

重型车辆高级驾驶辅助系统研究综述

张志利, 祝慧鑫, 周召发, 赵军阳, 张克凡

(火箭军工程大学, 陕西 西安 710025)

摘要: 针对高级驾驶辅助系统 (Advanced Driving Assistance System, ADAS) 重型车辆视野盲区大、反应要求高、制动时间短的安全特征, 论述了重型车辆 ADAS 技术的发展历程以及目前 ADAS 技术的涵盖范围, 重点论述了重型车辆 ADAS 的环境感知技术 (包括基于视觉类图像、雷达类点云、多模态融合的目标检测技术) 以及定位定向技术 (囊括局部高精地图构建和多模态融合定位定向方案研究)。展望了重型车辆 ADAS 技术的发展趋势。

关键词: 兵器科学与技术; 高级驾驶辅助系统; 重型车辆; 环境感知; 定位定向

中图分类号: U495

文献标志码: A

文章编号: 2097-2741(2024)03-094-011

Review on ADAS Technologies for Heavy-Duty Vehicles

ZHANG Zhili, ZHU Huixin, ZHOU Zhaofa, ZHAO Junyang, ZHANG Kefan

(Rocket Force University of Engineering, Xi'an 710025, Shaanxi)

ABSTRACT: Considering safety characteristics of heavy-duty vehicles such as large blind spots, high reaction requirements and short braking time, the development courses of heavy-duty vehicle ADAS technologies and the current coverage of ADAS technologies were reviewed. First, environment sensing technologies of heavy-duty vehicle ADAS, including target detection technologies based on vision-like images, radar-like point clouds and multimodal fusion were discussed respectively. Second, the localization and orientation technology of heavy-duty vehicle ADAS, encompassing the construction of local high-precision maps and the research of multimodal fusion localization and orientation scheme were described. Finally, the trend of further development of ADAS technologies for heavy-duty vehicles were predicted.

KEYWORDS: weapons science and technology; ADAS; heavy-duty vehicle; environment sensing; localization and orientation

高级驾驶辅助系统 (Advanced Driving Assistance System, ADAS) 指的是一种集成了多种车载传感器和算法来实时收集和分析数据的技术系统, 可感知车辆周围路况和环境, 为驾驶员提供探测、预警和辅助驾驶等多种功能, 以提高行驶的安全性和舒适性^[1]。随着集成电路和控制系统的发展, ADAS 已经发展为涵盖行车监测、危险

预警和辅助控制等多方面多功能的庞大研究系统。2014 年, 国际自动机工程师学会给出了自动驾驶技术的六分级制度^[2], 指出要实现完全自动驾驶, 必须先实现包含 L1~L3 阶段的 ADAS。如今, ADAS 作为自动驾驶技术的基础, 凭借其安全性、便捷性和舒适性成为所有新款 L2~L4 级汽车的标配, 其中许多基础的辅助驾驶功能 (诸如车道保

收稿日期: 2024-03-26

第一作者: 张志利 (1966—), 男, 教授, 主要从事发射平台智能感知与导航技术研究。E-mail: zhangzl@126.com

引用格式: 张志利, 祝慧鑫, 周召发, 等. 重型车辆高级驾驶辅助系统研究综述[J]. 火箭军工程大学学报, 2024, 38 (3): 94-103, 110.

持、自适应巡航控制和紧急制动等)已经实现并广泛应用。

重型车辆不同于乘用车辆,在技术特征和架构设计上主要指便于运输人员和货物、执行特定任务的汽车^[3]。重型车辆的种类非常广泛,包括客运车辆、货运车辆、工程车辆和特种车辆等,具有视野盲区大、反应要求高、制动距离短等特点,因此,其安全需求更高、法规要求更严。随着乘用车辆自动驾驶技术的发展,重型车辆的辅助驾驶研究成为日益紧迫的课题。2022年,交通运输部、公安部、应急管理部联合发布的《道路运输车辆动态监督管理办法》就指出,应当“按照标准建设道路运输车辆动态监控平台,或者使用符合条件的社会化卫星定位系统监控平台,对所属道路运输车辆和驾驶员运行过程进行实时监控和管理”。重型车辆ADAS技术可以有效减少视野盲区、紧急刹车等行为,提高驾驶的安全性和舒适性。对此,国内外开展了大量研究,主要内容涵盖环境感知^[4]、定位定向^[5]、轨迹规划^[6]等多个领域。目前,重型车辆ADAS技术已基本达到L1~L2级智能重型车辆的量产水平,且正在加速推进L3~L4级自动驾驶的模块化开发。

本文综述了重型车辆ADAS技术的发展历史,并重点讨论了ADAS研究中的环境感知技术和定位定向技术。

1 发展历程

ADAS和自动驾驶技术的发展很大程度上与现实的军事需求息息相关。1983年,美国国防部高级研究计划局(Defense Advanced Research Projects Agency, DARPA)与美国陆军合作,发起了自助式陆地车辆(Autonomous Land Vehicle, ALV)计划。1985年首辆样车研发成功,但其图像处理和计算机技术并不能够满足军用无人地面平台的使用需求。1988年DARPA正式叫停了ALV项目,但却为后续研究打下了良好基础。

2004年,DARPA为解决军方提出的无人驾驶车辆问题,发起了DARPA挑战赛。比赛要求参赛车辆必须是无人驾驶的自主地面车辆,不允许远程遥控,并对每辆赛车进行实车跟踪,在10 h内最先到达终点的队伍获胜。虽然15支参赛团队都没能顺利完成任务,但这极大地引发了世界范围内研究人员的热情。2005年DARPA挑战赛

中,5支参赛队伍的无人车成功通过了路况恶劣的沙漠赛道。其中,Oshkosh公司TerraMax团队设计的MTVR型无人卡车MK-23(如图1所示)获得第五名的好成绩^[7],受到了重型车辆特别是特种车辆研究领域的极大关注。受此激励,第三届挑战赛“城市挑战赛”于2007年举行,并要求参赛车辆能遵守所有交通规则,在赛道上检测和避开其他机器人。最终卡内基梅隆大学的Boss、斯坦福大学的Junior、弗吉尼亚理工大学的Odin依次获得前三名。在此次比赛中,ADAS和自动驾驶技术的基本雏形已经出现,主要基础模块为:(1)电气化改装的执行架构;(2)基于激光雷达(Light Detection and Ranging, LiDAR)、摄像头、毫米波雷达等多传感器的环境感知算法;(3)结合全球定位系统(Global Positioning System, GPS)、实时动态测量(Real Time Kinematic, RTK)、惯性测量单元(Inertial Measurement Unit, IMU)等工具实现的高精地图(High-definition Map, HD map)定位;(4)通过各类机器学习算法得到的路径规划等。在重型车辆自动驾驶研究方面,除上述架构外,车距控制、车道辅助和紧急制动等侧重于提高行驶安全性的ADAS技术也开始研究并应用于重型车辆。




图1 MK-23车辆平台简要结构(单位:英尺)^[7]

Fig. 1 Brief construction of the MK-23 vehicle platform (Unit: foot)^[7]

Google在2009年建立了自动驾驶实验室Google X,并于2014年5月发布了纯电动全自动驾驶汽车车型——萤火虫。许多企业同步开展了大量研究,其中包含奔驰、通用、丰田等传统汽车公司和Tesla、Uber、百度、NVIDIA等高科技公司。Oshkosh与美军方合作深化特种车辆自动驾驶技术研究,2014年推出美军自动驾驶扫雷吉普M-ATV等。2023年,oToBrite推出其全球首款用于重型车辆的一体化ADAS系统oToGuard,可以集成实现盲点信息系统、离车信息系统和驾驶员监控系统等十几种ADAS功能。

国内也进行了重型车辆 ADAS 技术研究。焦贵伟等^[8]通过加装由红外光源、CCD 摄像机等模块构成的装甲车辆辅助驾驶视频系统,可为车内人员提供车辆四周实时图像。李海玲等^[9]通过融合超声波雷达和视觉传感器来提供客车周边环境的有效感知信息。而 DeepWay、卡睿智行、智加科技、斯年智驾、西井科技等公司也致力于研发 L4 级别的无人驾驶卡车技术。

目前,重型车辆 ADAS 技术研究主要集中在车辆编队行驶、矿区无人驾驶、港口无人货运等领域。在车辆编队行驶领域,大宗物流业务量庞大,运输路线业务集中度高,无人重型车辆的编队行驶可以起到降本增效的目的。美国 Otto 卡车公司于 2016 年 10 月便完成了第一个无人卡车运输商业订单,Waymo、Tesla、Volvo 等公司都在积极布局无人卡车市场。2023 年,KargoBot 公司提出了“一种人与系统混合并存”卡车编队的重型车辆 ADAS 方案(KargoOne),适合大宗货运问题的混合无人化解决。在矿区无人驾驶领域,矿区场景相对简单,司机缺口需求大,因此重型车辆 ADAS 可以发挥重要作用。小松智能公司的无人自卸卡车在去除驾驶室后,整体的承载量、平稳性和灵活性都得到提升,其主要业务包含了澳大利亚、北美洲和南美洲三大洲六大矿区。在港口无人货运领域,目前全国共有 400 多辆重型车辆在港口进行商业化运营或者测试,主要涉及宁波港、珠海港、厦门港等大型港口,涵盖了无人集

装箱卡车、无人平板车、无人宽体车等重型车辆车型。

发展至今,ADAS 体系庞大,研究的广度和深度得到很大扩展。依据 GB/T 39263—2020《道路车辆 先进驾驶辅助系统(ADAS) 术语及定义》^[10]中不同功能的实现区别,ADAS 可以分为信息辅助和控制辅助两大类,涉及车辆信息、驾驶员状态、道路环境等多个方面,其具体分类情况如图 2 所示。

由图 2 可知,ADAS 主要集中在车辆与其周边环境、车辆与驾驶员、车辆与控制系统的交互 3 个主要部分。其中,车辆与周边环境的交互是重型车辆 ADAS 技术的基础性、关键性研究内容,下文针对其中的环境感知技术和定位定向技术具体展开说明。

2 环境感知技术

环境感知技术可以为 ADAS 提供必要的信息基础,使车辆能够更准确地感知和响应周围环境,从而有效提升驾驶的智能化水平。环境感知技术在 ADAS 中具有基础性、显著性的地位,其中最重要的是目标检测技术。依据现有研究情况,目标检测技术可分为基于视觉类图像、基于雷达类点云和基于多模态融合 3 类。

2.1 基于视觉类图像的目标检测技术

基于视觉类图像的目标检测技术在图像分类



图 2 ADAS 分类^[10]

Fig. 2 Categorization of ADAS^[10]

的基础上更进一步, 旨在识别图像中的目标对象并确定它们的位置。因此, 这要求目标检测任务不仅需要分类能力, 还需要对目标的位置信息进行准确定位。目标检测的基本原理是: 在图像中生成候选框, 提取特征并使用分类器确定候选框的类别, 通过边界框回归来精确定位目标位置。传统的特征提取算法有方向梯度直方图 (Histogram of Oriented Gradient, HOG)^[11]、尺度不变特征变换 (Scale-Invariant Feature Transform, SIFT)^[12]、定向快速旋转简报 (Oriented FAST and Rotated BRIEF, ORB)^[13]、局部二值模式 (Local Binary Pattern, LBP)^[14]等, 但这些方法的计算复杂度高、存储消耗大以及对光照、视角、尺度和旋转变敏感, 这些缺点限制了它们在复杂场景下的应用。Yao 等^[15]便指出在目标检测过程中, SIFT 算法的计算成本高, 而 ORB 算法匹配精度较低。传统方法越来越不能满足当前需求。

随着 2012 年扩展深度的卷积神经网络模型 AlexNet^[16]的爆火, 深度学习方法在目标检测中不断取得突破, 引起了全世界的关注。目前, 以深度学习为基础的目标检测模型主要分为单阶段模型 (One stage)、两阶段模型 (Two stage) 和基于 Transformer 的模型 3 种发展途径, 其主要发展情况如图 3 所示。

One stage 模型直接将输入图像映射到目标的边界框和类别, 速度快但精度低, 主要以 YOLO (You Only Look Once)、SSD (Single Shot Multibox Detector)、RetinaNet 等模型为代表。Two stage 模型则首先生成一组候选区域, 然后对

每个候选区域进行分类和边界框回归, 速度慢但精度高, 主要以 RCNN 系列 (基于区域的卷积神经网络 (Regions with Convolutional Neural Network, RCNN)、Fast RCNN、Faster RCNN)、SPPNet (Spatial Pyramid Pooling in Deep Convolutional Networks) 等模型为代表。基于深度学习的车辆检测的速度和准确性主要依赖于算法结构和骨干网络 2 个方面^[17]。One stage 和 Two stage 之间的区别主要来源于算法结构的不同。当网络结构同样紧凑时, 研究者们希望改进骨干网络来提高目标检测的速度和准确性。例如, 当 Faster RCNN 的骨干网络采用 VGG16 (此时为 16 层网络) 时, 其图像处理速度只有 5 帧/s, 而平均精度为 73%; 当骨干网络采用 ZFNet (此时为 7 层网络) 时, 其图像处理速度将会增加到 17 帧/s, 但平均精度下降到 62%^[18]。因此, 当前基于视觉类图像的目标检测技术的一个核心问题是如何构建一个高效且轻量化的特征提取网络。近年提出了许多优秀的轻量级神经网络架构, 如 AFF-Net^[19]、PACNet^[20]和 MobileViT^[21]等, 这些都值得进一步研究。

尽管之前的检测方法都对各目标之间的联系进行了挖掘, 但直到 Transformer^[22]模型才提出利用注意力机制对目标关联关系进行深度解析。注意力机制可以帮助模型去关注图像中的重要区域, 通过对图像中不同区域之间的关系进行建模并学习长距离依赖关系, 以提高检测精度和速度。同时不同于其他机制, 注意力机制可以并行计算图像中不同位置的特征之间的关系, 使得基于




图 3 基于视觉的目标检测技术发展路线

Fig. 3 Development route of vision-based target detection techniques

Transformer 的模型能够在 GPU 上高效运行,从而提高检测速度。基于 Transformer 的模型主要代表有 Relation Net^[23]、DETR (Detection Transformer)^[24]、ViTFRCNN^[25]等。基于 Transformer 的模型可以较容易地扩展到多模态目标检测任务,例如图像-文本目标检测、图像-点云目标检测和视频目标检测等。Yan 等^[26]基于 Transformer 提出了一种鲁棒多模态 3D 目标检测器 CMT (Cross Model Transformer),可以输入摄像头和点云 tokens,从而直接输出精准 3D 检测框。

2.2 基于雷达类点云的目标检测技术

雷达类点云数据由于其测距测速精度高、探测能力以及抗环境干扰能力强等优点,在 ADAS 目标检测中受到广泛关注。其中,激光雷达是目前主流的雷达传感器,可以通过输出非结构化、稀疏的和非齐次的点云数据结构来表示其对环境的感知结果^[27]。

如图 4 所示为不同传感器之间的探测能力区别^[28]。与其他传感器相比,可以看出激光雷达在探测距离、可靠度、夜间模式和行人判别等方面具有明显优势,展现出更大的探测范围、更高的检测精度和更详细的环境三维信息。




图 4 不同传感器的探测能力^[28]

Fig. 4 Detection capabilities of different sensors^[28]

点云数据囊括了大量的环境信息,因此体积大而稀疏,需要进行预处理才能使用。在 ADAS 领域,随着技术的进步和数据量的增大,传统的目标检测算法暴露出越来越多的问题。当前,由于深度学习的优异性能,在处理更加复杂的目标、更大规模的数据时往往采用 PointNet 系列 (PointNet^[29]、PointNet++^[30])、VoxelNet^[31]、SE-COND (Sparsely Embedded Convolutional Detection)^[32]、PointPillar^[33]、PCT (Point Cloud Transformer)^[34]等深度学习模型进行点云处理。尽管如此,深度学习算法处理点云数据时仍存在一定不足。一方面,点云本身稀疏和非结构化的性质导致其密度和数量在不同场景中变化很大,

因此难以采取统一范式处理;另一方面,汽车行驶时要求 ADAS 和自动驾驶系统的反应时间尽可能短,因此实时性要求高,检测算法和网络必须在两次扫描的时间间隔内得到可靠的计算结果。Wang 等^[35]指出在现有深度学习方法中,基于投影的方法和基于离散化的点云处理方法都利用了 2D 图像对应的成熟网络架构,但投影过程中却分别存在信息丢失、分辨率提高而导致的成本增加问题。目前基于点的点云处理方法研究较多,但点表示缺少明确的临近信息,广泛采用的邻居搜索机制 (例如 K-近邻算法^[36]) 则存在效率不高的问题。接下来,可以在索引结构上的稀疏卷积^[37]、不平衡数据中学习^[38]、大规模点云的有效分割^[39]等方向进行深入研究。

2.3 基于多模态融合的目标检测技术

目前在多传感器融合的研究中,主流的传感器组合形式主要是“雷达+摄像头”的研究方案。如图 5 所示^[40],相较于其他方法,主动和被动深度测量技术在探测范围、目标分类、轮廓信息等方面可以起到良好的互补作用,因此将两者数据进行融合可获得更全面准确的感知能力。

具体研究中存在多种细化的研究路线。一种重要的研究方向是“毫米波雷达+摄像头”,Wei 等^[41]对其融合过程中涉及的传感器选择、传感器标定和传感器融合 3 个部分进行了论述。而“激光雷达+摄像头”同样是一个重要的研究方向,Huang 等^[40]以激光雷达和摄像头分支的数据格式及其不同特征为代表,探讨了多模态传感器融合的分类情况。同时,部分研究人员也注意到了多种传感器融合对于目标检测的重要意义。Li 等^[42]从立体视觉、毫米波雷达和摄像头融合、激光雷达和摄像头融合、多传感器融合多个角度对车辆检测算法进行总结,但研究中缺少对于行人等静态障碍物和车道线、交通标志等道路特征的论述。

Tesla 研发的以 Autopilot 视觉方案为代表的多传感器融合方案,其核心是名为 HydraNet^[43]的算法架构,通过 Multi-Head Attention 的 Transformer 模型直接端到端处理多相机图像,并增加特征队列模块用于时序特征缓存以及增加视频模块来融合时序上的信息,最终解码输出车体坐标下的感知结果。

如图 6 所示,在 HydraNet 的基础上,Tesla FSD 于 2022 年推出的 Occupancy Network^[44]引起研究人员对三维场景重建的极大兴趣。Occupancy




图 5 基于多模态传感器融合模型的自动驾驶感知任务^[41]

Fig. 5 Perception tasks of autonomous driving by multi-modal sensor fusion model^[41]




图 6 Occupancy Network 运行结果^[44]

Fig. 6 Operation results of Occupancy Network^[44]

Network^[45–46]将三维场景表示为离散的体素格子, 然后使用神经网络来学习每个体素格子的占据概率。其优点在于能够以端到端的方式学习并表示整个三维场景, 而无需显式地重建几何形状或表面, 这使得 Occupancy Networks 在处理不规则形状和不完整的输入数据时表现良好。

不同于 Tesla 特征提取依然沿用 RegNet + BiFPNs, 许多研究者提出新的网络架构以实现更高性能。Fu 等^[47]提出一种新的 3D 到 2D 标签传输模型 Panoptic NeRF, 利用 NeRF 作为一个可微分的工具来统一粗糙的 3D 注释和从现有数据集转移的 2D 语义线索。

3 定位定向技术

定位定向技术包括地图匹配、动态障碍物检测、车辆稳定性控制和自主导航等功能, 通过使用全球导航卫星系统 (Global Navigation Satellite System, GNSS)、视觉惯性里程计 (Visual-Inertial Odometer, VIO)、IMU 和其他传感器, 提供车辆的精确位置、姿态和运动信息, 帮助车辆感

知周围环境并做出准确的导航决策。车辆定位定向技术在现代交通领域具有重要地位, 不仅是导航定位系统的核心, 还是实现智能交通、车辆管理和安全防护的基础技术, 在重型车辆的 ADAS 技术中发挥着越来越重要的作用。

由于港口运输、矿区驾驶等场景的环境成分简单, 突发情况少, 相应的重型车辆定位定向技术已经较为成熟。但在复杂道路行驶 (尤其是非高速路段) 方面, 重型车辆在道路上的尺寸和载重较大, 因此对定位的精度要求更高、研究难度更大、迫切性更强。重型车辆 ADAS 的定位定向技术主要涉及高清地图的构建、即时定位与地图构建和多模态定位方案等方面。

与传统地图相比, HD map 被视为自动驾驶定位定向技术的关键基础设施^[48], 包含车道、交通灯和相关物体的更详细且精度更高的信息, 为车辆提供超传感器距离的感知能力, 拓展多种复杂功能场景运行设计域, 从而满足 ADAS 向自动驾驶转变的需求^[49]。目前, 用于创建高清地图的主流开源框架包括 Lanelet2^[50]、OpenDRIVE^[51] 和 Apollo maps^[52]。HD map 有多种建图方法, 但主要存在 GNSS 在部分场合信号较弱、IMU 和轮式编码器漂移和误差累积等问题。

为实现车辆在未知道路环境中的准确定位, 提出了即时定位与地图构建 (Simultaneous Localization and Mapping, SLAM) 问题。SLAM 可以通过融合传感器数据, 利用自身的算法和模型来实现环境建模和自身定位^[53]。目前, SLAM 算法依据常用的传感器类型可以分为视觉 SLAM 算法^[54]、激光雷达 SLAM 算法^[55]、超声波雷达

SLAM 算法^[56]和多传感器融合 SLAM 算法^[57]等。多传感器融合 SLAM 算法可以通过优势互补实现精度提高和实时性增强，并具备较强的鲁棒性和环境适应性，受到了研究人员的关注。Tian 等^[58]构建了一种结合视觉、激光、编码器和 IMU 多种信息的多传感器后端融合 SLAM 算法，并证明其构建的地图边缘更清晰，噪声更低。但 Debeunne 等^[57]也指出，目前多传感器融合 SLAM 算法仅仅只达到为单一框架提供额外信息的目标，要实现通用的 SLAM 融合框架还是一个巨大的挑战。同时，一些其他方向的 SLAM 算法也起到了良好的启发作用。Ahmed 等^[59]综述了近十年来主动式 SLAM（A-SLAM）的研究进展，并广泛地定性和定量分析了 A-SLAM 研究的方法、场景、配置、路径规划和效用函数。

由于单一传感器各自具备不同的优缺点，在交通情况复杂、城市高楼密集的环境下，现有的单一定位定向方案很难实现稳定厘米级定位，GNSS/INS/LiDAR/HD Map/VIO 的多模态融合方案受到更多关注^[60]。如麻省理工发布的视觉导航数据集 UrbanNav^[61]中，城市地区的大面积交通拥堵和高楼、树木、车辆（高度可达 4.5 m 的双层巴士）等障碍物的遮挡对融合感知定位方案提出挑

战。目前，国内外自动驾驶车企大都采用多传感器融合的方式来尝试解决此问题，新款车型及传感器配置情况如表 1 所示。

相较于乘用车自动驾驶技术的快速落地，重型车辆的 ADAS 和自动驾驶领域则主要是在自动驾驶多传感器方案设计和实际场景测试上展开研究。小马智卡于 2022 年 4 月在中国高速场景下展开接连 6 h 无人接管的自动驾驶测试，包括昼夜交替、雨雾天气和交通事故等真实场景。大陆集团在 CES 2023 上将摄像头、激光雷达和毫米波雷达集成在一个紧凑、预先校准的传感器阵列中，可极大提高重型车辆可靠识别物体和全面检测车辆周围环境的能力。同时，算法理论层面的研究也进一步深化。Tao 等^[62]通过全局位姿图优化自适应融合 VIO 和 GPS/NRTK（Network RTK，多基准站载波相位差分技术）的输出，结果表明，多传感器融合定位策略在定位精度、环境适应性、节省成本方面都取得了良好效果。Li 等^[42]提出对 GNSS PPP-RTK（PPP：Precise Point Positioning，精密单点定位）、MEMS IMU 和车轮里程计进行数据融合，定位系统在东、北和垂直方向的位置误差有效值分别为 0.02 m、0.02 m、0.06 m，高精度定位（水平方向 10 cm，垂直方向 20 cm）

表 1 国内外企业自动驾驶新款车型的传感器配置情况

Tab. 1 Sensor configurations of new self-driving models from domestic and foreign companies

公 司	时 间	车 型	主要发 售地区	自动驾 驶等级	传感器配置情况				
					激光雷达/ 个	超声波雷达/ 个	毫米波雷达/ 个	高清摄像头/ 颗	普通摄像头/ 颗
本田	2021 年	Honda Legend	日本	L3	5 (16 线)	12	5	2	4
理想	2022 年	理想 L9	中国	L2	1 (128 线)	12	1	6 (800 万像素)	5 (200 万像素)
小鹏	2023 年	P7i	中国	L2+	0	12	5	0	13
特斯拉	2023 年	Cybertruck	美国	L3	0	0	1 (Phoenix 型)	4 (540 万像素)	7 (120 万像素)
奔驰	2023 年	EQE	全球	L2+	0	12	5	共 5 个	
奥迪	2023 年	Q5 e-tron	全球	L2+	1	12	5	共 6 个	
蔚来	2023 年	ET9	中国	L2+	未知	未知	1 (4D 毫米波 雷达)	未知	未知
华为	2023 年	问界 M9	中国	L3	1 (192 线)	12	7	1 (800 万像素)	3 (250 万像素)
比亚迪	2024 年	仰望 U9	中国	未评级	0	12	4	2 (800 万像素)	6

的可用率为95.2%。值得肯定的是,随着市场竞争和研究的深入,基于多传感器融合的定位定向技术会朝着高精度、高效率和高可靠的目标进一步发展。

4 总结与展望

目前重型车辆ADAS技术研究正在向智能领域发展、向深层机理钻研,而这必然要求ADAS技术向数据层面挖掘更有效、更准确的车辆环境信息。基于对已有研究的调研与梳理,综合技术研究的体系性,未来重型车辆的ADAS研究方法发展将有以下4个特点:

(1) 研究方法将继续与乘用车同步发展,在保持技术连贯性和互操作性的同时,也会针对重型车辆特有的使用环境和现实需求进行专门的调整和优化。

(2) 基于重型车辆安全可靠、法规要求严等特点,重型车辆ADAS技术的传感器配置将更为复杂和多样化,信号传输、器件兼容和算法算力等方面将进一步发展与升级。

(3) 随着传感器技术的不断进步和算法的优化,车辆ADAS系统将能够更加准确地感知和识别周围环境,在环境感知方面呈现更强的感知范围、更精确的感知能力和更高的感知可靠性。

(4) 通过算法模型的优化和多模态异构数据的引入,重型车辆ADAS技术凭借高精度地图、轻地图以及无图智驾的辅助导航功能,将会在定位定向方面实现更加精准的车辆定位效果。

参考文献:

- [1] MACHIDA T, SHITAOKA K. Test coverage index for ADAS/ADS assessment based on various real-world information points[J]. IEEE Transactions on Intelligent Transportation Systems, 2022, 23(2): 1443-1455.
- [2] Society of Automotive Engineers. Taxonomy and definitions for terms related to driving automation systems for on-road motor vehicles: SAE J 3016—2018[S]. Warrendale: SAE, 2018.
- [3] International Organization for Standardization. Road vehicles—types—terms and definitions: ISO 3833—1977[S]. Geneva: ISO, 1997.
- [4] NATAN O, MIURA J. Towards compact autonomous driving perception with balanced learning and

multi-sensor fusion[J]. IEEE Transactions on Intelligent Transportation Systems, 2022, 23(9): 16294-16266.

- [5] HUANG X Q, DENG H, ZHANG W, et al. Towards multi-modal perception-based navigation: A deep reinforcement learning method[J]. IEEE Robotics and Automation Letters, 2021, 6(3): 4986-4993.
- [6] GU J Y, LIND A, CHHETRI T R, et al. End-to-end multimodal sensor dataset collection framework for autonomous vehicles[J]. Sensors, 2023, 23(15): 6783.
- [7] OZGUNER U, REDMILL K A, BROGGI A. Team TerraMax and the DARPA grand challenge: A general overview[C]//IEEE Intelligent Vehicles Symposium. Piscataway, NJ, USA: IEEE, 2004: 232-237.
- [8] 焦贵伟, 蔡灿伟, 陈翠华, 等. 基于CCD摄像机的装甲车辆辅助驾驶系统设计[C]//OSEC首届兵器工程大会论文集. 北京: 中国兵工学会, 2017: 93-96.
- [9] 李海玲, 罗高华, 窦佳欢, 等. 全景行车辅助系统在新能源客车上的应用[J]. 客车技术与研究, 2019, 41(5): 37-39.
- LI H L, LUO G H, DOU J H, et al. Application of panoramic driving assistance system to new energy buses[J]. Bus & Coach Technology and Research, 2019, 41(5): 37-39.
- [10] 国家标准化管理委员会. 道路车辆—先进驾驶辅助系统(ADAS)—术语及定义: B/T 39263—2020[S]. 北京: 中国标准出版社, 2020.
- [11] SHIRPOUR M, KHAIRDOOST N, BAUER M A, et al. Traffic object detection and recognition based on the attentional visual field of drivers[J]. IEEE Transactions on Intelligent Vehicles, 2023, 8(1): 594-604.
- [12] AL-MADEED S, BOUBEZARI R, KUNHOTH S, et al. Robust feature point detectors for car make recognition[J]. Computers in Industry, 2018, 100: 129-136.
- [13] SONG H S, WANG X, HUA C, et al. Vehicle trajectory clustering based on 3D information via a coarse-to-fine strategy[J]. Soft Computing, 2018, 22(5): 1433-1444.
- [14] WANG Z G, ZHAN J, DUAN C, et al. Vehicle detection in severe weather based on pseudovisual search and HOG-LBP feature fusion[J]. Proceedings of the Institution of Mechanical Engineers, Part D: Journal of Automobile Engineering, 2021, 236(7): 1607-1618.

- [15] YAO C X, ZHANG H F, ZHU J, et al. ORB feature matching algorithm based on multi-scale feature description fusion and feature point mapping error correction[J]. IEEE Access, 2023, 11: 63808–63820.
- [16] NEBAUER C. Evaluation of convolutional neural networks for visual recognition[J]. IEEE Transactions on Neural Networks, 1998, 9(4): 685–696.
- [17] WANG Z G, ZHAN J, DUAN C G, et al. A review of vehicle detection techniques for intelligent vehicles[J]. IEEE Transactions on Neural Networks and Learning Systems, 2023, 34(8): 3811–3831.
- [18] REN S Q, HE K M, GIRSHICK R, et al. Faster R-CNN: Towards real-time object detection with region proposal networks[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2017, 39(6): 1137–1149.
- [19] HUANG Z P, ZHANG Z Z, LAN C L, et al. Adaptive frequency filters as efficient global token mixers[C]//2023 IEEE / CVF Computer Society, International Conference on Computer Vision. Piscataway, NJ, USA: IEEE, 2023: 6026–6036.
- [20] MYUNG S, HUH I, JANG W, et al. PACNet: A model pruning approach to inductive transfer learning[C]//Proceeding of the 39th International Conference on Machine Learning. New York, USA: ACM, 2022: 16240–16252.
- [21] MEHTA S, RASTEGARI M. MobileViT: Lightweight, general-purpose, and mobile-friendly vision transformer [EB/OL]. 2021[2024-01-18]. <https://doi.org/10.48550/arXiv.2110.02178>.
- [22] VASWANI A, SHAZEER N, PARMAR N, et al. Attention is all you need[C]//Proceeding of the 31st International Conference on Neural Information Processing Systems. New York, USA: ACM, 2017: 6000–6010.
- [23] SUNG F, YANG Y X, ZHANG L, et al. Learning to compare: Relation network for few-shot learning[C]//2018 IEEE / CVF Conference on Computer Vision and Pattern Recognition. Piscataway, NJ, USA: IEEE, 2018: 1199–1208.
- [24] CARION N, MASSA F, SYNNAEVE G, et al. End-to-end object detection with transformers[C]//European Conference on Computer Vision. Cham: Springer, 2020: 213–229.
- [25] BEAL J, KIM E, TZENG E, et al. Toward transformer-based object detection [EB/OL]. 2012[2024-01-18]. <https://doi.org/10.48550/arXiv.2012.09958>.
- [26] YAN J J, LIU Y F, SUN J J, et al. Cross modal transformer: Towards fast and robust 3D object detection[C]//International Conference on Computer Vision. Piscataway, NJ, USA: IEEE, 2023: 18268–18278.
- [27] BELLO S A, YU S S, WANG C, et al. Review: Deep learning on 3D point clouds[J]. Remote Sensing, 2020, 12(11): 1729.
- [28] 车载激光雷达技术与应用研究报告(2023年)[R]. 北京: 中国信息通信研究院, 2023.
- [29] CHARLES R Q, HAO S, MO K C, et al. PointNet: Deep learning on point sets for 3D classification and segmentation[C]//2017 IEEE Conference on Computer Vision and Pattern Recognition. Piscataway, NJ, USA: IEEE, 2017: 77–85.
- [30] QI C R, YI L, SU H, et al. PointNet++: Deep hierarchical feature learning on point sets in a metric space [EB/OL]. 2017[2024-01-18]. <https://doi.org/10.48550/arXiv.1706.02413>.
- [31] ZHOU Y, TUZEL O. VoxelNet: End-to-end learning for point cloud based 3D object detection [C]//2018 IEEE / CVF Conference on Computer Vision and Pattern Recognition. Piscataway, NJ, USA: IEEE, 2018: 4490–4499.
- [32] YAN Y, MAO Y X, LI B. SECOND: Sparsely embedded convolutional detection[J]. Sensors, 2018, 18(10): 3337.
- [33] LANG A H, VORA S, CAESAR H, et al. PointPillars: Fast encoders for object detection from point clouds[C]//2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Piscataway, NJ, USA: IEEE, 2019: 12689–12697.
- [34] GUO M H, CAI J X, LIU Z N, et al. PCT: Point cloud transformer[J]. Computational Visual Media, 2021, 7(2): 187–199.
- [35] WANG L L, HUANG Y P. A survey of 3D point cloud and deep learning-based approaches for scene understanding in autonomous driving[J]. IEEE Intelligent Transportation Systems Magazine, 2022, 14(6): 135–154.
- [36] LI Y Y, BU R, SUN M C, et al. PointCNN: Convolution on X-transformed points [EB/OL]. 2018[2024-01-18]. <https://doi.org/10.48550/arXiv.1801.07791>.
- [37] HU Y M, LI T M, ANDERSON L, et al. Taichi: A language for high-performance computation on spatially sparse data structures[J]. ACM Transactions on Graphics, 2019, 38(6): 201.

- [38] ZHANG Z Y, HUA B S, YEUNG S K. Shell-Net: Efficient point cloud convolutional neural networks using concentric shells statistics[C]//2019 IEEE/CVF International Conference on Computer Vision. Piscataway, NJ, USA: IEEE, 2019: 1607-1616.
- [39] HU Q Y, YANG B, XIE L H, et al. RandLA-Net: Efficient semantic segmentation of large-scale point clouds[C]//2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Piscataway, NJ, USA: IEEE, 2020: 11108-11117.
- [40] HUANG K L, SHI B T, LI X, et al. Multi-modal sensor fusion for auto driving perception: A survey [EB/OL]. 2022[2024-01-18]. <https://doi.org/10.48550/arXiv.2202.02703>.
- [41] WEI Z Q, ZHANG F K, CHANG S, et al. MmWave radar and vision fusion for object detection in autonomous driving: A review[J]. *Sensors*, 2022, 22(7): 2542.
- [42] LI X X, QIN Z Y, SHEN Z H, et al. A high-precision vehicle navigation system based on tightly coupled PPP-RTK/INS/Odometer integration[J]. *IEEE Transactions on Intelligent Transportation Systems*, 2023, 24(2): 1855-1866.
- [43] HSHAZEER N, FATAHALIAN K, MARK W R, et al. HydraNets: Specialized dynamic architectures for efficient inference[C]//2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Piscataway, NJ, USA: IEEE, 2018: 8080-8089.
- [44] MESCHEDER L, OECHSLE M, NIEMEYER M, et al. Occupancy networks: Learning 3D reconstruction in function space[C]//2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Piscataway, NJ, USA: IEEE, 2019: 4455-4465.
- [45] MILDENHALL B, SRINIVASAN P P, TANCIK M, et al. NeRF: Representing scenes as neural radiance fields for view synthesis[C]//European Conference on Computer Vision. Cham: Springer, 2020: 405-421.
- [46] PENG S Y, NIEMEYER M, MESCHEDER L, et al. Convolutional occupancy networks[C]//European Conference on Computer Vision. Cham: Springer, 2020: 1-17.
- [47] FU X, ZHANG S Z, CHEN T R, et al. Panoptic NeRF: 3D-to-2D label transfer for panoptic urban scene segmentation[C]//2022 International Conference on 3D Vision. Piscataway, NJ, USA: IEEE, 2022: 1-11.
- [48] JO K, KIM C, SUNWOO M. Simultaneous localization and map change update for the high definition map-based autonomous driving car[J]. *Sensors*, 2018, 18(9): 3145.
- [49] ZHANG F Y, SHI W Z, CHEN M, et al. Open HD map service model: An interoperable high-definition map data model for autonomous driving[J]. *International Journal of Digital Earth*, 2023, 16(1): 2089-2110.
- [50] POGGENHANS F, PAULS J H, JANOSOVITS J, et al. Lanelet2: A high-definition map framework for the future of automated driving[C]//2018 21st International Conference on Intelligent Transportation Systems. Piscataway, NJ, USA: IEEE, 2018: 1672-1679.
- [51] BAO Z B, HOSSAIN S, LANG H X, et al. High-definition map generation technologies for autonomous driving[EB/OL]. 2022[2024-01-18]. <https://doi.org/10.48550/arXiv.2206.05400>.
- [52] ZHOU Y, WAN G W, HOU S H, et al. DA4AD: End-to-end deep attention-based visual localization for autonomous driving[C]//16th European Conference on Computer Vision. Cham: Springer, 2020: 271-289.
- [53] HHUANG S. A review of optimisation strategies used in simultaneous localisation and mapping[J]. *Journal of Control and Decision*, 2019, 6(1): 61-74.
- [54] DAI Y, WU J X, WANG D. A review of common techniques for visual simultaneous localization and mapping[J]. *Journal of Robotics*, 2023: 8872822.
- [55] XU X B, ZHANG L, YANG J, et al. A review of multi-sensor fusion SLAM systems based on 3D LIDAR[J]. *Remote Sensing*, 2022, 14(12): 2835.
- [56] AMJAD B, AHMED Q Z, LAZARIDIS P I, et al. Radio SLAM: A review on radio-based simultaneous localization and mapping[J]. *IEEE Access*, 2023, 11: 9260-9278.
- [57] DEBEUNNE C, VIVET D. A review of visual-LiDAR fusion based simultaneous localization and mapping[J]. *Sensors*, 2020, 20(7): 2068.
- [58] TIAN C J, LIU H B, LIU Z, et al. Research on multi-sensor fusion SLAM algorithm based on improved mapping[J]. *IEEE Access*, 2023, 11: 13690-13703.
- [59] AHMED M F, MASOOD K, FREMONT V, et

-
- al. Active SLAM: A review on last decade[J]. Sensors, 2023, 23(19): 8097.
- [60] XIN S M, GENG J H, ZHANG G H, et al. 3D-mapping-aided PPP-RTK aiming at deep urban canyons[J]. Journal of Geodesy, 2022, 96(10): 78.
- [61] WEN W S, WONG D, SUZUKI T, et al. UrbanNav: An open-sourcing localization dataset collected in asian urban canyons, including Tokyo and Hong Kong [C/OL] (2018-12-19) [2024-02-18]. <https://github.com/weisongwen/UrbanNavDataset>.
- [62] TAO X W, ZHU B, XUAN S Y, et al. A multi-sensor fusion positioning strategy for intelligent vehicles using global pose graph optimization [J]. IEEE Transactions on Vehicular Technology, 2022, 71(3): 2614-2627.