控制与决策
Control and Decision

基于数据驱动的智能网联车辆队列控制综述

吴彦宏, 左志强, 王一晶, 王浩宇, 李峥

引用本文:
吴彦宏, 左志强, 王一晶, 等. 基于数据驱动的智能网联车辆队列控制综述[J]. 控制与决策, 2025, 40(12): 3489-3508.

在线阅读 View online: https://doi.org/10.13195/j.kzyjc.2025.0561

您可能感兴趣的其他文章

Articles you may be interested in

一种具有非线性动力学模型的智能电网快速分布式控制

A fast distributed control of smart grids with nonlinear dynamic model

控制与决策. 2021, 36(8): 1849-1854 https://doi.org/10.13195/j.kzyjc.2019.1696

区分交通流模式的混合服务路口信号控制策略

Signal control strategies of mixed service intersections to discriminate traffic flow patterns

控制与决策. 2021, 36(6): 1509-1515 https://doi.org/10.13195/j.kzyjc.2019.1520

基于FWADE-ELM的短时交通流预测方法

Short-term traffic flow forecasting based on hybrid FWADE-ELM

控制与决策. 2021, 36(4): 925-932 https://doi.org/10.13195/j.kzyjc.2019.1103

基于混合整数规划的智能网联车冲突区时序优化模型

Mixed integer programming model of scheduling for connected automated vehicles in a conflict zone

控制与决策. 2021, 36(3): 705-710 https://doi.org/10.13195/j.kzyjc.2019.0886

基于生成对抗网络的大规模路网交通流预测算法

Traffic flow forecasting algorithm for large-scale road network based on GAN

控制与决策. 2021, 36(12): 2937-2945 https://doi.org/10.13195/j.kzyjc.2020.0333

基于数据驱动的智能网联车辆队列控制综述

吴彦宏[1,2]，左志强[1,3†]，王一晶[1,3]，王浩宇[1,3]，李 峥[1,3]

(1. 天津大学 电气自动化与信息工程学院，天津 300072；
2. 浙江工业大学 信息工程学院，杭州 310014；
3. 天津市智能无人集群技术与系统重点实验室，天津 300072)

摘 要: 智能网联车辆作为现代交通系统的重要组成部分, 在提升交通效率、保障交通安全及改善环境质量等方面展现出巨大潜力, 已成为智慧交通领域的研究热点. 鉴于此, 对车辆队列模型、队列控制策略以及数据驱动系统架构等领域的最新研究成果进行深入调研与系统梳理, 全面总结基于数据驱动的智能网联车辆队列控制的研究现状与发展趋势. 首先, 总结智能网联车辆队列建模的方法, 比较分析机理建模与数据驱动建模的异同与优势; 其次, 探讨智能网联车辆队列系统的优化控制问题, 重点分析传统控制方法与数据驱动控制策略之间的差异, 特别是多目标优化方法在智能化与网联化交通环境中的应用潜力; 进一步, 阐述数据驱动控制策略的数据来源、系统架构及其实现路径, 并讨论实施过程中的技术挑战与解决方案; 最后, 总结当前智能网联车辆控制系统发展过程中面临的主要问题与挑战, 并对未来研究的方向与重点进行展望, 旨在为推动智能网联车在复杂交通环境中的广泛应用提供理论指导与实践依据.

关键词: 智能网联车；队列控制；数据驱动；优化；建模；系统框架

中图分类号: TP273 **文献标志码:** A

DOI: 10.13195/j.kzyjc.2025.0561

引用格式: 吴彦宏, 左志强, 王一晶, 等. 基于数据驱动的智能网联车辆队列控制综述 [J]. 控制与决策, 2025, 40(12): 3489-3508.

A survey of data-driven control for connected and autonomous vehicles

WU Yan-hong[1,2]，*ZUO Zhi-qiang*[1,3†]，*WANG Yi-jing*[1,3]，*WANG Hao-yu*[1,3]，*LI Zheng*[1,3]

(1. School of Electrical and Information Engineering，Tianjin University，Tianjin 300072，China；2. School of Information Engineering，Zhejiang University of Technology，Hangzhou 310014，China；3. Tianjin Key Laboratory of Intelligent Unmanned Swarm Technology and System，Tianjin 300072，China)

Abstract: Connected and autonomous vehicles (CAVs), as a critical component of the modern transportation system, have demonstrated significant potential in enhancing traffic efficiency, ensuring safety, and improving environmental quality, making them a research hotspot in the field of intelligent transportation. This paper conducts an in-depth review of the latest research achievement in vehicle platoon models, platoon control strategies, and data-driven system architectures. It also provides a comprehensive overview of the current status and development trends in data-driven platoon control for CAVs. Firstly, the paper summarizes the methods for modeling vehicle platoons and compares the similarities, differences, and advantages of mechanistic modeling and data-driven modeling. Secondly, it delves into the optimization control issues in the platoon system, with a focus on analyzing the differences between traditional control methods and data-driven control strategies, particularly highlighting the application potential of multi-objective optimization methods in intelligent and connected traffic environments. Next, it elaborates on the data sources, system architecture and implementation pathways of data-driven control strategies. Finally, the paper identifies the key challenges and bottlenecks of the development of platoon control systems and outlines future research directions and priorities, aiming to provide both theoretical guidance and practical insights for promoting the widespread application of CAVs in complex traffic environments.

Keywords: connected and autonomous vehicles; platoon control; data-driven; optimization; modelling; system architecture

收稿日期: 2025-05-29；**录用日期:** 2025-09-17.

基金项目: 国家自然科学基金项目 (62173243, 62503426, 62403348); 天津市自然科学基金项目 (23JCQNJC01780).

†通信作者. E-mail: zqzuo@tju.edu.cn.

0 引 言

在全球范围内, 汽车产业面临前所未有的变革浪潮, 与之相关的汽车技术正处于蓬勃发展的关键阶段. 电动化、智能化和网联化作为三大核心驱动力, 正以前所未有的速度推动汽车产业迈向新高度[1]. 智能网联汽车 (connected and autonomous vehicles, CAVs) 作为这一变革的代表性成果, 凭借其先进感知、决策和控制技术, 成为实现车辆的自主驾驶与智能网联的先进交通载体[2]. 通过多模态传感器获取车辆周边环境数据, 再经高性能计算与机器学习等前沿技术进行环境感知、行为预测与路径规划, 最终通过控制执行单元实现车辆精准操作[3]. 而电动化技术赋予车辆高效能源利用率和零排放特性, 不仅有利于减少环境污染, 而且显著降低了能源消耗. 智能化技术则让车辆能够及时响应复杂的交通环境, 实现自动驾驶和智能避障, 从而提高驾驶安全性和舒适性[4]. 此外, 智能网联电动技术借助 5G 车联通信技术实现人、车、路之间的高效数据交互 (如图 1 所示), 有利于智能交通系统的优化运行和资源有效调配, 从而提高交通效率[5-6].

图1 智能网联车技术框架

为推动智能网联汽车的发展, 各国相继出台了一系列政策和法规. 美国早在 1990 年就已发布了《智能车-高速路系统战略计划》, 开启了智能联网与自动驾驶汽车技术的发展浪潮[7]. 2020 年, 美国政府公布了《确保美国自动驾驶汽车技术的领航地位: 自动驾驶汽车 4.0 法案》[8], 进一步明确了美国自动驾驶领域的未来发展方向. 2017 年 5 月, 德国总理起草并由联邦参议院通过了首个自动驾驶相关法律《道路交通法-第八修正案》, 该法律允许自动驾驶在特定条件下替代人类进行驾驶[9]. 同年, 日本自动驾驶研究工作组发布了《日本自动驾驶政策方针 1.0 版》, 并每年持续. 近期, 工作组又颁布了《日本自动驾驶政策方针 4.0 版》, 对自动驾驶服务、道路普及线路图、技术测试和验证等多方面进行了完善[10]. 在国际层面, 联合国也积极推动自动驾驶技术的发展, 除了已有的《LKAS 车道自动保持系统条例》技术法规外, 2016 年 3 月 23 日正式发布《维也纳公约-道路交通》[11]. 这也是联合国在自动驾驶领域出台的主要技术规范, 其规定在符合联合国车辆管理条例情况下, 自动驾驶技术可以成功应用到交通运输行业中. 我国也将智能网联汽车技术的发展同样提升至国家战略层面. 中国工程院在 2016 年出台了《智能网联汽车技术路线图》, 提出了 2030 年智能网联汽车发展的目标和关键技术路线[12]. 2018 年, 由工业和信息化部联合发布的《智能网联汽车标准体系建设指南》, 明确了智能网联汽车标准体系的框架和主要内容, 涵盖车辆和信息通信方面[13]. 2021 年, 工信部与交通运输部又先后分别出台了《智能网联汽车道路测试与示范应用管理规范》和《交通运输部关于服务构建新发展格局的指导意见》, 进一步推进智能网联汽车试点示范工作[14], 推动了从道路测试向示范应用的转变. 三部委于 2023 年启动了《关于开展智能网联汽车准入和上路通行试点工作》, 正式宣布我国智能网联车辆进入应用阶段. 2025 年, 工业和信息化部与市场监管总局联合发布《关于进一步加强智能网联汽车产品准入、召回及软件在线升级管理的通知》, 推动了智能网联汽车产业生态的构建[15].

为此, 美国、中国、日本和欧洲等世界主要汽车强国在智能网联汽车领域已开展了大量前瞻性研究工作. 例如, 美国著名的 Peloton 车辆队列自动跟驰项目、欧洲的 Grand cooperative driving challenge (GCDC) 项目、Safe road trains for the environment (SARTER) 项目和 SCANIA 项目[16] 等. 这些项目均已顺利完成或推进到了实车验证阶段, 如图 2 所示. 欧美的各大汽车厂商已将相关的研究成果整合到最新车辆系统中. 例如, 融合了雷达、超声波探测器、摄像头以及全球定位系统 (global positioning system, GPS) 的通用凯迪拉克 Super Cruise 系统, 具备自适应巡航和路况障碍物识别等能力的奔驰自动驾驶系统, 以及可感知周围交通状况并对前方道路进行导航的谷歌 Waymo Driver 系统等[17]. 在商业化应用方面, 多家国际汽车制造商和科技公司相继推出了具有部分或完全自动驾驶功能的车辆, 并在特定区域或公共道路上进行了实车测试[18]. 这些活动不仅验证了智能网联汽车的实用性和安全性, 也促进了相关技术标准和法规体系的建立和完善. 尽管面临技术挑战、法律法规限制和公众接受度等问题, 国外智能网联汽车的发展仍表现出强劲的动力和广阔的前景. 在国内, 已有诸多与车辆队列相关的研究和应用成果, 如长安进行了 55 辆 CS55 商用车车辆队列试验, 由汽标委智能网联汽车分标委组织的全国首次大规模商用车列队跟驰公开验证试验等[19]. 在城市

应用层面, 深圳市利用智能网联技术, 率先开展了城市公交车队的智能调度系统试点, 通过精准的数据分析与实时通信技术, 显著优化了公交车辆的运行效率. 此外, 宁波市的港口物流也引入了智能网联车队, 借助智能调度和路线优化, 显著提升了港口物流的作业效率和装卸效率[20]. 这些应用实例不仅彰显了中国在智能网联车辆队列技术方面的先进性, 更为智能网联汽车的未来发展提供了有益的探索与实践经验.

图2　智能网联车商业化应用

现有综述大多侧重于智能网联车辆队列控制的某一特定领域, 如机理建模、控制策略等, 而本综述则以“数据驱动”的方法为核心, 全面涵盖了车辆队列建模、控制策略的优化以及数据驱动系统架构的最新研究进展. 特别是在数据驱动建模方面, 本文突出基于大数据和人工智能技术的创新应用, 重点介绍如何通过深度学习、强化学习等方法来应对传统方法难以处理的复杂交通场景和非线性问题. 因此, 本综述不仅对现有研究成果进行总结, 还通过比较分析不同建模方法的优势与局限, 进一步扩展研究的深度和广度.

本文结构如下: 第 1 节介绍智能网联车辆队列的建模方法; 第 2 节综述智能网联车辆队列的控制方法和局限性; 第 3 节围绕智能网联车数据来源及系统框架进行分析; 第 4 节进行总结与展望.

1　车辆队列建模

1.1　机理建模

车辆队列建模旨在通过对车辆队列行驶的动态行为进行数学建模和分析, 从而深入解析车辆间的网联互通机制、自主协同控制策略机理[21]. 随着智能网联技术的快速发展和交通需求的日益增长, 智能网联车辆队列建模在优化交通流、提升道路安全性等方面具有重要的理论意义和实践价值[22]. 目前, 主流的车辆队列建模方法主要分为机理建模方法和数据驱动建模方法[23]. 此外, 可以根据研究对象和目标不同分为单车建模与车辆队列建模两部分, 二者分别体现出微观与宏观分析的区别[24]. 单个车辆动力学建模聚焦于车辆的物理行为和运动机制, 如加速、转向和制动等, 通过精准的动力学和运动学原理来模拟车辆在不同条件下的响应[25]. 相比之下, 车辆队列建模将多辆车视为一个整体, 着重探索其在交通系统中的行为模式和相互作用, 强调车辆之间的距离维持、速度同步以及群体行驶的稳定性.

车辆队列动力学建模涉及动力传动系统中多项非线性结构, 如发动机、传动系统以及制动系统[26]. 目前, 许多研究利用这种单体车辆模型构建分布式车辆队列系统, 以保证队列的弦稳定性[27]. 此外, 线性模型在车辆队列建模中已被广泛应用, 包括单积分器模型、二阶模型 (包括双积分器模型) 以及三阶模型. 对于单积分器模型, 车辆速度作为控制输入, 位置则是其唯一状态. 该模型简化了控制器设计的理论分析, 并能将车队中的最优控制问题简化为一个凸优化问题[28]. 然而, 考虑到这种模型与实际车辆动力结构存在一定差异, 可能会引发队列行驶过程中的不稳定现象. 因此, 一些学者提出将车队视为单一质点更为合理, 从而推导出双积分器模型, 即二阶模型[29]. 上述两种模型作为众多重要理论成果的基础, 皆以加速度作为车辆的控制输入[30]. 但是, 使用加速度控制模型难以准确描述车辆内部动力学特征. 鉴于此, 三阶模型应运而生[31]. 该模型以扭矩而非加速度作为控制输入, 能够更加准确地调节发动机和制动系统, 从而更准确地模拟动力传动系统的输入和输出特征[32].

然而, 考虑到 CAVs 的渗透率难以在短期内达到 100%, 在未来一段时间内将呈现混合交通阶段[33]. 在此背景下, 有必要对人类驾驶车辆 (human driving vehicles, HDVs) 进行建模, 以便深入理解和预测其驾驶行为. HDVs 与 CAVs 之间的关键差异在于前者涉及到不可控的驾驶人行为, 这种非理想的驾驶行为具有内在的不确定性和随机性, 可能会影响队列的稳定性[34]. 为了描述这种复杂的人类驾驶行为特性, 研究人员相继开发了一系列驾驶人数学模型, 如智能驾驶人模型 (intelligent driver model, IDM)、最优速度模型 (optimal velocity model, OVM)、坦佩雷模型及前馈反馈集成模型等[35]. IDM 由 Treiber 等[36] 于 2000 年提出, 用于模拟驾驶人在跟车和保持安全距离方面的动态响应. 该模型综合考虑车辆的当前速度、与前车的相对距离及相对速度, 并采用非线性函数计算车辆的加速度, 从而模拟驾驶人在不同交通状况下的驾驶偏好[37]. 事实上, 当队列间隔显

著低于期望间隔时, 车辆加速度将会急剧增加, 进而导致车辆失稳. 为解决这一问题, Kesting 等[38] 引入恒定加速度启发式 (constant acceleration heuristic, CAH) 方法限制车辆速度的突变, 从而提出了自适应巡航控制 (adaptive cruise control, ACC) 模型. ACC 模型结合 IDM 的动态车辆特性预测与 CAH 算法的反馈控制机制, 能够智能调整车辆的加速度, 以确保车辆队列稳定. 针对传统 IDM 模型在复杂交通环境下的局限性, 研究人员引入了随机性因素、多车道交互及车辆间通信机制, 以模拟实际交通流中的非线性特性和车辆间的动态交互[39]. 近年来, 大量基于深度学习和机器学习方法已广泛应用于 IDM 模型的优化, 旨在提升模型对 HDVs行为预测的准确度[40].

OVM 作为交通流理论中的一个重要分支, 自 20 世纪 90 年代初由 Bando 等[41] 提出以来, 已成为智能网联车辆控制与建模领域的研究热点. OVM 模型基于非线性车辆动力学的特性, 通过定义车辆与前车之间的最优跟随距离来调整车速, 从而提高车辆行驶的平滑性和道路通行效率. 基于此, Helbingand 通过分析大量实测数据来校准模型参数, 并采用阶跃函数来处理模型中的异常加速与减速现象[42]. 近年来, 一种基于碰撞时间的新型 OVM 受到了广泛关注, 其通过简化单变量函数描述交错车辆的跟随状态, 能够有效评估单向双车道中头车间距、速度和加速度的影响[43]. 然而, 上述方法仅关注车辆与其最优速度之间的偏差, 未考虑车辆间相对速度的变化, 这在一定程度上限制了其对复杂交通环境的适应性. 为此, Jiang 等[44] 提出了一种全速差模型 (full velocity difference model, FVDM), 该模型引入速度差项, 使模型对领航车辆状态的变化更为敏感. 考虑到延迟因子对车辆稳定性造成的影响, 驾驶人反应时间的延迟被纳入 FVDM 模型开发中[45]. 为研究超车行为对队列跟踪行为的影响, He 等[46] 提出一种考虑车头间距分布和预设道路超车行为的最优速度模型. 此外, 为探究驾驶人心理状态对于不同交通条件下车辆间距的影响, Wang 等[47] 将车辆跟随动态行为融入最优速度模型中, 结果表明驾驶人的心理状态对交通的拥堵有显著影响.

上述工作主要关注纵向车辆队列模型, 但是无法满足复杂的道路交通场景, 因此开展横向和纵向耦合的队列模型研究至关重要. 横纵向耦合模型不仅涉及车辆的安全跟驰行为, 还涵盖车辆的加速、减速、转向等动作, 这对车辆队列的高效协同运行至关重要[48]. 传统的车辆控制研究主要聚焦于纵向或横向控制的独立研究, 然而, 这种分离的研究思路忽略了车辆在实际行驶过程中横纵向行为的相互影响, 无法全面反映车辆动态行为的复杂性. 因此, 近年来, 学者们开始致力于横纵向耦合动力学模型的探索, 旨在通过综合考虑车辆在横向和纵向上的动态响应, 实现对车辆行为的更加准确的建模和控制[49-50]. 但是, 这种耦合的动力学模型包含复杂的动力学系统和难以量化为驾驶人行为参数, 因而难以构建精准的动力模型.

1.2 数据驱动建模

随着智能交通系统的持续发展, 实时监测和存储大量的人车路交通数据成为可能. 在对这些交通数据进行分析处理时, 传统的理论驱动方法需根据数据特征施加相关研究对象的假设, 并建立符合假设的数学模型[21, 51]. 然而, 在混合车辆队列的建模中, 不仅需要自动驾驶车辆在感知、决策和控制方面的高级功能, 还需考虑驾驶人行为的多样性和不确定性. 而基于单一理论假设难以建立较为准确的数学模型, 且传统的物理建模方法已经无法满足当前交通系统发展的需求. 因此, 如何利用交通大数据解析复杂交通系统的内在规律, 成为学术界亟需解决的问题. 近年来, 一些数据驱动方法, 如 Koopman 算子、子空间辨识和深度强化学习, 为混合车辆队列的建模提供了有效的解决方案[22]. 这些方法旨在根据收集到的大量实车数据准确地描述不同类型车辆的驾驶行为模式, 从而开发有效的车辆队列模型.

Koopman 算子理论自 20 世纪 30 年代由 Koopman[52] 提出以来, 已在复杂系统的数据驱动建模领域得到广泛应用, 其通过在无限维函数空间中将非线性动态系统的演化描述为线性形式, 为复杂系统提供了一种可行的分析和建模手段. 在车辆队列数据驱动建模中, Koopman 算子能够将高维非线性车辆动态行为转化为线性问题, 极大地简化了模型的分析、预测及控制过程[53]. 具体而言, Koopman 算子利用动态模式分解技术, 可以在不直接处理系统内部复杂的非线性相互作用的前提下, 刻画出车辆队列的主要特征. 针对 Koopman 算子在实际应用中遇到的诸多挑战, 如高维数据处理的计算效率低下、模型解释性不足等问题, 一些研究者已经提出相应的改进策略. Williams 等[54] 将深度学习与 Koopman 算子相结合, 提出一种新的数据驱动建模方法, 显著提高了模型的预测准确性. 例如, Proctor 等[55] 引入稀疏编码技术, 有效降低了 Koopman 算子的计算复杂度, 同时保留了模型预测精度. Kutz 等[56] 则通过开发更为高效的算法来近似 Koopman 算子,

提高了数据处理的效率和模型的应用范围. 尽管Koopman算子在车辆队列数据驱动建模研究中已取得显著进展, 但如何进一步提高模型的预测准确性, 并扩展到更多交通场景以及增强模型的可解释性等问题仍然是未来研究的重点.

子空间辨识方法最早由Kung于1978年提出[57], 随后, Juang等[58]将这一概念应用于结构模型参数的辨识中, 其本质是通过输入/输出(I/O)数据构成的Hankel矩阵直接计算出状态空间模型. 相较于传统的基于机理模型的方法, 子空间辨识技术无需依赖于详细的系统先验知识, 能够有效适应复杂变化的工作环境, 提高系统建模的准确性和实时性. 近年来, 子空间辨识方法在理论研究领域得到了迅速发展, 涌现出许多代表性的算法, 包括典型变量分析法(canonical variate analysis, CVA)、多变量输出误差状态空间法(multivariable output error state space, MOESP)、数值子空间系统辨识方法(numerical algorithms for subspace system identification, N4SID). 其中, CVA方法作为一种多变量统计分析方法, 常用于处理具有多个变量的数据集, 以寻找变量间的最大相关性. 在模型参数辨识领域, CVA则广泛应用于识别系统模型中的参数, 特别是在动态系统的建模与辨识中[59]. 该方法通过“过去”数据的线性组合实现对“未来”数据的最优估计, 使用加权的估计误差来定义此估计的范数指标, 并通过范数指标的极小化构造辨识算法. 近些年来, 已有研究开始探索将CVA与其他优化算法相结合, 以解决传统参数辨识方法难以应用于复杂系统中的问题[60]. MOESP辨识是由Verhaegen[61]提出的一类基于几何概念的子空间辨识方法, 该方法利用已知数据构造出特定的Hankel矩阵, 并通过正交三角分解方法将结果分解成两个相互正交的子空间, 从而获得系统广义可观测性矩阵的一致估计. 然后, 根据获得的广义可观测矩阵进一步求解出系统矩阵. N4SID方法由van Overschee等[62]受线性系统的几何性角度启发而提出, 可视为一种具有秩约束的多步预报误差法, 该方法采用线性回归法求解系统矩阵, 并通过几何方法实现预测误差的极小化. N4SID利用Kalman滤波获取系统状态的估计, 并利用这一估计计算系统矩阵, 可有效降低噪声数据对系统识别结果的影响, 从而提高模型辨识的精度和可靠性.

子空间辨识方法作为一种高效的数据驱动建模技术, 近年来在车辆队列数据驱动建模领域得到了广泛应用[63], 该方法直接从系统输入输出数据中提取模型结构, 在处理复杂交通系统的建模问题时显示出独特的优势[64]. 此外, 针对子空间辨识方法在车辆队列中遇到的计算效率和模型精度问题, 一些研究通过算法优化和模型改进提出了一系列有效的解决方案. 例如, 通过改进交通数据预处理和特征提取步骤, 以提高车辆模型的数据处理能力和预测准确性[65]. 通过引入稀疏表示和正则化技术, 可以有效减少车辆模型的过拟合风险, 并增强模型的泛化能力[66]. 针对子空间辨识算法在高噪声交通环境下的扰动问题, 通过引入先进的噪声过滤技术来提高车辆建模的准确度和可靠性[67]. 尽管子空间辨识方法已在车辆建模领域取得了显著的应用成果, 但仍面临数据质量依赖性强、模型解释性差等挑战. 未来的研究需要进一步探索更加高效、鲁棒的建模算法, 并致力于提高模型的透明度和解释能力, 以适应复杂交通场景的需求.

2 车辆队列控制

2.1 控制系统框架

车辆队列控制算法依赖先进的车载通信技术和自动控制技术, 通过实时交换车辆状态信息实现车辆之间的紧密协作, 从而优化整个车队的行驶策略. 车辆队列控制方法与多智能体控制方法在本质上是类似的, 它们均致力于实现多个个体的高效协同, 以达到既定的共同目标[68]. 在车辆队列控制中, 车辆之间需要通过即时信息共享与策略协同确保交通流畅及安全, 而多智能体控制则涉及更广泛的适用场景, 其中智能体可能是机器人、软件代理等, 强调个体在动态变化环境中的自主学习与决策. 两者皆依赖于先进的通信技术与智能算法, 以确保个体能够有效互通信息并做出最佳决策, 从而增强整体系统的效率与鲁棒性. 近年来涌现出大量先进的控制算法, 主要分为分布式控制模式和集中式控制模式两种[69], 如图3所示. 集中式控制模式旨在通过一个中央控制单元统一接收和处理所有车辆的状态信息, 并据此制定合适的控制指令, 以实现车辆队列的协同控制[70]. 这种模式的核心优势在于能够全局优化车队的运行策略, 确保车辆行为的高度一致性和协同性, 从而优化交通流. 此外, 通过集中式处理, 可以有效减少车辆间的冗余通信, 并降低系统的复杂性, 以便适用于复杂的控制逻辑. 基于此, Levine等[71]提出了一种基于线性反馈控制律的集中式控制算法框架, 为车辆队列控制研究提供理论基础. 然而, 该模式也存在着通信延迟率高和系统可扩展性差的缺陷. 为解决上述问题, Stankovic等[72]设计了一种基于分布式的控制模式, 其将车队控制问题转化为若干由各

车辆独立解决的子问题, 这种分布式控制模式允许车辆根据自身及周围车辆的状态信息, 独立做出控制决策, 而无需依赖中央控制器的指令. 上述方案能够在复杂的交通环境中, 快速应对路况变化和突发事件, 从而提高车队的整体行驶效率.

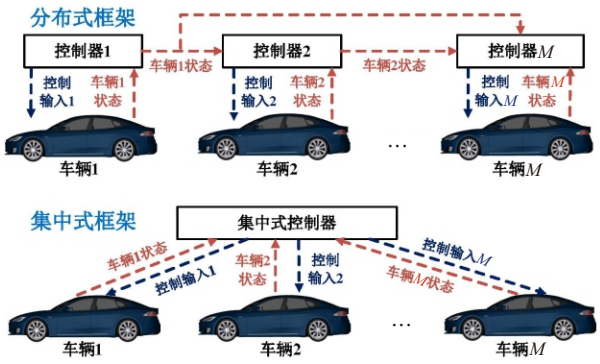

图3 智能网联车控制系统框架

2.2 基于模型的队列控制方法

基于上述两种控制模式, 相继涌现出大量车辆队列控制算法, 如比例-积分-微分 (PID) 控制、鲁棒控制、滑模控制和模型预测控制 (MPC) 等. Xavier 等[73] 提出一种基于分布式 PID 的车辆队列控制策略, 可根据两车之间相对位置和速度信息进行队列控制. 鉴于车辆固有的非线性和不确定性, Wang[74] 开发了一种基于新型分离原则的自适应 PID 控制器进行队列控制. 针对难以分析车辆模型的非线特征的问题, Li 等[75] 利用逆模型补偿技术来构建线性车辆动力学模型, 并在此基础上构建了一种基于增量 PID 的队列控制算法.

在实际车辆队列应用中, 模型参数不精准和外部干扰等因素均会对队列性能造成重大影响, 因而有必要提高队列的鲁棒性. 近年来, 一些鲁棒控制策略已成功应用于车辆队列控制中, 使得车辆系统在面对参数不确定性和扰动时能够保持稳定运行. 鲁棒 H_∞ 控制方法以 H_∞ 范数为目标函数, 求解满足该范数性能指标最优的控制增益, 以减少系统对扰动的敏感性, 从而提高系统的鲁棒性. 此外, 鲁棒 H_∞ 控制能够结合线性时变系统和模糊多胞机模型, 有效地解决系统模型参数时变以及范数有界的不确定性问题. 近年来, 该方法在车辆队列控制领域得到了广泛的应用. Hang 等[76] 提出了一种基于线性参数变化系统的鲁棒 H_∞ 路径跟踪控制器. 此外, 为应对车辆质量变化、纵向速度波动以及轮胎转向刚度系数不确定性带来的影响, 开发了一种基于鲁棒 H_∞ 控制理论的队列路径跟踪控制器, 以提高系统在复杂工况下的鲁棒性和路径跟踪性能[77]. Zhang 等[78] 采用范数有界不确定性模型来表征车辆转向刚度系数的变化特性, 提出了一种鲁棒控制策略, 旨在提升车辆的稳定性及路径跟踪的精度. 除了 H_∞ 控制器外, 鲁棒控制还涉及 μ 综合、线性矩阵不等式 (LMI) 等相关技术. 其中, μ 综合作为一种处理多变量系统不确定性的先进技术, 能够通过精确表征系统中的不确定性来进行模型设计, 从而确保控制器在各种扰动条件下依然满足系统的稳定性要求. 而 LMI 方法则是通过构造满足一定条件的矩阵不等式, 以此构建系统的稳定性条件. 根据上述结果, Gao 等[79] 提出了一种新型 H_∞ 鲁棒控制策略, 该策略能够在随机参数变化和外部扰动的情况下保持良好的控制效果. 此外, Zheng 等[80] 深入研究了无向通信拓扑对车队的鲁棒性和 H_∞ 控制器设计的影响. 为解决未知道路曲率的队列路径跟踪问题, Nguyen 等[81] 开发了一种预测模型以提前获取道路曲率的动态先验信息, 并进一步提出了一种鲁棒静态输出反馈控制策略, 从而实现稳定的队列跟踪性能. 这些工作为车辆队列在面对不确定性问题时提供了理论支撑, 促进了高效、鲁棒车辆队列控制策略的设计与实现.

近年来, 滑模控制 (sliding mode control, SMC) 算法由于其具有良好的鲁棒性和对不确定参数的低敏感性, 已成为队列控制的最重要研究方向[82]. SMC 算法由苏联科学家 Utkin[83] 于上世纪 70 年代提出, 它将系统状态轨迹稳定在一个预定的滑动面上, 其基本原理是通过设计控制律使系统状态轨迹一旦到达某个预定的滑动面后, 即使有系统参数不确定性和外部扰动, 系统状态也能够沿该滑动面稳定地达到期望的平衡状态. 这种算法在队列控制应用中, 需要构建关于车辆之间距离和速度差的函数, 反映队列中每辆车的理想动态行为[84]. 值得注意的是, SMC 的滑模面与趋近律的设计将直接影响控制器的控制效果. 为此, Wang 等[85] 利用扰动观测器和改进的多幂趋近律, 提出了一种集成式的 SMC 方法的纵向车辆队列控制策略. Devika 等[86] 考虑到气动制动系统的迟滞特性, 设计了一种基于变时间距策略的滑模控制器, 从而保障队列稳定行驶. Ma 等[87] 提出一种基于分层模糊逻辑的车辆队列变结构 SMC 方法, 该方法能够自适应地补偿由参数不确定性和外部干扰所引起的状态误差. 然而, 车辆队列控制不仅需确保每辆车的稳定驾驶, 还要保持期望的队列间距. 为此, Kwon 等[27] 开发了一种联合式的 SMC 方法, 旨在实现保障车辆队列的弦稳定性. 此外, 为减少初始距离误差对队列稳定性的影响, 文献 [88] 提出一种考虑等时车头距离的 SMC 策略. 该策

略通过设计新的距离误差函数, 能将具有任意初始值的距离误差转化为初始值为零的距离误差, 从而显著提升了队列系统的容错能力. 针对车辆队列中的复杂道路环境工况, 出现了一种多模态切换的队列控制器, 其可做出正常、紧急和过激操作的决策[89]. 此外, 为降低队列通信负载, Xiao 等[31] 设计了一种高阶滑模控制器, 用以估计车队中车辆的位置、速度和加速度等关键信息. 在车辆队列控制中, SMC 方案对系统不确定性和外部扰动展现出独特的优势, 然而其固有的抖振问题在复杂路况和多车协同场景下对系统稳定性与控制精度构成挑战, 阻碍了其进一步的推广应用.

MPC 作为一种先进的过程控制方法, 其核心思想是使用系统的数学模型预测未来一段时间内的系统行为, 基于这些预测来优化当前的控制输入[90]. MPC 自 20 世纪 70 年代末期兴起以来, 由于其在处理多变量、多约束和非线性系统问题中表现出优越的性能, 已在汽车、电力系统和航空航天等众多工业领域得到广泛应用[91]. 具体而言, MPC 算法在每个控制周期开始时, 根据当前系统状态和已知的未来扰动信息, 通过系统的数学模型预测未来一段时间内系统的行为. 该方法需要处理一个有限时间优化问题, 其目的是在确保满足系统物理约束条件的前提下实现性能指标的最小化. 优化结果将生成一系列未来的控制输入序列, 并将第 1 个输入施加到实际系统中. 在下一个控制周期中, MPC 算法将根据新的系统状态重新进行预测和优化, 这种策略被称为滚动时域优化或递推优化. 相较于传统的 PID 控制、鲁棒控制以及 SMC 方法, MPC 在处理复杂系统中的模型不确定性、非线性驾驶人行为以及条件约束方面展现出显著优势. 然而, MPC 需要在线实时求解优化问题, 特别是在复杂系统或高速采样频率下, 这可能导致较高的计算负担. 随着计算机硬件性能的显著提升, 近年来 MPC 已广泛应用于车辆队列控制[92]. 此外, Kianfar 等[93] 设计了一种基于 MPC 的集中式车辆队列控制算法, 有效缓解了由领航车辆加速度变化过快引起的队列振荡现象. 针对具有单向通信拓扑和未知期望轨迹的异质车辆队列, Zheng 等[94] 提出了一种分布式 MPC 算法, 并给出队列渐近稳定的充分条件. 此外, 为解决车辆队列通信失效问题, Nunen 等[95] 通过将前车预测的加速度保存至预测存储缓冲器中, 并共享给队列中其他车辆, 从而保证队列稳定性. 针对队列求解过程中面临的计算负担和通信延迟影响, Feng 等[96] 提出了一种基于 Tube 的 MPC 算法来保证队列高效运行. 另一方面, 为了确保在前车行为不确定的情况下能够保持安全车距, Massera 等[97] 设计一种基于范数约束的鲁棒 MPC, 实现了对车辆间距的精确控制与安全性保障. 这种方法包括前馈控制和反馈控制, 其反馈控制模块能够实时减轻由动力学的不确定性引起的系统偏差, 而前馈控制模块负责保证队列能够按照期望轨迹运行. 这类鲁棒与模型预测结合的方法本质上是通过求解最优问题来确定一系列鲁棒不变集, 从而构建管状扰动区间来约束不确定行为[98]. 值得注意的是, 上述鲁棒模型预测控制方法不仅在实际应用中具有高效的适应性和低成本优势, 而且还能在保障车辆队列安全运行的前提下, 有效应对各种不确定性和外部干扰.

2.3 基于数据驱动的队列控制方法

基于数据驱动的队列控制方法是利用大规模的实时数据, 尤其是交通流量和车辆行为数据, 进行智能优化与决策的一种方法[99]. 与传统的基于物理模型的控制方法不同, 数据驱动控制方法依赖数据的采集与分析, 在不需要对复杂系统进行精确建模的前提下, 通过学习历史数据中的规律, 优化系统的调度与控制策略. 这种方法特别适用于那些难以建立精确数学模型、系统行为高度非线性或动态变化的复杂系统, 如智能交通系统、智能网联车辆等领域[99]. 基于数据驱动的队列控制方法通过实时数据反馈和深度学习等技术, 能够实现更加灵活和自适应的控制策略, 从而有效提升系统的运行效率和稳定性.

在智能网联车辆队列控制中, 基于数据驱动的控制方法可以分为几类: 1) 基于统计学习的队列控制方法, 该方法通过对历史交通数据的分析, 挖掘系统的内在规律, 建立预测模型并进行决策优化. 例如, 使用支持向量机或回归分析方法预测交通流量的变化趋势[100]. 2) 基于强化学习的队列控制方法, 强化学习通过智能体与环境的交互, 不断调整控制策略, 以最大化系统长期收益. 强化学习能够在动态环境中灵活应对, 并通过奖惩机制优化队列控制策略, 特别适用于智能网联车辆的跟驰控制与车道变换决策等任务[101]. 3) 深度学习方法也被广泛应用于数据驱动的队列控制中, 特别是深度强化学习, 其能够处理高维度、非线性的交通系统状态, 从而实现高效的车队控制和调度[102]. 其中, 基于数据驱动的队列控制方法不依赖传统控制方法所需的精确物理模型, 能够在大规模数据的支持下, 从实际交通状况中学习有效的控制策略, 避免了传统模型在面对复杂、动态环境时的局限性. 此外, 数据驱动控制方法具有较强的

自适应能力, 能够根据实时数据对控制策略进行动态调整, 特别是在应对复杂交通流变化时展现出较好的灵活性. 随着计算能力和数据采集技术的提升, 数据驱动方法的实时性和精度得到了显著提高, 能够为智能网联车辆提供更为高效、稳定的队列控制方案.

较为典型的数据驱动队列控制方法是基于机器学习的控制策略. Kim 等[103] 提出了一种回归分析方法, 利用历史车辆行为数据预测车辆队列的演化, 并据此调整车辆的速度和间距, 以优化车队的稳定性和通行效率. 其本质上属于深度学习范畴, 该方法的优势在于计算简便, 适用于数据较为简洁的环境, 但缺乏对复杂非线性特征的处理能力. 图模型在车辆队列控制中的应用也受到越来越多的关注, 由于智能网联车辆之间的信息交互和协作具有明显的图结构特征, 图模型可以通过模拟车与车之间的相互作用来优化车队控制策略[104]. Wei 等[105] 提出了一种基于图神经网络的车队协同控制方法, 利用图模型建立车与车之间的相互依赖关系, 并通过图神经网络进行信息传递和控制优化, 该方法通过精确刻画智能网联车辆间的交互关系, 进一步促进了大规模车队系统的协同优化. 此外, 研究者将深度学习与传统控制方法相结合, 以利用深度神经网络强大的数据学习能力弥补传统方法的不足[106-108]. Dong 等[109] 提出了一种基于深度神经网络模型预测控制的方法, 通过学习大量的交通数据和车辆行为模式, 能够精确预测车辆队列的演化过程, 并优化车辆之间的控制策略. Basile 等[110] 通过使用长短时记忆人工神经网络, 结合实时交通流和环境感知信息, 提出了一种基于深度学习的车队队列控制方法, 该方法能够更好地应对车辆队列在动态变化中的非线性和时序性特征. 由此可见, 深度学习与传统控制方法结合为数据驱动控制器的设计提供了新的视角, 具有巨大的应用潜力, 但仍面临实时性和计算复杂度等挑战.

强化学习 (reinforcement learning, RL) 是一种通过试错交互学习最优控制策略的方法, 其核心思想是智能体在环境中不断尝试不同的控制输入, 并根据奖励调整其策略, 以实现长期收益最大化. 在智能网联车辆的队列控制中, 传统优化方法往往依赖准确的动力学建模, 而强化学习方法可以在不完全建模的情况下, 通过数据驱动的方式学习最优控制策略, 从而增强系统的适应性和鲁棒性. 近年来, 深度强化学习、基于模型的强化学习以及多智能体强化学习等方法被广泛应用于智能网联车辆队列控制问题[111]. 深度强化学习结合了深度神经网络和强化学习框架, 通过高维状态空间的特征提取与策略优化, 实现复杂动态环境下的最优控制. 在智能网联车辆的队列控制中, 深度强化学习方法主要用于跟驰控制、换道决策、能耗优化等任务[112]. 在具体研究方面, 近年来的工作主要围绕提高训练效率、增强策略泛化能力和降低计算成本展开. 例如, Li 等[113] 基于 Transformer 架构的强化学习方法, 使智能体能够有效关注关键状态信息, 从而提升复杂环境下的决策能力. 此外, 模仿学习被引入深度强化学习框架, 利用专家演示数据进行预训练, 从而减少策略学习过程中因随机探索导致的不稳定性, 提高训练效率[114]. 为了克服传统深度强化学习方法在智能网联车辆控制中存在的收敛速度慢、探索效率低的问题, 研究人员提出了基于自监督学习和对比学习的强化学习框架. 这些方法通过从大量无标签数据中提取有用信息, 提高了策略的泛化能力和环境适应性[115]. 例如, 在高速公路合流场景中, 自监督学习可以帮助智能体更快识别最佳合流策略, 从而提高交通流效率和安全性. 在算法方面, 深度确定性策略梯度由于能够直接优化连续控制输入, 被广泛用于车辆跟驰和队列间距控制[116]. 此外, 近端策略优化通过策略裁剪机制增强了训练稳定性, 在复杂交通环境下的收敛效果更优[117]. 双延迟深度确定性策略梯度在深度确定性策略梯度基础上引入双 Q 网络和延迟更新机制, 进一步抑制 Q 值过估计, 提高学习稳定性[118]. 后续的工作将进一步融合多目标优化和元学习方法, 以提高深度强化学习在智能网联车辆队列控制中的适应性[119].

基于模型的强化学习 (MBRL) 结合环境动力学建模和强化学习策略优化, 从而实现了在提高采样效率的同时, 减少对真实交互数据的依赖[120]. MBRL 方法的核心思想是通过学习一个近似的环境模型, 使智能体能够在虚拟环境中进行策略优化, 从而减少对昂贵的真实世界数据的需求. 近年来, MBRL 主要应用于车队跟驰控制、队列协同决策、节能优化等任务[121]. 具体而言, 工作主要聚焦于提高动力学模型的准确性、增强策略的泛化能力, 以及优化基于模型的规划方法. 例如, 一些研究采用高斯过程和基于变分推理的深度动力学模型进行车辆动力学建模, 从而提高模型的可解释性和可靠性. 此外, Transformer 架构和图神经网络被用于智能网联车队的复杂交互关系建模, 使得 MBRL 能够更精准地预测车辆之间的相互影响. 在智能网联车辆队列控制中, MBRL 能够结合模型预测控制方法, 实现高效的规划与决策. 此外, 研究人员提出了基于贝叶斯优化

的方法, 用于处理智能网联车队在复杂交通环境中的不确定性问题[122]. 通过构建不确定性感知的动力学模型, MBRL 能够在混合交通环境 (自动驾驶车辆与人类驾驶车辆共存) 中做出更安全、稳定的决策. 在具体应用方面, MBRL 已经在智能网联车队的协同控制、节能优化和动态队列调整等任务中展现出了显著优势. 在动态交通环境下, 基于 MBRL 的方法能够预测未来交通流变化, 并通过预先调整控制策略, 减少拥堵和能耗. 此外, 在车路云通信辅助的智能网联车队控制中, MBRL 结合强化学习的协同规划能力, 使得车队能够更高效地调整队列结构, 提高整体交通效率.

在智能网联车辆的队列控制中, 多个车辆需要协同决策以实现整体交通流的最优调度. 因此, 多智能体强化学习 (multi-agent reinforcement learning, ARL) 作为一种有效的求解方法, 已逐渐成为研究的焦点. MARL 的基本思想是在多智能体环境中, 通过共享或独立的奖励机制, 促进智能体之间的协作, 从而学习到稳定且高效的决策策略[123]. MARL 方法主要包括两类范式: 集中训练-分散执行 (ventralized training and decentralized execution, CTDE) 和完全分布式学习. 在 CTDE 范式中, 训练阶段利用全局信息进行智能体策略的优化, 然而在执行阶段, 智能体仅依赖自身的局部观测进行决策, 这一特性大大提高了算法的可扩展性与适应性. 典型的 CTDE 算法包括多智能体深度确定性策略梯度和价值分解网络, 其中深度确定性策略梯度在处理多智能体间复杂互动时表现出色, 完全分布式学习则通过对全局价值函数的分解, 有效促进了个体智能体之间的协作[124]. 此外, 完全分布式学习方法则关注每个智能体在缺乏全局信息的情况下, 依赖局部观测与邻近智能体的信息进行独立决策. 这类方法强调在动态变化的环境中, 智能体间通过直接交互来实现协作与信息共享.

表 1 综合总结和分析了上述智能网联车队列控制方法的分类、优缺点分析及相应文献. 可以看出, 智能网联车队列控制主要可以分为机理模型方法、数据驱动方法和深度学习方法 3 大类, 每种方法均有不同的应用特点和优势. 在机理模型方法中, 滑模控制和模糊控制被广泛应用. 滑模控制方法具有较强的鲁棒性和抗干扰能力, 适用于复杂的动态环境, 但其缺点是设计较为复杂, 且对模型的不确定性要求较高. 模糊控制方法则能够通过经验规则处理不确定性, 但控制精度受限于规则的构建和计算的复杂性. 数据驱动方法, 如强化学习和深度学习, 在智能网联车队列控制中具有较高的适应性和自我学习能力, 能够在复杂的环境中实现较好的控制性能. 然而, 上述方法对数据的依赖性较强, 需要大量训练数据, 且计算成本较高. 总体而言, 虽然机理模型方法和数据驱动方法各有优缺点, 而随着深度学习方法的出现, 能够进一步提升智能网联车队列控制的准确性和适应性. 未来, 如何平衡计算复杂度和控制精度, 结合不同方法的优势, 将是该领域研究的重要方向.

表1　智能网联车辆队列控制算法分析

分类	方法	文献	优势	劣势
机理模型方法	鲁棒控制	[77-81]	对模型不确定性和外部扰动有较强适应性, 易于保证系统稳定性	设计复杂, 需先验建模, 难以处理高维动态环境
	滑模控制	[82-89]	控制精度高, 抗干扰能力强, 适合多变工况	容易产生“抖振”现象, 控制律不够平滑
	模型预测控制	[90-98]	能考处理系统未来动态与约束, 适合负责任务优化	计算量大, 需高性能硬件支撑, 对模型依赖性强
数据驱动方法	深度学习控制	[100-105]	能自动提取复杂特征, 适应非线性、未知环境	可解释性差, 训练数据需求高, 泛化能力有限
	强化学习控制	[111-124]	适合序列决策问题, 可持续自学习, 具备实时调整能力	收敛慢, 样本效率低, 探索过程中可能导致系统不稳定
	深度 + 机理控制	[106-110]	融合先验知识与数据优势, 提高泛化性与安全性	融合设计复杂, 需兼顾模型精度与学习灵活性

2.4　多目标优化控制

智能网联汽车在行驶过程中, 需要同时关注队列间距、能量消耗、通勤效率、网络安全及乘坐体验等因素. 该目标对于推动智能交通系统的发展、增强道路安全水平、提高能源效率和提升用户驾驶体验具有重要的意义[125]. 近年来, 上述因素在车辆队列多目标优化研究中得到广泛关注, 其主要致力于安全性、经济性和舒适性这 3 大核心目标的平衡[126]. 队列控制中的安全性是指在车辆队列行驶过程中确保各车辆间保持安全距离, 并能快速响应突发情况以保障队列内所有车辆的安全行驶. 这一概念不仅包括防止物理碰撞, 也涉及通过预防性控制措施减少潜在风险, 确保车队在各种道路条件和交通环境下的行驶安全. 当前, 车辆队列控制安全性研究主要集中在以下几个方面: 一是通过高精度的传感器和通讯技术提高车辆对周围环境的感知能力, 增强车队

在复杂交通环境的适应性和响应速度[127]; 二是开发先进的控制算法, 优化车队内部的车辆间距控制和紧急制动机制, 以适应不同的行驶速度和道路条件[128]; 三是利用车联网技术实现车队与外部交通基础设施的网联互通, 通过实时数据交换和分析, 提前预测和避免潜在的交通风险[129]. 此外, 随着人工智能技术的融入, 车辆队列控制系统愈发智能化, 能够实时学习和调整控制策略, 从而提升车队行驶的安全性.

车辆队列控制的经济性主要是指通过优化车队行驶策略降低能源消耗, 同时提高道路利用率和行驶效率的能力[130]. 这一定义不仅涵盖单一车辆的能源效率, 还包括整个车队运行过程中的经济效益, 如通过减少空气阻力实现的燃油经济性提升、行驶时间的缩短以及交通拥堵的减轻等. 车辆队列控制在经济性方面有诸多尝试[131], 大量研究通过优化车辆间的通信技术和控制策略, 减少因频繁加速和减速导致的能源消耗, 提高能源利用效率. 此外, 一些学者致力于基于空气动力学拖曳效应来减少空气阻力, 以此提升车辆燃油经济性或电池续航里程[132]. 车辆队列控制的驾驶舒适性旨在减少乘员感受到的车辆震动, 从而提升驾乘舒适度. 驾驶舒适性不仅涉及车辆加速和转向行为, 还包括驾驶过程中的安全感和可预测性. 值得注意的是, 驾驶舒适性与驾驶经济性具有正相关特征, 可以通过减少频繁的急加速和急减速行为来提高其性能[133].

车辆队列控制技术的发展需同时兼顾安全性、舒适性与经济性, 其本质属于一个多目标优化问题, 要求在多个冲突目标间找到一个可接受的平衡点. 一般而言, 多目标优化旨在寻找一组最佳解决方案, 通常称为帕累托前沿, 而不是单一的最优解. 现有的多目标优化方法主要分为先验方法、后验方法和交互式方法[134]. 在先验方法中, 多目标问题在获得单一解决方案之前需将其转换为单目标问题. 相反, 后验方法旨在生成一个帕累托最优集, 该集合包含彼此不相互支配的多个解决方案. 为了克服先验方法和后验方法的局限, 一种交互式方法应运而生, 这要求多目标优化算法不断进行交互匹配, 以指导搜索过程. 近年来, 帕累托最优法在车辆队列多目标优化问题中得到广泛应用, 该解集中的每个解代表队列中多个优化目标[135], 通过搜索最优帕累托前沿以达到一种最佳权衡状态. 事实上, 一般很难通过改善队列中某一辆车的行驶性能而不损害到其他车辆的性能, 从而实现多个优化目标间的有效平衡. 面对安全性、舒适性和经济性这 3 个相互竞争的多目标优化问题, 大量优化方案相继涌现, 包括粒子群优化[136]、模拟退火算法[137] 和遗传算法[138] 等. 这些方法可以有效揭示目标间的相互影响和权衡, 为决策者提供一个综合考量各个目标的决策基础.

粒子群优化 (PSO) 算法是一种模拟鸟群、鱼群等社会行为的优化算法, 由 Kennedy 等[136] 于 1995 年提出, 该算法基于群体协作的原理, 通过追踪并模仿群体中表现最优的个体来更新自己的位置和速度. 粒子群优化算法由于其简单性和高效性, 在多目标优化领域得到了广泛应用[139]. 其在优化过程中, 每个粒子都保存自己的位置和速度, 同时记录下自己的最佳位置 (个体极值) 和整个群体的最佳位置 (全局极值). 为了提高多目标优化的收敛速度, 一些学者利用分解理论来构建优化的粒子选择机制[140]. Zhu 等[141] 提出一种外部存储集引导的择优策略, 通过分配粒子对多目标问题进行优化, 从而加速帕累托前沿收敛. Dupont 等[142]利用切比雪夫理论来设计动态加权聚合函数, 从而增强粒子选择的更新机制. 相应地, 基于代理辅助技术的优化粒子群算法得到了普遍的认可, 该算法通过引用帕累托存储更新机制来增强外部存储器中解的质量, 从而有效促进算法快速向最优解方向收敛[143].

遗传算法 (GA) [144] 是一种模拟自然选择和遗传学原理的启发式算法, 于 1975 年提出. 该算法基于达尔文的进化论, 通过模拟自然界中生物的遗传和进化机制, 以解决优化和搜索问题. 该算法根据交叉、变异和选择等遗传操作对这些染色体进行迭代, 从而在迭代过程中生成新的个体. 而每一代个体的适应度由一个预定的适应度函数决定, 该函数根据问题的目标对个体进行评估. 在多目标优化问题中, 遗传算法表现出显著的优势[145]: 一方面, 基于群体的搜索方法能够同时探索目标解空间的多个区域, 增加找到全局最优解的可能性; 另一方面, 可以通过在每一代中保留一组优秀的个体, 即非支配解集合, 从而逐步逼近真实的帕累托前沿. 遗传算法的灵活性使其能够快速与其他方法进行结合, 从而进一步提高在多目标问题中的搜索效率和解的多样性. 因此, 遗传算法成为解决复杂多目标优化问题的有效工具之一, 尤其适合于队列控制中的非凸性多目标优化问题[146]. Rulz 等[147] 提出了一种具有随机密钥的遗传算法, 用于优化容量和距离限制情况下的车辆路径跟踪问题. 此外, 遗传算法的灵活性使其能够快速与其他方法进行结合, 从而进一步提高在多目标问题中的搜索效率和解的多样性. Ma等[148] 提出了一种基于模拟退火-粒子群优化的混合算法来缓解队列经济性和安全性之间的冲突, 该算法通过全

局搜索和局部优化的结合, 能够有效地寻找到满足所有目标的最优解.

灰狼优化 (grey wolf optimization, GWO) 算法是一种受灰狼社会等级和狩猎行为启发的群体智能优化算法, 由 Mirjalili 等[149] 于 2014 年提出. GWO 算法模拟了灰狼群体中的领导层次结构和狩猎策略, 通过模拟灰狼群体追踪、包围和攻击猎物的行为来寻找全局最优解. 在 GWO 算法中, 每个解可视为群体中的一个灰狼, 根据其适应度在多个目标上的表现来分配等级. 此外, GWO 在多目标优化问题中也得到了广泛应用, 其本质是同时寻找多个互相冲突的目标函数的最优解集合[150]. 然而, GWO 生成的解决方案可能会集中在搜索空间的某些区域, 而无法覆盖整个可能的解空间, 从而导致找到的解缺乏多样性和广度. 为了解决这个问题, Asghari 等[151] 提出了一种混沌动态灰狼优化算法, 其利用混沌映射原理引导潜在解的搜索过程, 并通过设计非线性控制参数来平衡探索与开发过程. 此外, Gupta 等 [152] 开发一种基于随机游走的改进 GWO 算法, 有效克服了 GWO 算法易于陷入局部最优的瓶颈. 基于 GWO 算法中灰狼的社会等级对决定其搜索策略影响的原则, Gao 等[153] 创新性地提出了变异灰狼优化算法, 该算法引入了新的控制参数方程, 有效减少了陷入局部最优解的概率. 此外, 将 GWO 算法与其他先进算法结合成为近年来提升算法性能的有效策略之一. 例如, Cheng 等[154] 提出了一种粒子群算法和灰狼优化算法的组合算法, 以提高优化求解速度. 相应的, Gaidhane 等[155] 建立了一种基于基于 GWO 和人工蜂群的多目标优化算法. 此类融合策略借助蜂群算法在全局搜索中的高效探索能力与 GWO 算法在局部精细搜索方面的优异性能, 形成一种动态平衡机制, 有效地平衡了探索与开发过程.

3　数据来源与系统架构

3.1　数据获取与处理

数据获取与处理是智能网联车辆队列控制的核心, 直接决定了系统的性能和智能算法的有效性[156]. 在此过程中, 主要包括车辆传感器数据、V2X 通信数据以及交通流数据等来源, 如图 4 所示.

车辆传感器数据主要来源于不同类型的传感器, 如激光雷达、毫米波雷达、摄像头和惯性测量单元. 这些传感器能够提供车辆的实时位置、速度、加速度、距离、姿态等信息. 1) 激光雷达与毫米波雷达: 这两种传感器能够提供高精度的距离和速度数据, 尤其适用于复杂环境中的车辆检测. 激光雷达在精

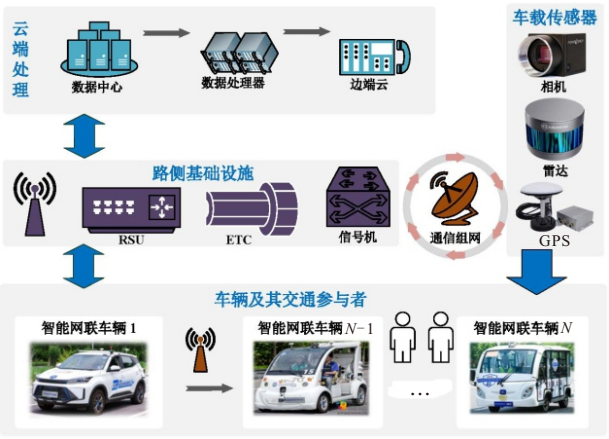

图4　智能网联车数据结构框架

准获取环境障碍物信息方面具有显著优势, 但受天气等因素影响较大; 毫米波雷达则能够在较差天气条件下保持较好的性能, 并具有较强的抗干扰能力. 2) 摄像头: 摄像头通过图像处理算法提供道路及车辆的视觉信息, 常用于检测道路标志、交通信号灯、行人及其他道路用户. 在队列控制中, 摄像头的图像数据能够辅助实现交通情景的理解和决策支持. 3) 惯性测量单元: 提供的加速度与角速度数据, 能够帮助智能网联车辆进行精确的状态估计, 尤其在高速行驶时对车辆动态行为的实时预测至关重要.

V2X (vehicle-to-everything) 通信技术作为智能网联车辆的核心通信技术, 通过车与车 (vehicle-to-everything, V2V) 和车与基础设施 (vehicle-to-infrastructure, V2I) 的信息交互, 能够提供车辆间的实时状态信息、交通信号和道路条件等数据. 这些数据对于车队队列的优化、行驶安全性和交通流的顺畅性至关重要[157]. 具体而言: 1) V2V 通信. V2V 通信使得车辆能够共享自身的实时位置信息、速度、加速度等数据, 进一步提升车队间的协同控制能力. 例如, 在高速公路上, 车与车之间可以通过通信协调车速、车间距, 优化车队的行驶效率, 降低交通拥堵风险. 2) V2I 通信. V2I 通信能够实现车与交通基础设施之间的信息交换, 通过与路侧单元之间的通信, 车辆可以接收到红绿灯信号、道路交通状况、施工信息等, 有助于优化路径选择和动态速度调整. 交通流数据主要来源于交通监控系统、地面感应环和其他智能交通设施. 该类数据能够反映路段的实时交通密度、车速、交通流量等关键信息, 作为车队控制决策的重要依据. 其中, 交通监控系统通过布设在路段上的摄像头与传感器, 交通监控系统能够实时捕捉交通流的变化, 提供流量、速度等数据, 帮助车队控制系统了解当前的交通状况. 而地面感应环能够通过感应车辆的通过情况, 准确测量车流量和车速, 并为队列

控制系统提供实时的交通流量信息.

由于智能网联车辆队列控制系统中涉及多源异构数据的融合, 如何有效处理和融合来自不同传感器、通信设备及交通流的实时数据, 是确保控制算法高效运行的关键. 常见的数据融合方法包括卡尔曼滤波、粒子滤波等, 这些方法能够处理来自多个传感器的噪声数据, 提供更为准确的状态估计[158-159]. 此外, 随着深度学习和自监督学习等技术的快速发展, 研究人员已开始利用这些新兴技术提升数据处理与融合的精度与效率. 例如, 通过深度神经网络对复杂环境中的传感器数据进行学习, 能够有效提高环境感知的精度, 并为决策系统提供更可靠的输入.

3.2 计算架构

在智能网联车辆队列控制系统中, 计算架构的设计直接决定了系统的实时性、扩展性与鲁棒性. 随着智能网联技术的发展, 传统的集中式计算架构逐渐向分布式架构与边缘计算相结合的模式过渡. 当前, 计算架构主要集中在以下几个方面的研究与优化.

分布式计算架构是智能网联车辆队列控制的核心组成部分, 能够实现车辆之间的协同计算与信息共享. 在这一架构下, 每辆车作为独立的智能体, 拥有自身的计算能力, 并通过车与车或车与基础设施通信进行数据交换和协同控制[160]. 分布式架构的优势在于其能够降低单点故障的风险, 增强系统的鲁棒性, 并能够实现灵活的车队控制. 然而, 分布式系统的设计也面临着数据同步、网络延迟、带宽限制等挑战, 这些问题需要通过高效的通信协议和计算模型来解决. 目前的研究多集中在通过加强 V2X 通信技术的应用, 优化车队间的数据传输效率与协同策略[161].

为进一步提升计算架构的实时性与可扩展性, 边缘计算和云计算的结合逐渐成为智能网联车辆队列控制中的发展趋势. 边缘计算将数据处理从云端转移到车载计算设备或路侧单元, 使得车辆能够更快速地对环境变化作出反应, 减少了数据传输和处理的延迟. 云计算则可以在全局范围内进行大规模数据存储与分析, 并为车队提供长期的规划与优化支持. 近年来, 边缘计算和云计算的结合已成为智能交通系统中重要的计算架构设计模式. 边缘计算通过近实时的数据处理能力, 实现了车队的局部优化和即时决策, 而云计算则通过提供强大的计算能力和海量数据分析, 进一步提升了车队控制的全局性能[162].

随着车队规模的增大, 智能网联车辆队列控制系统需要采用多层次计算架构来提高其可扩展性和容错性. 该架构通常包括感知层、决策层和执行层, 感知层负责获取环境数据并进行初步处理, 决策层根据处理后的数据进行队列控制决策, 执行层则负责车辆的运动控制. 在多层次架构中, 感知层主要涉及车辆传感器、交通流数据的获取与处理, 决策层则通过算法进行车队调度与路径优化, 而执行层则控制车辆的具体运动行为[163]. 通过分层设计, 各层之间的协同能够实现高效的车队管理和动态调度, 尤其是在大规模车队或复杂交通环境中, 能够保证系统的灵活性与响应速度.

3.3 测试方法与验证

测试方法与验证是智能网联车辆队列控制系统中至关重要的一部分, 通过合理的测试方法, 可以验证控制算法的有效性、稳定性以及在实际环境中的适应性. 当前, 智能网联车辆队列控制系统的测试方法主要包括仿真测试、实车测试和基于场景的测试方法[164].

仿真测试是智能网联车辆队列控制系统验证中的重要手段. 通过仿真平台 (如 SUMO、VISSIM 等), 研究人员可以在虚拟环境中模拟不同的交通情景和车队行为, 从而评估队列控制算法在各种交通场景中的表现[165]. 仿真测试具有成本低、可控性强等优点, 能够在多种交通模式下验证算法的效果. 然而, 仿真测试的局限性在于其无法完全模拟现实世界中的所有复杂因素, 如突发交通事故、动态路况等. 因此, 虽然仿真测试能够为算法提供初步验证, 但仍需要通过实车测试进一步验证其在现实环境中的稳定性和有效性[166]. 实车测试能够为智能网联车辆队列控制系统提供最真实的验证. 在实际交通环境中, 车队的控制策略需要应对多变的路况、交通密度和其他不可预见的因素. 通过实车测试, 研究人员能够评估算法在复杂、动态交通环境下的表现, 并根据测试结果对算法进行调优. 近年来, 实车测试已成为智能网联车辆队列控制系统验证的关键手段.

为了验证智能网联车辆队列控制系统在各种复杂交通情境中的适应性, 基于场景的测试方法应运而生. 该方法通过构建不同的交通场景 (如复杂交叉口、密集车流、紧急避障等) 来评估系统在面对突发情况时的表现. 基于场景的测试方法能够模拟多种极限情况下的车队行为, 帮助研究人员发现算法在极端情形下的潜在问题. 例如, 在紧急制动场景下, 车辆能否及时响应、是否能够保持队列稳定等问题, 都可以通过基于场景的测试得到有效验证.

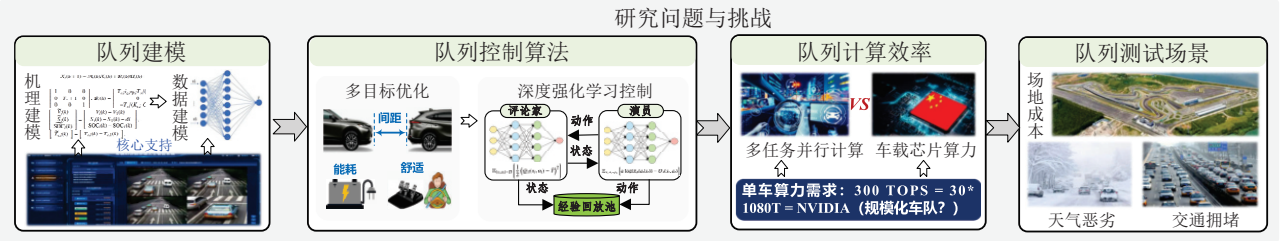

图5　智能网联车辆队列研究问题与挑战.

4　问题分析与挑战

在智能网联车辆队列控制的研究中, 尽管已取得一定的进展, 但仍存在若干亟待解决的难题. 本节从建模、控制和数据计算 3 个角度出发, 对目前的研究问题与挑战进行梳理, 如图 5 所示.

4.1　建　模

智能网联车队列的建模方法主要分为机理建模和数据驱动建模两大类. 机理建模依托交通流理论和车辆动力学, 能够较好地反映交通系统的内在机理, 特别是在稳定、单一的交通环境中能够给出可解释且较为精确的预测. 然而, 在动态复杂场景下, 其线性化假设失准, 面对强非线性、突发交通事件及极端气象条件时, 预测精度显著下降. 而数据驱动建模凭借深度学习、大规模数据挖掘等手段, 能够实时捕捉非线性特征并适应复杂环境, 但对高质量数据依赖严重, 易受噪声、缺失与分布漂移影响, 且在大规模、高维异构数据面前泛化能力有限. 因此, 如何提升数据驱动模型的鲁棒性和准确性, 降低对高质量数据的过度依赖, 仍是未来研究的核心难点.

4.2　控　制

对于智能网联车队列传统的优化控制方法通常集中在单目标或简易的多目标形式出现, 这些方法在理想化交通环境中表现良好, 随着网联规模扩大与场景复杂化, 其局限逐渐凸显. 近年来, 强化学习、深度学习等数据驱动控制方法为高动态、不确定环境提供了新思路, 特别是面向实时调度与动态优化方面优势明显. 然而, 此类方法收敛速度较慢、控制稳定性不足, 在实际道路中实时性与可靠性亟待提升. 因此, 未来应聚焦多目标优化与实时控制的深度融合, 开发适应复杂交通环境的鲁棒控制算法.

4.3　数据与计算

智能网联车队列控制依赖海量数据, 面对实时性和精准性要求较高的应用场景, 高效获取和处理数据成为关键瓶颈. 现有的计算架构难以满足大规模、异构交通数据的实时需求, 尤其在边缘计算环境下, 数据传输和计算分配仍需优化, 以降低延迟并提升可靠响应. 同时, 伴随个人驾驶数据的采集和智能网联车辆的普及, 数据隐私和风险同步上升. 如何在保障数据安全和隐私的前提下, 提升数据利用率, 成为未来智能网联车队列控制研究中的重要方向.

4.4　测　试

智能网联车队列测试场景的多样性与复杂性使得实验设计和测试数据的获取愈发困难. 真实交通环境涉及道路状况、气候变化、驾驶员行为等多重因素交织, 增加了系统验证的难度. 现有测试手段难以覆盖大规模车队和复杂交通网络, 亟需设计出高效、可靠的大规模仿真和测试平台. 此外, 随着智能网联车辆自主决策能力的提高, 全面、系统的安全评估方案开发也更显迫切. 未来的测试研究聚焦: 构建精确、全面的测试评估指标和标准, 优化仿真平台的效率和逼真度, 并推动跨领域、跨行业的联合测试, 确保智能网联车队列控制系统在复杂动态环境下安全高效地运行.

5　结　语

智能网联车辆作为智慧交通系统中的关键组成部分, 具备巨大的研究与应用潜力. 本文从车辆队列建模、队列控制策略以及数据驱动系统架构等角度, 全面梳理了相关领域的研究进展. 首先, 机理建模与数据驱动建模的比较为理解智能网联车辆队列控制提供了理论基础, 揭示了两者在准确性、可解释性和适应性等方面的优势与局限; 其次, 优化控制方法在智能网联车辆队列系统中的应用, 特别是多目标优化策略的提出, 为应对复杂交通环境中的实时性与动态性挑战提供了新的思路. 本文同时探讨了数据驱动控制策略在智能网联车辆队列管理中的实际应用路径, 提出了数据获取、系统架构以及技术实现中的若干关键问题和挑战, 并结合现有解决方案进行了系统分析.

参考文献 (References)

[1]　陈虹, 郭露露, 边宁. 对汽车智能化进程及其关键技术的思考[J]. 科技导报, 2017, 35 (11): 52-59.
(Chen H, Guo L L, Bian N. On automobile intelligentization and key technologies[J]. Science & Technology Review, 2017, 35 (11): 52-59.)

[2]　Liu W, Hua M, Deng Z Y, et al. A systematic survey of

control techniques and applications in connected and automated vehicles[J]. IEEE Internet of Things Journal, 2023, 10(24): 21892-21916.

[3] Eskandarian A, Wu C X, Sun C Y. Research advances and challenges of autonomous and connected ground vehicles[J]. IEEE Transactions on Intelligent Transportation Systems, 2021, 22(2): 683-711.

[4] Cheng Z Y, Zhu J Y, Feng Z X, et al. Driving safety risk analysis and assessment in a mixed driving environment of connected and non-connected vehicles: A systematic survey[J]. IEEE Transactions on Intelligent Transportation Systems, 2025, 26(5): 5747-5781.

[5] 杨东龙, 曾乾瑜, 刘漫霞. 智能网联汽车管理立法研究及深圳市创新实践[J]. 城市交通, 2023, 21(3): 41-45.
(Yang D L, Zeng Q Y, Liu M X. Legislation of intelligent connected vehicles management and innovative practice in Shenzhen[J]. Urban Transport of China, 2023, 21(3): 41-45.)

[6] Narayanan S, Chaniotakis E, Antoniou C. Factors affecting traffic flow efficiency implications of connected and autonomous vehicles: A review and policy recommendations[J]. Advances in Transport Policy and Planning, 2020: 1-50.

[7] Chen K, Galler B A. An overview of intelligent vehicle-highway systems (IVHS) activities in North America[C]. Proceedings of the 5th Jerusalem Conference on Information Technology. Jerusalem, 1990: 694-701.

[8] Science N T C. Ensuring American leadership in automated vehicle technologies: Automated vehicles 4.0[M]. Washington: United States Department of Transportation, 2020.

[9] Kouroutakis A E. Autonomous vehicles: Regulatory challenges and the response from Germany and UK[J]. Mitchell Hamline Law Review, 2020, 46(5): 3.

[10] 严新平, 褚端峰, 刘佳仑. 智能交通发展的现状、挑战与展望[J]. 交通运输研究, 2021, 7(6): 2-10.
(Yan X P, Chu D F, Liu J L. Status quo, challenges and perspectives of intelligent transportation development[J]. Transport Research, 2021, 7(6): 2-10.)

[11] Tao J B, Klueck F, Felbinger H, et al. Automated test case generation and virtual assessment framework for UN regulation on automated lane keeping systems[J]. SAE Technical Paper Series, 2021: 2021-1-0870.

[12] 郭王虎. 智能网联汽车技术路线图 2.0 发布[J]. 智能网联汽车, 2020(6): 4.

[13] 李高磊, 李建华, 周志洪. 面向新型关键基础设施的密码应用安全性评估技术综述[J]. 网络与信息安全学报, 2023, 9(6): 1-19.
(Li G L, Li J H, Zhou Z H. Review of cryptographic application security evaluation techniques for new critical infrastructures[J]. Chinese Journal of Network and Information Security, 2023, 9(6): 1-19.)

[14] 孙航, 解瀚光, 王兆. 智能网联汽车信息安全标准体系建设与产业政策研究[J]. 中国汽车, 2018(12): 6.
(Sun H, Xie H G, Wang Z. Intelligent and connected vehicle cyber security standard construction and industry policy research[J]. China Auto, 2018(12): 6.)

[15] 高镇海, 郑程元, 赵睿. 真实与虚拟场景下自动驾驶车辆的主动安全性验证与确认综述[J]. 吉林大学学报: 工学版, 2025, 55(4): 1142-1162.
(Gao Z H, Zheng C Y, Zhao R. Review of active safety verification and validation for autonomous vehicles in real and virtual scenarios[J]. Journal of Jilin University: Engineering and Technology Edition, 2025, 55(4): 1142-1162.)

[16] Uhlemann E. Platooning: Connected vehicles for safety and efficiency[J]. IEEE Vehicular Technology Magazine, 2016, 11(3): 13-18.

[17] 王柠莎, 陈岳飞, 柏文琦. 智能网联汽车测试装备移动承载平台关键技术及应用[J]. 计量科学与技术, 2025, 69(2): 45-54.
(Wang N S, Chen Y F, Bo W Q. Key technologies and applications of mobile carrier platform for intelligent connected vehicle testing equipment[J]. Metrology Science and Technology, 2025, 69(2): 45-54.)

[18] Ullmann L H. What does waymo see? A critical inquiry into urban surveillance by autonomous vehicles[D]. Los Angeles: University of California, 2025.

[19] 李克强. 我看智能网联汽车十年发展[J]. 智能网联汽车, 2022, 3: 6-9.

[20] 刘思杨, 张云飞. 从智能网联 1.0 到智能网联 2.0: 面向双智的实时数字孪生城市构建[J]. 电信科学, 2023, 39(3): 32-44.
(Liu S Y, Zhang Y F. From ICV 1.0 to ICV 2.0: real-time digital twin city construction for the coordinated development of ICV and smart city[J]. Telecommunications Science, 2023, 39(3): 32-44.)

[21] Li S E, Zheng Y, Li K Q, et al. Dynamical modeling and distributed control of connected and automated vehicles: Challenges and opportunities[J]. IEEE Intelligent Transportation Systems Magazine, 2017, 9(3): 46-58.

[22] Yang J R, Chu D F, Lu L P, et al. Model-data-driven control for human-leading vehicle platoon[J]. Proceedings of the Institution of Mechanical Engineers, Part D: Journal of Automobile Engineering, 2025, 239(7): 2616-2636.

[23] Ma Y S, Che W W, Deng C, et al. Data-driven distributed vehicle platoon control for heterogeneous nonlinear vehicle systems[J]. IEEE Transactions on Intelligent Transportation Systems, 2024, 25(3): 2373-2381.

[24] 左志强, 刘正璇, 王一晶. 基于车路云一体化的混合交通系统优化控制综述[J]. 控制与决策, 2023, 38(3): 577-594.
(Zuo Z Q, Liu Z X, Wang Y J. A survey of optimal control for mixed traffic system with vehicle-roadcloud integration[J]. Control and Decision, 2023, 38(3): 577-594.)

[25] Dunbar W B, Caveney D S. Distributed receding horizon control of vehicle platoons: Stability and string stability[J]. IEEE Transactions on Automatic Control, 2012, 57(3): 620-633.

[26] Li S B, Li K Q, Rajamani R, et al. Model predictive multi-objective vehicular adaptive cruise control[J]. IEEE Transactions on Control Systems Technology, 2011, 19(3): 556-566.

[27] Kwon J W, Chwa D. Adaptive bidirectional platoon control using a coupled sliding mode control method[J]. IEEE Transactions on Intelligent Transportation Systems, 2014, 15(5): 2040-2048.

[28] Lin F, Fardad M, Jovanovic M R. Optimal control of vehicular formations with nearest neighbor interactions[J]. IEEE Transactions on Automatic Control, 2012, 57(9): 2203-2218.

[29] Knorn S, Donaire A, Agüero J C, et al. Passivity-based control for multi-vehicle systems subject to string constraints[J]. Automatica, 2014, 50(12): 3224-3230.

[30] Bamieh B, Jovanovic M R, Mitra P, et al. Coherence in large-scale networks: Dimension-dependent limitations of local feedback[J]. IEEE Transactions on Automatic Control, 2012, 57(9): 2235-2249.

[31] Xiao L Y, Gao F. Practical string stability of platoon of adaptive cruise control vehicles[J]. IEEE Transactions on Intelligent Transportation Systems, 2011, 12(4): 1184-1194.

[32] Ploeg J, Shukla D P, van de Wouw N, et al. Controller synthesis for string stability of vehicle platoons[J]. IEEE Transactions on Intelligent Transportation Systems, 2014, 15(2): 854-865.

[33] 秦严严, 张健, 陈凌志. 手动-自动驾驶混合交通流元胞传输模型[J]. 交通运输工程学报, 2020, 20(2): 229-238.
(Qin Y Y, Zhang J, Chen L Z. Cell transmission model of mixed traffic flow of manual-automated driving[J]. Journal of Traffic and Transportation Engineering, 2020, 20(2): 229-238.)

[34] Zheng L J, Tian C, Sun D H, et al. A new car-following model with consideration of anticipation driving behavior[J]. Nonlinear Dynamics, 2012, 70(2): 1205-1211.

[35] Hoogendoorn S, Knoop V. Traffic flow theory and modelling[J]. The Transport System and Transport Policy: An Introduction, 2013: 125-159.

[36] Treiber M, Hennecke A, Helbing D. Congested traffic states in empirical observations and microscopic simulations[J]. Physical Review E, 2000, 62(2): 1805-1824.

[37] Kesting A, Treiber M, Helbing D. General lane-changing model MOBIL for car-following models[J]. Journal of the Transportation Research Board, 2007, 1999(1): 86-94.

[38] Kesting A, Treiber M, Helbing D. Enhanced intelligent driver model to access the impact of driving strategies on traffic capacity[J]. Philosophical Transactions of the Royal Society A: Mathematical, Physical and Engineering Sciences, 2010, 368(1928): 4585-4605.

[39] Treiber M, Kesting A. The intelligent driver model with stochasticity-new insights into traffic flow oscillations[J]. Transportation Research Procedia, 2017, 23: 174-187.

[40] Wang Y L, Feng Y H. IDM-follower: A model-informed deep learning method for car-following trajectory prediction[J]. IEEE Transactions on Intelligent Vehicles, 2024, 9(6): 5014-5020.

[41] Bando M, Hasebe K, Nakanishi K, et al. Analysis of optimal velocity model with explicit delay[J]. Physical Review E, 1998, 58(5): 5429.

[42] Bando M, Hasebe K, Nakayama A, et al. Dynamical model of traffic congestion and numerical simulation[J]. Physical Review E, 1995, 51(2): 1035-1042.

[43] Jin S, Wang D H, Xu C, et al. Staggered car-following induced by lateral separation effects in traffic flow[J]. Physics Letters A, 2012, 376(3): 153-157.

[44] Jiang R, Wu Q, Zhu Z. Full velocity difference model for a car-following theory[J]. Physical Review E, 2001, 64(1): 017101.

[45] Zhou J, Shi Z K, Cao J L. Nonlinear analysis of the optimal velocity difference model with reaction-time delay[J]. Physica A: Statistical Mechanics and its Applications, 2014, 396: 77-87.

[46] He Z C, Wang Y M, Sun W B, et al. Modelling car-following behaviour with lateral separation and overtaking expectation[J]. Transportmetrica B: Transport Dynamics, 2016, 4(3): 223-239.

[47] Wang J F, Sun F X, Cheng R J, et al. An extended heterogeneous car-following model with the consideration of the drivers' different psychological headways[J]. Physica A: Statistical Mechanics and its Applications, 2018, 506: 1113-1125.

[48] Zhao H, Sun D, Zhao M, et al. Combined longitudinal and lateral control for heterogeneous nodes in mixed vehicle platoon under V2I communication[J]. IEEE Transactions on Intelligent Transportation Systems, 2021, 23(7): 6751-6765.

[49] Bayuwindra A, Ploeg J, Lefeber E, et al. Combined longitudinal and lateral control of car-like vehicle platooning with extended look-ahead[J]. IEEE Transactions on Control Systems Technology, 2020, 28(3): 790-803.

[50] Wang Y L, Bian N, Zhang L, et al. Coordinated lateral and longitudinal vehicle-following control of connected and automated vehicles considering nonlinear dynamics[J]. IEEE Control Systems Letters, 2020, 4(4): 1054-1059.

[51] Sharma A, Zheng Z D, Bhaskar A, et al. Modelling car-following behaviour of connected vehicles with a focus on driver compliance[J]. Transportation Research Part B: Methodological, 2019, 126: 256-279.

[52] Koopman B O. Hamiltonian systems and

transformation in Hilbert space[J]. Proceedings of the National Academy of Sciences, 1931, 17(5): 315-318.

[53] Feng Y Y, Yu S Y, Sheng E C, et al. Distributed MPC of vehicle platoons considering longitudinal and lateral coupling[J]. IEEE Transactions on Intelligent Transportation Systems, 2024, 25(3): 2293-2310.

[54] Williams M O, Kevrekidis I G, Rowley C W. A data–driven approximation of the koopman operator: Extending dynamic mode decomposition[J]. Journal of Nonlinear Science, 2015, 25(6): 1307-1346.

[55] Proctor J L, Brunton S L, Kutz J N. Dynamic mode decomposition with control[J]. SIAM Journal on Applied Dynamical Systems, 2016, 15(1): 142-161.

[56] Kutz J N, Brunton S L, Brunton B W, et al. Dynamic mode decomposition: data-driven modeling of complex systems[M]. Philadelphia: Society for Industrial and Applied Mathematics, 2016.

[57] Kung S. A new identification method and reduction algorithm viasingular value deeomposion[C]. The 12th Asilomar Conference on Circuits, Systems and Computers. Piscataway: IEEE, 1978: 11-34.

[58] Juang J N, Pappa R S. An eigensystem realization algorithm for modal parameter identification and model reduction[J]. Journal of Guidance, Control, and Dynamics, 1985, 8(5): 620-627.

[59] Larimore W E. Canonical variate analysis in identification, filtering, and adaptive control[C]. The 29th IEEE Conference on Decision and Control. Honolulu, 1990: 596-604.

[60] Wu P, Lou S W, Zhang X J, et al. Data-driven fault diagnosis using deep canonical variate analysis and fisher discriminant analysis[J]. IEEE Transactions on Industrial Informatics, 2021, 17(5): 3324-3334.

[61] Verhaegen M. Identification of the deterministic part of MIMO state space models given in innovations form from input-output data[J]. Automatica, 1994, 30(1): 61-74.

[62] van Overschee P, de Moor B. N4SID: Subspace algorithms for the identification of combined deterministic-stochastic systems[J]. Automatica, 1994, 30(1): 75-93.

[63] Wu Y H, Zuo Z Q, Wang Y J, et al. Distributed data-driven model predictive control for heterogeneous vehicular platoon with uncertain dynamics[J]. IEEE Transactions on Vehicular Technology, 2023, 72(8): 9969-9983.

[64] Chiuso A. The role of vector autoregressive modeling in predictor-based subspace identification[J]. Automatica, 2007, 43(6): 1034-1048.

[65] Pilario K E S, Cao Y, Shafiee M. A kernel design approach to improve kernel subspace identification[J]. IEEE Transactions on Industrial Electronics, 2021, 68(7): 6171-6180.

[66] Dorfler F, Coulson J, Markovsky I. Bridging direct and indirect data-driven control formulations via regularizations and relaxations[J]. IEEE Transactions on Automatic Control, 2023, 68(2): 883-897.

[67] Wu P, Pan H P, Ren J, et al. A new subspace identification approach based on principal component analysis and noise estimation[J]. Industrial & Engineering Chemistry Research, 2015, 54(18): 5106-5114.

[68] Sonko S, Etukudoh E A, Ibekwe K I, et al. A comprehensive review of embedded systems in autonomous vehicles: Trends, challenges, and future directions[J]. World Journal of Advanced Research and Reviews, 2024, 21(1): 2009-2020.

[69] 张新钰, 卢毅果, 高鑫, 等. 面向智能网联汽车的车路协同感知技术及发展趋势[J]. 自动化学报, 2025, 51(2): 233-248.
(Zhang X Y, Lu Y G, Gao X, et al. Vehicle-road collaborative perception technology and development trend for intelligent connected vehicles[J]. Acta Automatica Sinica, 2025, 51(2): 233-248.)

[70] Chehardoli H, Ghasemi A. Adaptive centralized/decentralized control and identification of 1-D heterogeneous vehicular platoons based on constant time headway policy[J]. IEEE Transactions on Intelligent Transportation Systems, 2018, 19(10): 3376-3386.

[71] Levine W, Athans M. On the optimal error regulation of a string of moving vehicles[J]. IEEE Transactions on Automatic Control, 1966, 11(3): 355-361.

[72] Stankovic S S, Stanojevic M J, Siljak D D. Decentralized overlapping control of a platoon of vehicles[J]. IEEE Transactions on Control Systems Technology, 2000, 8(5): 816-832.

[73] Xavier P, Pan Y J. A practical PID-based scheme for the collaborative driving of automated vehicles[C]. Proceedings of the 48h IEEE Conference on Decision and Control (CDC) Held Jointly with 2009 28th Chinese Control Conference. Shanghai, 2009: 966-971.

[74] Wang W. The safety and comfort control of vehicles by the separation principle of PID controller tuning[C]. 2010 IEEE International Conference on Industrial Technology. Piscataway: IEEE, 2010: 145-150.

[75] Li S E, Gao F, Cao D P, et al. Multiple-model switching control of vehicle longitudinal dynamics for platoon-level automation[J]. IEEE Transactions on Vehicular Technology, 2016, 65(6): 4480-4492.

[76] Hang P, Xia X, Chen X. Handling stability advancement with 4WS and DYC coordinated control: A gain-scheduled robust control approach[J]. IEEE Transactions on Vehicular Technology, 2021, 70(4): 3164-3174.

[77] Hou L, Xin L, Li S E, et al. Interactive trajectory prediction of surrounding road users for autonomous driving using structural-LSTM network[J]. IEEE Transactions on Intelligent Transportation Systems, 2020, 21(11): 4615-4625.

[78] Zhang H, Wang R, Wang J. Robust path following control for autonomous ground vehicles with delay and

data dropout[M]. London: Springer, 2023.

[79] Gao F, Li S E, Zheng Y, et al. Robust control of heterogeneous vehicular platoon with uncertain dynamics and communication delay[J]. IET Intelligent Transport Systems, 2016, 10(7): 503-513.

[80] Zheng Y, Li S E, Li K Q, et al. Platooning of connected vehicles with undirected topologies: Robustness analysis and distributed H-infinity controller synthesis[J]. IEEE Transactions on Intelligent Transportation Systems, 2018, 19(5): 1353-1364.

[81] Nguyen A T, Sentouh C, Zhang H, et al. Fuzzy static output feedback control for path following of autonomous vehicles with transient performance improvements[J]. IEEE Transactions on Intelligent Transportation Systems, 2020, 21(7): 3069-3079.

[82] 郭戈, 赵梓唯. 网联车辆队列有限时间终端滑模控制[J]. 控制理论与应用, 2023, 40(1): 149-159.
(Guo G, Zhao Z W. Finite-time terminal sliding mode control of connected vehicle platoons[J]. Control Theory & Applications, 2023, 40(1): 149-159.)

[83] Utkin V I. Sliding modes and their applications in variable structure systems[M]. Moscow, 1978.

[84] 高振宇, 孙振超, 郭戈. 网联车辆有限时间滑模预设性能队列控制[J]. 控制理论与应用, 2023, 40(11): 1891-1902.
(Gao Z Y, Sun Z C, Guo G. Finite-time sliding mode prescribed performance platoon control of connected vehicles[J]. Control Theory & Applications, 2023, 40(11): 1891-1902.)

[85] Wang J M, Luo X Y, Yan J, et al. Distributed integrated sliding mode control for vehicle platoons based on disturbance observer and multi power reaching law[J]. IEEE Transactions on Intelligent Transportation Systems, 2022, 23(4): 3366-3376.

[86] Devika K B, Sridhar N, Yellapantula V R S, et al. Control of heavy road vehicle platoons incorporating actuation dynamics[C]. 2019 IEEE Region 10 Conference. Kochi, 2019: 1434-1439.

[87] Ma Y L, Li Z X, Malekian R, et al. Hierarchical fuzzy logic-based variable structure control for vehicles platooning[J]. IEEE Transactions on Intelligent Transportation Systems, 2019, 20(4): 1329-1340.

[88] Guo X, Wang J, Liao F, et al. Distributed adaptive sliding mode control strategy for vehicle-following systems with nonlinear acceleration uncertainties[J]. IEEE Transactions on Vehicular Technology, 2016, 66(2): 981-991.

[89] Raza H, Ioannou P. Vehicle following control design for automated highway systems[J]. IEEE Control Systems Magazine, 1996, 16(6): 43-60.

[90] 席裕庚, 李德伟, 林姝. 模型预测控制 —— 现状与挑战[J]. 自动化学报, 2013, 39(3): 222-236.
(Xi Y G, Li D W, Lin S. Model predictive control: Status and challenges[J]. Acta Automatica Sinica, 2013, 39(3): 222-236.)

[91] 陈虹, 刘志远, 解小华. 非线性模型预测控制的现状与问题[J]. 控制与决策, 2001, 16(4): 385-391.
(Chen H, Liu Z Y, Xie X H. Nonlinear model predictive control : The state and open problems[J]. Control and Decision, 2001, 16(4): 385-391.)

[92] Yu S Y, Hirche M, Huang Y J, et al. Model predictive control for autonomous ground vehicles: A review[J]. Autonomous Intelligent Systems, 2021, 1(1): 1-17.

[93] Kianfar R, Falcone P, Fredriksson J. A receding horizon approach to string stable cooperative adaptive cruise control[C]. 2011 14th International IEEE Conference on Intelligent Transportation Systems. Washington, 2011: 734-739.

[94] Zheng Y, Li S E, Li K Q, et al. Distributed model predictive control for heterogeneous vehicle platoons under unidirectional topologies[J]. IEEE Transactions on Control Systems Technology, 2017, 25(3): 899-910.

[95] Nunen E, Verhaegh J, Silvas E, et al. Robust model predictive cooperative adaptive cruise control subject to V2V impairments[C]. 2017 IEEE 20th International Conference on Intelligent Transportation Systems. Yokohama, 2017: 1-8.

[96] Feng S, Song Z Y, Li Z J, et al. Robust platoon control in mixed traffic flow based on tube model predictive control[J]. IEEE Transactions on Intelligent Vehicles, 2021, 6(4): 711-722.

[97] Massera Filho C, Terra M H, Wolf D F. Safe optimization of highway traffic with robust model predictive control-based cooperative adaptive cruise control[J]. IEEE Transactions on Intelligent Transportation Systems, 2017, 18(11): 3193-3203.

[98] Zhou J S, Tian D X, Sheng Z G, et al. Robust min-max model predictive vehicle platooning with causal disturbance feedback[J]. IEEE Transactions on Intelligent Transportation Systems, 2022, 23(9): 15878-15897.

[99] Bejarbaneh E Y, Du H P, Naghdy F. Data-driven optimal cooperative control for vehicle platoons with unknown dynamics[C]. 2024 IEEE 27th International Conference on Intelligent Transportation Systems. Edmonton, 2024: 3239-3244.

[100] 林浩, 李雷孝, 王慧. 支持向量机在智能交通系统中的研究应用综述[J]. 计算机科学与探索, 2020, 14(6): 901-910.
(Lin H, Li L X, Wang H. Survey on research and application of support vector machines in intelligent transportation system[J]. Journal of Frontiers of Computer Science and Technology, 2020, 14(6): 901-910.)

[101] 申元霞, 谢悦, 张学锋, 等. 基于多智能体强化学习的交叉道路车辆协同控制[J]. 西华大学学报: 自然科学版, 2025, 44(4): 40-48.
(Shen Y X, Xie Y, Zhang X F, et al. Cooperative control of cross-road vehicles using multi-agent reinforcement learning[J]. Journal of Xihua University: Natural Science Edition, 2025, 44(4): 40-48.)

[102] Ralf E, Felix R, Michael R. Decentralized coordination

of platoons — A conceptual approach using deep reinforcement learning[J]. Transportation Research Procedia, 2025, 82: 734-748.

[103] Kim K J, Seo J H, Park J G, et al. Generalization of TORCS car racing controllers with artificial neural networks and linear regression analysis[J]. Neurocomputing, 2012, 88: 87-99.

[104] Zhang Y, Cai W Z, Chen J C, et al. Unidirectional weighted graph-based time-aware formation control for connected and automated vehicle platoon[J]. IEEE Transactions on Intelligent Vehicles, 2025, 10(3): 1880-1893.

[105] Wei J H, Liu Y J, Chen H, et al. Adaptive neural control of connected vehicular platoons with actuator faults and constraints[J]. IEEE Transactions on Intelligent Vehicles, 2023, 8(6): 3647-3656.

[106] Kuutti S, Bowden R, Jin Y C, et al. A survey of deep learning applications to autonomous vehicle control[J]. IEEE Transactions on Intelligent Transportation Systems, 2021, 22(2): 712-733.

[107] Norouzi A, Heidarifar H, Borhan H, et al. Integrating machine learning and model predictive control for automotive applications: A review and future directions[J]. Engineering Applications of Artificial Intelligence, 2023, 120: 105878.

[108] Arandhakar S, Nakka J. Deep learning-driven robust model predictive control based active cell equalisation for electric vehicle battery management system[J]. Sustainable Energy, Grids and Networks, 2025, 42: 101694.

[109] Dong F, Li X C, You K Y, et al. Standoff tracking using DNN-based MPC with implementation on FPGA[J]. IEEE Transactions on Control Systems Technology, 2023, 31(5): 1998-2010.

[110] Basile G, Lui D G, Napoletano E, et al. LSTM-based predictive control for connected autonomous electric vehicles platoons[C]. 2024 IEEE International Conference on Electrical Systems for Aircraft. Railway, 2024: 1-6.

[111] Zhao R, Li Y, Fan Y, et al. A survey on recent advancements in autonomous driving using deep reinforcement learning: Applications, challenges, and solutions[J]. IEEE Transactions on Intelligent Transportation Systems, 2024, 25(12): 19365-19398.

[112] He Y, Zhao N, Yin H X. Integrated networking, caching, and computing for connected vehicles: A deep reinforcement learning approach[J]. IEEE Transactions on Vehicular Technology, 2018, 67(1): 44-55.

[113] Li G F, Qiu Y F, Yang Y F, et al. Lane change strategies for autonomous vehicles: A deep reinforcement learning approach based on transformer[J]. IEEE Transactions on Intelligent Vehicles, 2023, 8(3): 2197-2211.

[114] Kebria P M, Khosravi A, Salaken S M, et al. Deep imitation learning for autonomous vehicles based on convolutional neural networks[J]. CAA Journal of Automatica Sinica, 2020, 7(1): 82-95.

[115] Yuan Z J, Li G H, Wang Z K, et al. RL-CSL: A combinatorial optimization method using reinforcement learning and contrastive self-supervised learning[J]. IEEE Transactions on Emerging Topics in Computational Intelligence, 2023, 7(4): 1010-1024.

[116] Zhang F Y, Yang Q Y, An D. CDDPG: A deep-reinforcement-learning-based approach for electric vehicle charging control[J]. IEEE Internet of Things Journal, 2021, 8(5): 3075-3087.

[117] Sharma R, Garg P. Optimizing autonomous driving with advanced reinforcement learning: Evaluating DQN and PPO[C]. 2024 5th International Conference on Smart Electronics and Communication. Trichy, 2024: 910-914.

[118] Zhou J H, Xue S W, Xue Y, et al. A novel energy management strategy of hybrid electric vehicle via an improved TD3 deep reinforcement learning[J]. Energy, 2021, 224: 120118.

[119] Chen L, He Y, Pan W, et al. A novel generalized meta hierarchical reinforcement learning method for autonomous vehicles[J]. IEEE Network, 2023, 37(4): 230-236.

[120] Berkenkamp F, Turchetta M, Schoellig A, et al. Safe model–based reinforcement learning with stability guarantees[J]. Advances in Neural Information Processing Systems, 2017, 2(12): 30-42.

[121] Lee H, Kim K, Kim N, et al. Energy efficient speed planning of electric vehicles for car–following scenario using model-based reinforcement learning[J]. Applied Energy, 2022, 313: 118460.

[122] Cui Y D, Peng L, Li H Y. Filtered probabilistic model predictive control-based reinforcement learning for unmanned surface vehicles[J]. IEEE Transactions on Industrial Informatics, 2022, 18(10): 6950-6961.

[123] Dinneweth J, Boubezoul A, Mandiau R, et al. Multi-agent reinforcement learning for autonomous vehicles: A survey[J]. Autonomous Intelligent Systems, 2022, 2(1): 27.

[124] Li T, Zhu K, Luong N C, et al. Applications of multi-agent reinforcement learning in future internet: A comprehensive survey[J]. IEEE Communications Surveys and Tutorials, 2022, 24(2): 1240-1279.

[125] 郭戈, 许阳光, 徐涛. 网联共享车路协同智能交通系统综述[J]. 控制与决策, 2019, 34(11): 2375-2389.
(Guo G, Xu Y G, Xu T. A survey of connected shared vehicle-road cooperative intelligent transportation systems[J]. Control and Decision, 2019, 34(11): 2375-2389.)

[126] 陈龙, 何德峰, 李壮. 约束非线性车辆队列分布式多目标模型预测控制[J]. 控制与决策, 2022, 37(12): 3122-3128.
(Chen L, He D F, Li Z. Distributed multi-objective model predictive control for constrained nonlinear vehicle platoons[J]. Control and Decision, 2022, 37(12): 3122-3128.)

[127] 郭延永, 刘佩, 袁泉. 网联自动驾驶车辆道路交通安全研究综述[J]. 交通运输工程学报, 2023, 23(5): 19-38.
(Guo Y Y, Liu P, Yuan Q. Review on research of road traffic safety of connected and automated vehicles[J]. Journal of Traffic and Transportation Engineering, 2023, 23(5): 19-38.)

[128] Wang Y Y, Masoud N, Khojandi A. Real-time sensor anomaly detection and recovery in connected automated vehicle sensors[J]. IEEE Transactions on Intelligent Transportation Systems, 2021, 22(3): 1411-1421.

[129] Eckelmann S, Trautmann T, Ussler H, et al. V2V-communication, Lidar system and positioning sensors for future fusion algorithms in connected vehicles[J]. Transportation Research Procedia, 2017, 27: 69-76.

[130] Hu M J, Li C K, Bian Y G, et al. Fuel economy-oriented vehicle platoon control using economic model predictive control[J]. IEEE Transactions on Intelligent Transportation Systems, 2022, 23(11): 20836-20849.

[131] 罗凯. 智能网联电动汽车队列的经济性巡航分布式控制研究[D]. 南京: 东南大学.
(Luo K. Research on economic cruise distributed control of intelligent connected electric vehicle platoon[J]. Nanjing: University of Southeast.)

[132] Cerutti J J, Cafiero G, Iuso G. Aerodynamic drag reduction by means of platooning configurations of light commercial vehicles: A flow field analysis[J]. International Journal of Heat and Fluid Flow, 2021, 90: 108823.

[133] Ozkan M F, Ma Y. Distributed stochastic model predictive control for human-leading heavy-duty truck platoon[J]. IEEE Transactions on Intelligent Transportation Systems, 2022, 23(9): 16059-16071.

[134] Cinelli M, Kadziński M, Gonzalez M, et al. How to support the application of multiple criteria decision analysis? Let us start with a comprehensive taxonomy[J]. Omega, 2020, 96: 102261.

[135] 安星锟, 杨中平, 王玓. 基于改进型凸优化算法的有轨电车混合储能系统容量配置帕累托解集[J]. 电工技术学报, 2020, 35(14): 10-16.
(An X K, Yang Z P, Wang Y. Pareto solution set of tram hybrid energy storage system capacity allocation based on improved convex optimization[J]. Transactions of China Electrotechnical Society, 2020, 35(14): 10-16.)

[136] Kennedy J, Eberhart R. Particle swarm optimization[C]. Proceedings of ICNN'95 International Conference on Neural Networks. Perth, 1995: 1942-1948.

[137] Amine K. Multiobjective simulated annealing: Principles and algorithm variants[J]. Advances in Operations Research, 2019, 2019: 8134674.

[138] Song W Z, Yang Y, Qin W J, et al. Switching state selection for model predictive control based on genetic algorithm solution in an indirect matrix converter[J]. IEEE Transactions on Transportation Electrification, 2022, 8(4): 4496-4508.

[139] Ma G Q, Wang B Q, Ge S S. Robust optimal control of connected and automated vehicle platoons through improved particle swarm optimization[J]. Transportation Research Part C: Emerging Technologies, 2022, 135: 103488.

[140] Gong M G, Cai Q, Chen X W, et al. Complex network clustering by multiobjective discrete particle swarm optimization based on decomposition[J]. IEEE Transactions on Evolutionary Computation, 2014, 18(1): 82-97.

[141] Zhu Q L, Lin Q Z, Chen W N, et al. An external archive-guided multiobjective particle swarm optimization algorithm[J]. IEEE Transactions on Cybernetics, 2017, 47(9): 2794-2808.

[142] Dupont G, Adam S, Lecourtier Y, et al. Multi objective particle swarm optimization using enhanced dominance and guide selection[J]. International Journal of Computational Intelligence Research, 2008, 4(2): 145-158.

[143] Yu H B, Tan Y, Zeng J C, et al. Surrogate-assisted hierarchical particle swarm optimization[J]. Information Sciences, 2018, 454/455: 59-72.

[144] Holland J H. Genetic algorithms[J]. Scientific American, 1992, 267(1): 66-72.

[145] Tamaki H, Kita H, Kobayashi S. Multi-objective optimization by genetic algorithms: A review[C]. Proceedings of IEEE International Conference on Evolutionary Computation. Nagoya, 1996: 517-522.

[146] Zuo X, Chen C, Tan W, et al. Vehicle scheduling of an urban bus line via an improved multi objective genetic algorithm[J]. IEEE Transactions on Intelligent Transportation Systems, 2014, 16(2): 1030-1041.

[147] Ruiz E, Soto-Mendoza V, Ruiz Barbosa A E, et al. Solving the open vehicle routing problem with capacity and distance constraints with a biased random key genetic algorithm[J]. Computers & Industrial Engineering, 2019, 133: 207-219.

[148] Ma H, Chu L, Guo J H, et al. Cooperative adaptive cruise control strategy optimization for electric vehicles based on SA-PSO with model predictive control[J]. IEEE Access, 2020, 8: 225745-225756.

[149] Mirjalili S, Mirjalili S M, Lewis A. Grey wolf optimizer[J]. Advances in Engineering Software, 2014, 69: 46-61.

[150] Mirjalili S, Saremi S, Mirjalili S M, et al. Multi-objective grey wolf optimizer: A novel algorithm for multi-criterion optimization[J]. Expert Systems with Applications, 2016, 47: 106-119.

[151] Asghari K, Masdari M, Gharehchopogh F S, et al. A chaotic and hybrid gray wolf-whale algorithm for solving continuous optimization problems[J]. Progress in Artificial Intelligence, 2021, 10(3): 349-374.

[152] Gupta S, Deep K. A novel random walk grey wolf optimizer[J]. Swarm and Evolutionary Computation,

2019, 44: 101-112.

[153] Gao Z M, Zhao J. An improved grey wolf optimization algorithm with variable weights[J]. Computational Intelligence and Neuroscience, 2019, 2019: 2981282.

[154] Cheng X Z, Li J M, Zheng C Y, et al. An improved PSO-GWO algorithm with chaos and adaptive inertial weight for robot path planning[J]. Frontiers in Neurorobotics, 2021, 15: 770361.

[155] Gaidhane P J, Nigam M J. A hybrid grey wolf optimizer and artificial bee colony algorithm for enhancing the performance of complex systems[J]. Journal of Computational Science, 2018, 27: 284-302.

[156] Liang Y R, Muller S, Schwendner D, et al. A scalable framework for robust vehicle state estimation with a fusion of a low-cost IMU, the GNSS, radar, a camera and lidar[C]. 2020 IEEE/RSJ International Conference on Intelligent Robots and Systems. Las Vegas, 2020: 1661-1668.

[157] Noor-A-Rahim M, Liu Z L, Lee H, et al. 6G for vehicle-to-everything (V2X) communications: Enabling technologies, challenges, and opportunities[J]. Proceedings of the IEEE, 2022, 110(6): 712-734.

[158] Cappello F, Sabatini R, Ramasamy S, et al. Particle filter based multi-sensor data fusion techniques for RPAS navigation and guidance[C]. 2015 IEEE Metrology for Aerospace. Benevento, 2015: 395-400.

[159] Hossein T N N, Mita S, Long H. Multi-sensor data fusion for autonomous vehicle navigation through adaptive particle filter[C]. 2010 IEEE Intelligent Vehicles Symposium. La Jolla, 2010: 752-759.

[160] Arthurs P, Gillam L, Krause P, et al. A taxonomy and survey of edge cloud computing for intelligent transportation systems and connected vehicles[J]. IEEE Transactions on Intelligent Transportation Systems, 2022, 23(7): 6206-6221.

[161] Behere S, Törngren M. A functional reference architecture for autonomous driving[J]. Information and Software Technology, 2016, 73: 136-150.

[162] Liu S S, Liu L K, Tang J, et al. Edge computing for autonomous driving: Opportunities and challenges[J]. Proceedings of the IEEE, 2019, 107(8): 1697-1716.

[163] Chen Q, Ma X, Tang S H, et al. F-cooper: Feature based cooperative perception for autonomous vehicle edge computing system using 3D point clouds[C]. Proceedings of the 4th ACM/IEEE Symposium on Edge Computing. Arlington Virginia, 2019: 88-100.

[164] Wang F Y, Hu J, Lai J T. Testing intelligence: Accelerating the verification and validation of intelligent vehicles[J]. IEEE Transactions on Intelligent Vehicles, 2023, 8(2): 1003-1016.

[165] Huang W L, Wang K F, Lv Y S, et al. Autonomous vehicles testing methods review[C]. 2016 IEEE 19th International Conference on Intelligent Transportation Systems. Rio de Janeiro, 2016: 163-168.

[166] Shi Y, Liu Z, Wang Z, et al. An integrated traffic and vehicle co-simulation testing framework for connected and autonomous vehicles[J]. IEEE Intelligent Transportation Systems Magazine, 2022, 14(6): 26-40.

作者简介

吴彦宏 (1994–), 男, 讲师, 博士, 主要研究方向为智能网联车、数据驱动控制, E-mail: yanhongwu2025@zjut.edu.cn;

左志强 (1973–), 男, 教授, 博士生导师, 主要研究方向为模型预测控制、无人集群系统, E-mail: zqzuo@tju.edu.cn;

王一晶 (1976–), 女, 教授, 博士, 主要研究方向为非线性系统、切换系统, E-mail: yjwang@tju.edu.cn;

王浩宇 (1996–), 男, 助理研究员, 博士, 主要研究方向为自抗扰控制、智能网联车控制, E-mail: why2014@tju.edu.cn;

李峥 (1996–), 男, 博士后, 主要研究方向为无人驾驶车辆决策、规划技术, E-mail: zhengl@tju.edu.cn.

科研团队简介

天津大学电气自动化与信息工程学院“控制理论与应用”团队, 由天津市智能无人集群技术与系统重点实验室主任左志强教授领衔. 团队长期深耕智能驾驶关键技术的理论与工程化研究, 围绕“感知-决策-控制”全链条, 构建了从基础突破到系统落地的完整闭环, 自主研制出人机交互、融合感知、自主避障、车辆运控及远程管理等成套系统, 为智能驾驶规模化应用提供硬核支撑.

面向国家重大需求和产业前沿, 团队与中汽数据、中汽研软件测评中心、中船重工 707 所、天津所托瑞安、天津德科智控等头部企事业单位深度协同, 针对实时调参、微动作捕捉、云平台监测、大曲率转向、数据标注等“卡脖子”环节系统攻关, 应用成果显著.

近 3 年, 团队包揽 2024、2023 世界智能驾驶挑战赛 (WIDC) 双金奖, 斩获 2022 中国 (沈阳) 智能网联汽车大赛金奖, 并在 2020 WIDC 一举拿下一等奖 3 项、二等奖 1 项、三等奖 1 项, 获 2022 教育部产学合作协同育人项目, IEEE 数据驱动控制与学习系统会议-最佳论文奖, 《中国科学》-中国控制会议张贴论文奖, 充分展示了团队在智能驾驶领域的持续创新实力与学术引领力.

未来, 团队将紧盯智能驾驶技术前沿, 推动控制理论与人工智能深度融合, 探索新一代智能驾驶系统的理论创新与应用拓展, 力求在推动学科发展与产业转型升级中发挥更大作用.