现连续转向的约束转向角变得至关重要,但简单几何角度的控制器设计受到附加状态的影响,变得更加困难。因此,输出线性化的系统成为一种理想选择。基于此,Novel 等^[96]简化了反馈线性化的输出,突破了前轮或后轮位置的局限性,为轨迹跟踪控制提供了新的解决方案。

在面对复杂驾驶条件如湿滑道路或紧急机动时,车路协同中的预测控制方法在车辆轨迹控制中显示出显著的优势。模型预测控制作为一种通用的控制设计方法,能够有效处理复杂模型的细节,通过在短时间范围内求解运动规划问题来实现实时控制。随着计算机运算能力和算法的持续升级,预测控制在无人驾驶车辆中已成为可能。汽车控制器文献中涉及的模型预测控制框架的变体主要有 3 种:一是利用运动学模型的无约束模型预测控制,如 Ollero 等^[97]提出的 CARIMA 模型,在没有输入或状态约束的情况下应用模型预测控制框架,所得到的半封闭形式的解具有较低的计算要求;二是路径跟踪控制器,如 Kim 等^[98]基于质心的线性动力学模型和近似转向模型所验证的集成模型;三是轨迹跟踪控制器,例如 Falcone 等^[99]研究的轮胎模型的预测控制器,在仿真中执行了完全非线性预测控制策略,并在结冰条件下以 20 Hz 的控制频率实现了模拟紧急制动的稳定。此外,还通过为时变系统的一致局部渐近稳定性提供条件,改进了该方法的模拟

和实验结果。

2.4.3 多车协同控制

车路协同的显著优势在于,它可以利用 V2X 通信获取外部信息,并通过云控制中心实现多车协同控制,从而显著提高交通流量效率和降低能耗。这种方法主要采用基于概率或学习的算法对车辆进行控制,但也需要额外注意 V2X 通信技术中的延迟和数据丢包问题。

在多车协同控制方法中,主要有分布式、混合式和集中式 3 种策略。分布式策略允许每辆车独立地进行决策和控制,同时相互交换信息。混合式策略在分布式的基础上引入了一个中心协调器,以优化整体系统性能。集中式策略则由一个中央控制器负责整个系统的决策和控制,各车将信息传输给中央控制器,然后由中央控制器进行统一处理和调度。

车路协同的多车协同控制技术在安全性要求较高的场景中特别有效,如车队跟驰场景。相较于传统方法在获取驾驶意图方面的低效率,车路协同技术通过 V2X 通信能够更准确地获取其他车辆的驾驶意图,从而提高车辆控制的性能。此外,当在处理跟车问题中的碰撞概率分析时,CVIS 能够结合 V2V 技术和神经网络来获取前方车辆的状态信息和制动意图,从而提高控制的合理性。

在非理想通信条件下的车辆控制方法和理论为实现安全可靠的网联车辆控制提供了基本理论基础。Pan 等^[100]推导出随机意义下的 Riccati 不等式,并基于矩阵增广方法描述了包含有限跳变时延的网络化反馈控制系统。通过计算不同时延状态下的控制参数并根据当前通信时延切换控制参数,实现了系统的稳定性。仿真测试证明了这项研究为跳变时延下的多网联车辆的协同控制提供了一种可行的控制器设计方案,从而提高了车路协同系统的安全性。对于多种复杂的交通场景,Cai 等^[101]提出了基于协同指派的多车协同编队控制方法,以及基于车群指派的多车道无信号灯交叉路口通行控制方法。这些方法在提高交通系统整体效率、车辆行驶安全性和燃油经济性的同时,拓宽了现有多车协同控制的场景复杂度,解决了传统方法难以应用于多车道场景的问题。

考虑到智能网联汽车与人工驾驶汽车共存的混合交通环境,Zheng 等^[102]研究了混合交通系统的性能和最优控制器设计,揭示了智能网联汽车在低渗透率下提升交通效率的内在因素和发展潜能。通过

将通信能力受限条件下的智能网联汽车控制策略构建为带有结构约束的最优控制器求解问题，Wang 等^[103]设计了一种针对多车的次优控制策略，使得智能网联汽车能够在低渗透率下显著提升整体交通性能。

3 结语

以上综述表明：依托于 5G、人工智能和自动驾驶的技术进步，车路协同系统已经被视为实现绿色智慧交通系统的一种重要途径。车路协同系统融合了感知、驾驶认知、自主决策和协同控制等关键技术，可以实现交通系统中车辆与基础设施之间的智能互联和协同，以此提升交通安全性和运行效率。然而，尽管国内外学者已经在车路协同技术领域开展了大量的研究，但仍存在许多需要改进和深化的地方。未来的研究趋势和重点应集中在以下几个方面。

(1) 开发整合车端和路端信息的数据集

在当前的研究环境中，数据驱动方法已经成为一个主流的研究途径，许多研究都极度依赖于大量的可用数据。然而，在车路协同的研究领域，现存的数据集多是从车端或路端独立收集，这种分离的数据采集方式往往会导致车端和路端信息不同步、不匹配的问题，对研究结果产生显著影响。当前，整合了车端和路端信息的数据集如 DAIR-V2 等仍十分稀缺。因此，未来车路协同研究的一个重要方向，就是需要开发和优化更多这类融合了车端和路端信息的数据集，以便在实验中更好地模拟实际情况，提高研究结果的可靠性和准确性。另外，当数据集从虚拟环境迁移到现实环境时，如何确保数据的一致性和准确性也是一项挑战。一种可行的方法是借鉴并行系统理论的描述原理，通过将车端和路端的数据进行有效的耦合，形成一个反馈回路，从而实现系统的循环自优化。这不仅能增强数据的一致性和准确性，还可以提高车路协同系统的性能评估、安全性、可靠性和效率。因此，利用并行系统理论的描述原理来指导数据集的开发和优化，也将是未来车路协同研究的一个重要趋势。

(2) 提升多源感知信息的融合精度

由于传感器间存在的误差以及局部动态模型与网络架构的复杂性，车路协同感知面临的主要挑战之一是感知信息的融合精度。首先，由于各种工程实际中的误差，包括共享的过程噪声、相关的测量噪声等，会随着传感器数量的增加迭代传播，分布

式融合算法在实际应用中效果不佳。其次，基于卡尔曼滤波的分布式融合框架在实际工程中面临着网络结构和信息模式的复杂性以及局部动态模型的差异性，进一步加大了提高融合精度的难度。面对自动驾驶的感知限制，一种可能的解决途径是将认知能力引入感知层。许多研究人员正在探索这一领域，试图借鉴人类的认知能力来克服自动驾驶的挑战。一些其他的解决途径如优化分布式融合算法、改进传感器误差建模以及探索适应实际工程需求的局部动态模型和网络架构等也有望提升多源感知信息的融合精度。通过这些方式，可以从本质上提升自动驾驶的感知能力，从而提高 CVIS 的整体性能。

(3) 增强车路协同系统的实时性和安全性

在智能汽车日益普及的今天，车载传感器设备齐全而路侧传感器设备相对匮乏的状况给车路协同系统带来了一项的挑战。为了实现更高效和安全的车路协同，需要增加对路侧传感设备的投入以获取更多路端信息。此外，鉴于交通事故往往在瞬间发生，实时决策对提升车辆安全性至关重要。因此，CVIS 需要在保证云数据处理能力的前提下，极力避免通信故障，以确保在关键时刻能迅速做出准确的决策，从而避免事故的发生。然而，在实现安全和高效的車路协同的同时，还需要解决方法的解释性和系统安全性问题。在解释性方面，针对端到端方法的解释性问题，许多研究者正在通过生成可解释的中间表示来增强系统的解释性。在系统安全性方面，当前的防御措施已被证明不足以抵御最新的攻击技术，因此开发强大的防御技术以对抗此类攻击具有重要的研究意义。

(4) 优化复杂条件下多车协同决策控制的方法

近年来，车联网技术的快速发展为自动驾驶汽车的普及提供了巨大的助力。通过车载传感器系统、V2V 和 V2I 的无线通信技术，CVIS 能够实现多车辆之间的协同决策及控制，从而显著提升交通网络的效率。在复杂的交通条件下，如何做出有效决策成为了一项巨大的挑战。一种可能的解决方案是将人类的认知能力融入自动驾驶，全面理解并处理场景特征。此外，决策方法的稳健性和可推广性也是一大挑战。在此背景下，训练有素的大型语言模型，如 ChatGPT，在解决复杂问题方面具有较强的能力。因此，未来的一个研究方向是探索大型模型在车路协同系统中的合理应用，以克服现有的挑战。此外，如何有效地综合运用无线通信技术、道路交通信息以及车辆动态数据，对所有交通参与者进行精确建

模, 并实现复杂动力学系统的协同优化控制, 这也将是未来车路协同控制的一个关键挑战。

参考文献:

- [1] 曲小波, 刘亚君, 陈雨薇, 等. 城市电动公交车辆运营管理: 综述与展望 [J]. 汽车安全与节能学报, 2022, 13(3): 407-420.
QU Xiaobo, LIU Yajun, CHEN Yuwei, et al. Urban electric bus operation management: review and outlook [J]. Journal of Automotive Safety and Energy, 2022, 13(3): 407-420.
- [2] XU M, LIN H, LIU Y. A deep learning approach for vehicle velocity prediction considering the influence factors of multiple lanes [J]. Electronic Research Archive, 2023, 31(1): 401-420.
- [3] 秦严严, 王昊, 王伟, 等. 混有 CACC 车辆和 ACC 车辆的异质交通流基本图模型 [J]. 中国公路学报, 2017, 30(10): 127-136.
QIN Yanyan, WANG Hao, WANG Wei, et al. Fundamental diagram model of heterogeneous traffic flow mixed with cooperative adaptive cruise control vehicles and adaptive cruise control vehicles [J]. China Journal of Highway and Transport, 2017, 30(10): 127-136.
- [4] 张毅, 姚丹亚, 李力, 等. 智能车路协同系统关键技术与应用 [J]. 交通运输系统工程与信息, 2021, 21(5): 40-51.
ZHANG Yi, YAO Danya, LI Li, et al. Technologies and applications for intelligent vehicle-infrastructure cooperation systems [J]. Journal of Transportation Systems Engineering and Information Technology, 2021, 21(5): 40-51.
- [5] 丁飞, 张楠, 李升波, 等. 智能网联车路云协同系统架构与关键技术研究综述 [J]. 自动化学报, 2022, 48(12): 2863-2885.
DING Fei, ZHANG Nan, LI Shengbo, et al. A survey of architecture and key technologies of intelligent connected vehicle-road-cloud cooperation system [J]. Acta Automatica Sinica, 2022, 48(12): 2863-2885.
- [6] TIAN D, ZHANG C, DUAN X, et al. An automatic car accident detection method based on cooperative vehicle infrastructure systems [J]. IEEE Access, 2019, 7: 127453-127463.
- [7] ZHOU J, TIAN D, WANG Y, et al. Reliability-optimal cooperative communication and computing in connected vehicle systems [J]. IEEE Transactions on Mobile Computing, 2019, 19(5): 1216-1232.
- [8] 张新钰, 邹镇洪, 李志伟, 等. 面向自动驾驶目标检测的深度多模态融合技术 [J]. 智能系统学报, 2020, 15(4): 758-771.
ZHANG Xinyu, ZOU Zhenghong, LI Zhiwei, et al. Deep multi-modal fusion in object detection for autonomous driving [J]. CAAI Transactions on Intelligent Systems, 2020, 15(4): 758-771.
- [9] KIM T, GHOSH J. Robust detection of non-motorized road users using deep learning on optical and lidar data [C]//Proceedings of the 2016 IEEE 19th International Conference on Intelligent Transportation Systems (ITSC). Piscataway, NJ: IEEE, 2016: 271-276.
- [10] YU H, LUO Y, SHU M, et al. Dair-v2x: A large-scale dataset for vehicle-infrastructure cooperative 3d object detection [C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. Piscataway, NJ: 2022: 21361-21370.
- [11] VERONESE L D P, GUIVANT J, CHEEIN F A A, et al. A light-weight yet accurate localization system for autonomous cars in large-scale and complex environments [C]//Proceedings of the 2016 IEEE 19th International Conference on Intelligent Transportation Systems (ITSC). Piscataway, NJ: IEEE, 2016: 520-525.
- [12] XU Y, JOHN V, MITA S, et al. 3D point cloud map based vehicle localization using stereo camera [C]//Proceedings of the 2017 IEEE Intelligent Vehicles Symposium (IV). Piscataway, NJ: IEEE, 2017: 487-492.
- [13] BRUBAKER M A, GEIGER A, URTASUN R. Map-based probabilistic visual self-localization [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2015, 38(4): 652-665.
- [14] CARNEIRO R V, NASCIMENTO R C, GUIDOLINI R, et al. Mapping road lanes using laser remission and deep neural networks [C]//Proceedings of the 2018 International Joint Conference on Neural Networks (IJCNN). Piscataway, NJ: IEEE, 2018: 1-8.
- [15] BASTANI F, HE S, ABBAR S, et al. Roadtracer: Automatic extraction of road networks from aerial images [C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Piscataway, NJ: IEEE, 2018: 4720-4728.
- [16] 安鑫, 蔡伯根, 上官伟. 车路协同路侧感知融合方法的研究 [J]. 测控技术, 2022, 41(2): 1-12.
AN Xin, CAI Bogen, SHANGGUAN Wei. Vehicle road cooperative roadside perception fusion method [J]. Measurement & Control Technology, 2022, 41(2): 1-12.
- [17] FERNANDES L C, SOUZA J R, PESSIN G, et al.

- CaRINA intelligent robotic car: architectural design and applications [J]. *Journal of Systems Architecture*, 2014, 60(4): 372-392.
- [18] JENSEN M B, PHILIPSEN M P, MØGELMOSE A, et al. Vision for looking at traffic lights: issues, survey, and perspectives [J]. *IEEE Transactions on Intelligent Transportation Systems*, 2016, 17(7): 1800-1815.
- [19] GURGHIAN A, KODURI T, BAILUR S V, et al. Deepplanes: End-to-end lane position estimation using deep neural networks [C]//*Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition Workshops*. Piscataway, NJ: IEEE, 2016: 38-45.
- [20] WU T, RANGANATHAN A. A practical system for road marking detection and recognition [C]//*Proceedings of the 2012 IEEE Intelligent Vehicles Symposium*. Piscataway, NJ: IEEE, 2012: 25-30.
- [21] WEN C, SUN X, LI J, et al. A deep learning framework for road marking extraction, classification and completion from mobile laser scanning point clouds [J]. *ISPRS Journal of Photogrammetry and Remote Sensing*, 2019, 147: 178-192.
- [22] BERRIEL R F, ROSSI F S, DE SOUZA A F, et al. Automatic large-scale data acquisition via crowdsourcing for crosswalk classification: a deep learning approach [J]. *Computers & Graphics*, 2017, 68: 32-42.
- [23] MENZEL T, BAGSCHIK G, MAURER M. Scenarios for development, test and validation of automated vehicles [C]//*Proceedings of the 2018 IEEE Intelligent Vehicles Symposium (IV)*. Piscataway, NJ: IEEE, 2018: 1821-1827.
- [24] MURPHEY Y L, MILTON R, KILIARIS L. Driver's style classification using jerk analysis [C]//*Proceedings of the 2009 IEEE Workshop on Computational Intelligence in Vehicles and Vehicular Systems*. Piscataway, NJ: IEEE, 2009: 23-28.
- [25] CONSTANTINESCU Z, MARINOIU C, VLADOIU M. Driving style analysis using data mining techniques [J]. *International Journal of Computers Communications & Control*, 2010, 5(5): 654-663.
- [26] BOLOVINOU A, BAKAS I, AMDITIS A, et al. On-line prediction of an electric vehicle remaining range based on regression analysis [C]//*Proceedings of the 2014 IEEE International Electric Vehicle Conference (IEVC)*. Piscataway, NJ: IEEE, 2014: 1-8.
- [27] YURTSEVER E, MIYAJIMA C, TAKEDA K. A traffic flow simulation framework for learning driver heterogeneity from naturalistic driving data using autoencoders [J]. *International Journal of Automotive Engineering*, 2019, 10(1): 86-93.
- [28] SAMA K, MORALES Y, AKAI N, et al. Driving feature extraction and behavior classification using an autoencoder to reproduce the velocity styles of experts [C]//*Proceedings of the 2018 21st International Conference on Intelligent Transportation Systems (ITSC)*. Piscataway, NJ: IEEE, 2018: 1337-1343.
- [29] ROSS S, GORDON G, BAGNELL D. A reduction of imitation learning and structured prediction to no-regret online learning [C]//*Proceedings of the 14th International Conference on Artificial Intelligence and Statistics*. FL, USA: JMLR Workshop and Conference Proceedings, 2011: 627-635.
- [30] HE H, EISNER J, DAUME H. Imitation learning by coaching [J]. *Advances in Neural Information Processing Systems*, 2012, 25: 1-8.
- [31] ZHANG J, CHO K. Query-efficient imitation learning for end-to-end autonomous driving [C]//*Proceedings of the AAAI Conference on Artificial Intelligence*. Phoenix, Arizona, USA: AAAI, 2016.
- [32] HOQUE R, BALAKRISHNA A, NOVOSELLER E, et al. ThriftyDagger: budget-aware novelty and risk gating for interactive imitation learning [C]//*Conference on Robot Learning*. [S.l.]: PMLR, 2022: 598-608.
- [33] YAN C, QIN J, LIU Q, et al. Mapless navigation with safety-enhanced imitation learning [J]. *IEEE Transactions on Industrial Electronics*, 2022, 70(7): 7073-7081.
- [34] YE F, CHENG X, WANG P, et al. Automated lane change strategy using proximal policy optimization-based deep reinforcement learning [C]//*Proceedings of the 2020 IEEE Intelligent Vehicles Symposium (IV)*. Piscataway, NJ: IEEE, 2020: 1746-1752.
- [35] WU Y, LIAO S, LIU X, et al. Deep reinforcement learning on autonomous driving policy with auxiliary critic network [J]. *IEEE Transactions on Neural Networks and Learning Systems*, 2023, 34(7): 3680-3690.
- [36] HUANG Z, WU J, LV C. Efficient deep reinforcement learning with imitative expert priors for autonomous driving [J]. *IEEE Transactions on Neural Networks and Learning Systems*, 2022: 1-13.
- [37] CHEN L, HU X, TANG B, et al. Parallel motion planning: Learning a deep planning model against emergencies [J]. *IEEE Intelligent Transportation Systems Magazine*, 2018, 11(1): 36-41.
- [38] 郭奕瑾, 蒋涛, 张葛祥. 基于动态窗口和绕墙走的自动垂直泊车轨迹规划 [J]. *交通信息与安全*, 2017(1): 92-97.

- GUO Yicui, JIANG Tao, ZHANG Gexiang. Trajectory planning for automatic vertical parking based on dynamic window and wall following approach [J]. Journal of Transport Information and Safety, 2017(1): 92-97.
- [39] 杨刚, 张东好, 李克强, 等. 基于车车通信的车辆并行协同自动换道控制 [J]. 公路交通科技, 2017, 34(1): 120-129.
- YANG Gang, ZHANG Donghao, LI Keqiang, et al. Cooperative same-direction automated lane-changing based on vehicle-to-vehicle communication [J]. Journal of Highway and Transportation Research and Development, 2017, 34(1): 120-129.
- [40] 赵树恩, 王金祥, 李玉玲. 基于多目标优化的智能车辆换道轨迹规划 [J]. 交通运输工程学报, 2021, 21(2): 232-242.
- ZHAO Shuen, WANG Jinxiang, LI Yuling. Lane changing trajectory planning of intelligent vehicle based on multiple objective optimization [J]. Journal of Traffic and Transportation Engineering, 2021, 21(2): 232-242.
- [41] CHOI S, KIM J, YEO H. Attention-based recurrent neural network for urban vehicle trajectory prediction [J]. Procedia Computer Science, 2019, 151: 327-334.
- [42] CHEN W, WANG F, SUN H. S2tnet: spatio-temporal transformer networks for trajectory prediction in autonomous driving [C]//Proceedings of the Asian Conference on Machine Learning. [S. l.]: PMLR, 2021: 454-469.
- [43] MO X, XING Y, LV C. Interaction-aware trajectory prediction of connected vehicles using cnn-lstm networks [C]//Proceedings of the IECON 2020 the 46th Annual Conference of the IEEE Industrial Electronics Society. Piscataway, NJ: IEEE, 2020: 5057-5062.
- [44] CHANDRA R, GUAN T, PANUGANTI S, et al. Forecasting trajectory and behavior of road-agents using spectral clustering in graph-lstms [J]. IEEE Robotics and Automation Letters, 2020, 5(3): 4882-4890.
- [45] JEON H, CHOI J, KUM D. Scale-net: Scalable vehicle trajectory prediction network under random number of interacting vehicles via edge-enhanced graph convolutional neural network [C]//Proceedings of the 2020 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS). Piscataway, NJ: IEEE, 2020: 2095-2102.
- [46] GAO J, SUN C, ZHAO H, et al. Vectornet: encoding hd maps and agent dynamics from vectorized representation [C]//Proceedings of the Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. Piscataway, NJ: IEEE, 2020: 11525-11533.
- [47] LU Y, WANG W, HU X, et al. Vehicle trajectory prediction in connected environments via heterogeneous context-aware graph convolutional networks [J]. IEEE Transactions on Intelligent Transportation Systems, 2023, 24(8): 8452-8464.
- [48] 贾洪飞, 隗志才, 王晓原. 基于神经网络的车辆跟驰模型的建立 [J]. 公路交通科技, 2001, 18(4): 92-94.
- JIA Hongfei, JUAN Zhicai, WANG Xiaoyuan. Development of a car-following model based on artificial neural networks [J]. Journal of Highway and Transportation Research and Development, 2001, 18(4): 92-94.
- [49] CHEN Z, HUANG X. End-to-end learning for lane keeping of self-driving cars [C]//Proceedings of the 2017 IEEE Intelligent Vehicles Symposium (IV). Piscataway, NJ: IEEE, 2017: 1856-1860.
- [50] YE Y, ZHANG X, SUN J. Automated vehicle's behavior decision making using deep reinforcement learning and high-fidelity simulation environment [J]. Transportation Research Part C: Emerging Technologies, 2019, 107: 155-170.
- [51] YU C, WANG X, XU X, et al. Distributed multi-agent coordinated learning for autonomous driving in highways based on dynamic coordination graphs [J]. IEEE Transactions on Intelligent Transportation Systems, 2019, 21(2): 735-748.
- [52] GAO X, LI X, LIU Q, et al. Multi-agent decision-making modes in uncertain interactive traffic scenarios via graph convolution-based deep reinforcement learning [J]. Sensors, 2022, 22(12): 4586.
- [53] DAI Q, XU X, GUO W, et al. Towards a systematic computational framework for modeling multi-agent decision-making at micro level for smart vehicles in a smart world [J]. Robotics and Autonomous Systems, 2021, 144: 103859.
- [54] CHAE H, KANG C M, KIM B, et al. Autonomous braking system via deep reinforcement learning [C]//Proceedings of the 2017 IEEE 20th International Conference on Intelligent Transportation Systems (ITSC). Piscataway, NJ: IEEE, 2017: 1-6.
- [55] SAXENA D M, BAE S, NAKHAEI A, et al. Driving in dense traffic with model-free reinforcement learning [C]//Proceedings of the 2020 IEEE International Conference on Robotics and Automation (ICRA). Piscataway, NJ: IEEE, 2020: 1-6.

- way, NJ: IEEE, 2020: 5385-5392.
- [56] WANG X, XUE Y, CEN B-L, et al. Study on pollutant emissions of mixed traffic flow in cellular automaton [J]. *Physica A: Statistical Mechanics and its Applications*, 2020, 537: 122686.
- [57] MA L, QU S, SONG L, et al. Exploring the effect of connected autonomous vehicles in mixed traffic flow [C]//*Proceedings of the 3rd International Conference on Intelligent Computing and Human-Computer Interaction (ICHCI 2022)*. Guangzhou: SPIE, 2023, 12509: 201-206.
- [58] PAPADOULIS A, QUDDUS M, IMPRIALOU M. Evaluating the safety impact of connected and autonomous vehicles on motorways [J]. *Accident Analysis & Prevention*, 2019, 124: 12-22.
- [59] ZHENG F, LIU C, LIU X, et al. Analyzing the impact of automated vehicles on uncertainty and stability of the mixed traffic flow [J]. *Transportation Research Part C: Emerging Technologies*, 2020, 112: 203-219.
- [60] RAHMATI Y, KHAJEH HOSSEINI M, TALEBPOUR A, et al. Influence of autonomous vehicles on car-following behavior of human drivers [J]. *Transportation Research Record*, 2019, 2673(12): 367-379.
- [61] ZHAO X, WANG Z, XU Z, et al. Field experiments on longitudinal characteristics of human driver behavior following an autonomous vehicle [J]. *Transportation Research Part C: Emerging Technologies*, 2020, 114: 205-224.
- [62] WEN X, CUI Z, JIAN S. Characterizing car-following behaviors of human drivers when following automated vehicles using the real-world dataset [J]. *Accident Analysis & Prevention*, 2022, 172: 106689.
- [63] 杨澜, 赵祥模, 吴国垣, 等. 智能网联汽车协同生态驾驶策略综述 [J]. *交通运输工程学报*, 2020, 20(5): 58-72.
- YANG Lan, ZHAO Xiangmo, WU Guoyuan, et al. Review on connected and automated vehicles based cooperative eco-driving strategies [J]. *Journal of Traffic and Transportation Engineering*, 2020, 20(5): 58-72.
- [64] LAN X, DI CAIRANO S. Continuous curvature path planning for semi-autonomous vehicle maneuvers using RRT [C]//*Proceedings of the 2015 European Control Conference (ECC)*. Piscatway, NJ: IEEE, 2015: 2360-2365.
- [65] YANG I, KIM H J, JEON W H, et al. Development of realistic shortest path algorithm considering lane changes [J]. *Journal of Advanced Transportation*, 2016, 50(4): 541-551.
- [66] LUO Y, XIANG Y, CAO K, et al. A dynamic automated lane change maneuver based on vehicle-to-vehicle communication [J]. *Transportation Research Part C: Emerging Technologies*, 2016, 62: 87-102.
- [67] HUANG Z, WU Q, MA J, et al. An APF and MPC combined collaborative driving controller using vehicular communication technologies [J]. *Chaos, Solitons & Fractals*, 2016, 89: 232-242.
- [68] XU G, LIU L, OU Y, et al. Dynamic modeling of driver control strategy of lane-change behavior and trajectory planning for collision prediction [J]. *IEEE Transactions on Intelligent Transportation Systems*, 2012, 13(3): 1138-1155.
- [69] ZHENG J, SUZUKI K, FUJITA M. Predicting driver's lane-changing decisions using a neural network model [J]. *Simulation Modelling Practice and Theory*, 2014, 42: 73-83.
- [70] XIE D F, FANG Z Z, JIA B, et al. A data-driven lane-changing model based on deep learning [J]. *Transportation Research Part C: Emerging Technologies*, 2019, 106: 41-60.
- [71] CODEVILLA F, MÜLLER M, LÓPEZ A, et al. End-to-end driving via conditional imitation learning [C]//*Proceedings of the 2018 IEEE International Conference on Robotics and Automation (ICRA)*. Piscatway, NJ: IEEE, 2018: 4693-4700.
- [72] ZHAO J, QU T, XU F. A deep reinforcement learning approach for autonomous highway driving [J]. *IFAC-PapersOnLine*, 2020, 53(5): 542-546.
- [73] SCHULMAN J, WOLSKI F, DHARIWAL P, et al. Proximal policy optimization algorithms [J]. *arXiv preprint arXiv: 170706347*, 2017.
- [74] MUHAMMAD A, ELHATTAB M, ARFAOUI M A, et al. Age of information optimization in a ris-assisted wireless network [J]. *arXiv preprint arXiv: 210306405*, 2021.
- [75] XU W, LIU Y, YI H, et al. Lane-changing decision model for autonomous vehicle under mixed traffic environment [C]//*Proceedings of the Sixth International Conference on Traffic Engineering and Transportation System (ICTETS 2022)*. Guangzhou: SPIE, 2023, 12591: 768-774.
- [76] LIU Q, LI Z, LI X, et al. Graph convolution-based deep reinforcement learning for multi-agent decision-making in mixed traffic environments [J]. *arXiv preprint arXiv: 220112776*, 2022.
- [77] PEI H, ZHANG Y, ZHANG Y, et al. Optimal cooperative driving at signal-free intersections with

- polynomial-time complexity [J]. IEEE Transactions on Intelligent Transportation Systems, 2021, 23(8): 12908-12920.
- [78] LI L, WANG F-Y. Cooperative driving at adjacent blind intersections [C]//Proceedings of the 2005 IEEE International Conference on Systems, Man and Cybernetics. Piscataway, NJ: IEEE, 2005: 847-852.
- [79] WANG Y, CAI P, LU G. Cooperative autonomous traffic organization method for connected automated vehicles in multi-intersection road networks [J]. Transportation Research Part C: Emerging Technologies, 2020, 111: 458-476.
- [80] NTOUSAKIS I A, PORFYRI K, NIKOLOS I K, et al. Assessing the impact of a cooperative merging system on highway traffic using a microscopic flow simulator [C]//Proceedings of the ASME International Mechanical Engineering Congress and Exposition. Montreal: American Society of Mechanical Engineers, 2014, 46613: P.V012T15A024.
- [81] XU B, LI S E, BIAN Y, et al. Distributed conflict-free cooperation for multiple connected vehicles at unsignalized intersections [J]. Transportation Research Part C: Emerging Technologies, 2018, 93: 322-334.
- [82] DING J, PEI H, HU J, et al. Cooperative adaptive cruise control in vehicle platoon under environment of i-VICS [C]//Proceedings of the 2018 21st International Conference on Intelligent Transportation Systems (ITSC). Piscataway, NJ: IEEE, 2018: 1246-1251.
- [83] PEI H, ZHANG Y, TAO Q, et al. Distributed cooperative driving in multi-intersection road networks [J]. IEEE Transactions on Vehicular Technology, 2021, 70(6): 5390-5403.
- [84] WANG Z, WU G, HAO P, et al. Developing a platoon-wide eco-cooperative adaptive cruise control (CACC) system [C]//Proceedings of the 2017 IEEE Intelligent Vehicles Symposium (IV). Piscataway, NJ: IEEE, 2017: 1256-1261.
- [85] GUO G, YANG D, ZHANG R. Distributed trajectory optimization and platooning of vehicles to guarantee smooth traffic flow [J]. IEEE Transactions on Intelligent Vehicles, 2022, 8(1): 684-695.
- [86] RAJAMANI R, TAN H-S, LAW B K, et al. Demonstration of integrated longitudinal and lateral control for the operation of automated vehicles in platoons [J]. IEEE Transactions on Control Systems Technology, 2000, 8(4): 695-708.
- [87] 冀杰, 李以农, 郑玲, 等. 车辆自动驾驶系统纵向和横向运动综合控制 [J]. 中国公路学报, 2010, 23(5): 119-126.
- JI Jie, LI Yinong, ZHENG Ling, et al. Integrated control of longitudinal and lateral motion for autonomous vehicle driving system [J]. China Journal of Highway and Transport, 2010, 23(5): 119-126.
- [88] LEE H, TOMIZUKA M. Coordinated longitudinal and lateral motion control of vehicles for IVHS [J]. Journal of Dynamic Systems, Measurement and Control, 2001, 123(3): 535-543.
- [89] KUMARAWADU S, LEE T T. Neuroadaptive combined lateral and longitudinal control of highway vehicles using RBF networks [J]. IEEE Transactions on Intelligent Transportation Systems, 2006, 7(4): 500-512.
- [90] 郭景华, 罗禹贡, 李国强. 智能电动车辆横纵向协调与重构控制 [J]. 控制理论与应用, 2014(9): 1238-1244.
- GUO Jinghua, LUO Yugong, LI Keqiang. Cooperative and reconfigurable lateral and longitudinal control of intelligent electric vehicles [J]. Control Theory & Applications, 2014(9): 1238-1244.
- [91] BUEHLER M, IAGNEMMA K, SINGH S. The DARPA urban challenge: autonomous vehicles in city traffic [M]. NY, USA: Springer, 2009.
- [92] SAMSON C. Path following and time-varying feedback stabilization of a wheeled mobile robot [C]//Proceedings of the International Conference on Control Automation, Robotics and Vision. Singapore: [s.n.], 1992: 13.
- [93] THRUN S, MONTEMERLO M, DAHLKAMP H, et al. Stanley: The robot that won the DARPA Grand Challenge [J]. Journal of Field Robotics, 2006, 23(9): 661-692.
- [94] KANAYAMA Y, KIMURA Y, MIYAZAKI F, et al. A stable tracking control method for an autonomous mobile robot [C]//Proceedings of the IEEE International Conference on Robotics and Automation. Piscataway, NJ: IEEE, 1990.
- [95] JIANGDAGGER Z P, NIJMEIJER H. Tracking control of mobile robots: a case study in backstepping [J]. Automatica, 1997, 33(7): 1393-1399.
- [96] D'ANDREA-NOVEL B, CAMPION G, BASTIN G. Control of nonholonomic wheeled mobile robots by state feedback linearization [J]. The International Journal of Robotics Research, 1995, 14(6): 543-559.
- [97] OLLERO A, AMIDI O. Predictive path tracking of mobile robots. Application to the CMU Navlab [C]//Proceedings of 5th International Conference on Advanced Robotics, Robots in Unstructured Environments. Pisa:

- ICAR, 1991: 1081-1086.
- [98] KIM E, KIM J, SUNWOO M. Model predictive control strategy for smooth path tracking of autonomous vehicles with steering actuator dynamics [J]. *International Journal of Automotive Technology*, 2014, 15: 1155-1164.
- [99] FALCONE P, BORRELLI F, TSENG H E, et al. Linear time-varying model predictive control and its application to active steering systems: stability analysis and experimental validation [J]. *International Journal of Robust and Nonlinear Control: IFAC-Affiliated Journal*, 2008, 18(8): 862-875.
- [100] PAN J, XU Q, LI K, et al. Controller design for V2X application under unreliable feedback channel [C]//*Proceedings of the 2019 IEEE Intelligent Transportation Systems Conference (ITSC)*. Piscataway, NJ: IEEE, 2019: 2496-2502.
- [101] CAI M, XU Q, LI K, et al. Multi-lane formation assignment and control for connected vehicles [C]//*Proceedings of the 2019 IEEE Intelligent Vehicles Symposium (IV)*. Piscataway, NJ: IEEE, 2019: 1968-1973.
- [102] ZHENG Y, WANG J, LI K. Smoothing traffic flow via control of autonomous vehicles [J]. *IEEE Internet of Things Journal*, 2020, 7(5): 3882-3896.
- [103] WANG J, ZHENG Y, XU Q, et al. Controllability analysis and optimal controller synthesis of mixed traffic systems [C]//*Proceedings of the 2019 IEEE Intelligent Vehicles Symposium (IV)*. Piscataway, NJ: IEEE, 2019: 1041-1047.

Research Progress on Key Technologies in the Cooperative Vehicle Infrastructure System

LIN Hongyi¹ LIU Yang¹ LI Shen² QU Xiaobo¹

(1. School of Vehicle and Mobility, Tsinghua University, Beijing 100084, China; 2. School of Civil Engineering, Tsinghua University, Beijing 100084, China)

Abstract: With the steady growth of urban car ownership, the issue of traffic congestion is becoming increasingly prominent, bringing great pressure to urban development. To respond effectively to this challenge, it is critical to develop methods that can improve transport efficiency and reduce energy consumption. In current context, the Cooperative Vehicle Infrastructure System (CVIS), an ideal solution for realizing green and intelligent transportation systems, has become an important direction in both transportation research and practice. By integrating and optimizing various traffic resources, CVIS not only enhances traffic efficiency and reduces energy consumption but also provides key technical support for achieving “dual carbon” goals. This paper thoroughly analyzed the fundamental concepts, research methodologies and application scenarios of CVIS, and delved into its four core technological modules: fusion perception, driving cognition, autonomous decision-making, and cooperative control. The paper reviewed and summarized research achievements within these modules, ranging from traditional methods to the latest in deep reinforcement learning techniques. It also explored the potential applications of these technologies and methods for enhancing traffic efficiency, reducing energy consumption, and improving road safety. Finally, the paper scrutinized numerous challenges that CVIS may encounter in practical applications, including the security of information transmission, system stability, and environmental complexity. To overcome these challenges, the paper looked forward to the future development in four areas: developing datasets that integrate vehicle-side and roadside information, enhancing the fusion accuracy of multi-source perception information, improving the real-time performance and safety of CVIS, and optimizing multi-vehicle cooperative decision-making control methods under complex conditions. As a result, this paper not only has important reference value for the advancement of CVIS technology, but also provides important guidance for the future planning and construction of urban transportation systems.

Key words: cooperative vehicle infrastructure system; fusion perception; driving cognition; autonomous decision-making; cooperative control