

上海交通大学学位论文

基于信息融合技术的车载无人地图学习系统

- **姓 名**: 冯乐
- 学 号: 521030910219
- **导 师**: 袁汀
- **学** 院:电子信息与电气工程学院
- 专业名称:自动化
- 申请学位层次:学士

2025年5月

A Dissertation Submitted to

Shanghai Jiao Tong University for the Degree of Bachelor

A VEHICLE-MOUNTED AUTONOMOUS MAP LEARNING SYSTEM BASED ON INFORMATION FUSION TECHNOLOGY

Author: Feng Le Supervisor: Yuan Ting

School of Electronic Information and Electrical Engineering

Shanghai Jiao Tong University

Shanghai, P.R. China

May, 2025

上海交通大学

学位论文原创性声明

本人郑重声明:所呈交的学位论文,是本人在导师的指导下,独立进行研究工作 所取得的成果。除文中已经注明引用的内容外,本论文不包含任何其他个人或集体 已经发表或撰写过的作品成果。对本文的研究做出重要贡献的个人和集体,已在文 中以适当方式予以致谢。若在论文撰写过程中使用了人工智能工具,本人已遵循《上 海交通大学关于在教育教学中使用 AI 的规范》,确保人工智能生成内容的应用场景、 引用范围及标注方式均符合规定,并杜绝学术不端行为。本人完全知晓本声明的法律 后果由本人承担。



上海交通大学

学位论文使用授权书

本人同意学校保留并向国家有关部门或机构送交论文的复印件和电子版,允许论文被查阅和借阅。

本学位论文属于:

₩公开论文

□内部论文,保密□1年/□2年/□3年,过保密期后适用本授权书。

□秘密论文,保密____年(不超过10年),过保密期后适用本授权书。

□机密论文,保密____年(不超过 20 年),过保密期后适用本授权书。

(请在以上方框内选择打"√")

学位论文作者签名:冯乐、日期:2025年6月5日

指导教师签名: 🍒 汀 日期: **ン>>5** 年 🔓 月 5 日

摘要

在自动驾驶系统中,高精度地图不仅是实现车辆自主定位与环境感知的关键基础,也是支撑路径规划与控制决策的核心要素。相较于传统传感器感知,高精地图可提供更丰富的语义信息与结构化先验知识,从而显著提升系统在复杂交通环境下的鲁棒性与安全性。然而,当前地图构建仍面临诸多挑战。一方面,不同传感器在感知范围、抗干扰能力等方面存在差异,单一传感器往往难以满足高精度建图需求。另一方面,新算法的验证依赖大量多样化的高质量数据,而受制于数据采集成本高、场景构建复杂等因素,有效道路数据的获取仍存在较大困难,制约了建图算法的实际应用推广。为有效应对上述挑战,本研究参与搭建了一套智慧数据采集平台,并提出了一种基于信息融合技术的同步定位与建图方法,将GPS、激光雷达与IMU的数据通过主成分分析算法(Principal Component Analysis, PCA)进行融合处理,以提升自动驾驶场景下地图构建的准确性与鲁棒性。本文主要研究内容如下:

(1)系统地梳理了即时定位与地图构建(Simultaneous Localization and Mapping, SLAM)系统的理论框架与关键技术,重点分析了运动模型构建、状态估计方法与多 传感器信息融合机制,深入分析了毫米波雷达与激光雷达的互补优势。

(2)参与搭建集成了多种传感器的智慧数据采集平台,基于 Ubuntu 操作系统与 ROS (Robot Operating System)框架,形成了完整的数据采集、处理与可视化的框架。 同时对上海交通大学闵行校区的多段道路进行了数据采集,主要负责数据平台后端 数据处理模块,对传感器采集的原始数据进行数据处理,对各类传感器采集信息的数 据结构进行了统一建模。

(3)构建了基于融合算法的地图学习系统,为提升建图效率与定位精度,本文 提出了一种基于主成分分析的 (Principal Component Analysis, PCA)的建图算法,并 使用采集的数据进行仿真。该算法通过将多源传感器数据通过 PCA 进行融合,实现 了对动态环境的稀疏建图与实时位姿估计,提高了系统的运行效率与环境建图能力, 进一步证明了所提出算法在实际应用中的实用性与可靠性。

综上所述,本文在多传感器信息融合、建图算法及验证方面进行了深入研究,构 建了一套适用于智能车辆的高精度建图与定位方法,具备良好的实际应用前景。

关键词:自动驾驶,多传感器融合,点云地图,SLAM,激光雷达

Ι

ABSTRACT

In autonomous driving systems, high-definition (HD) maps serve not only as a fundamental basis for vehicle self-localization and environmental perception but also as a critical component supporting path planning and control decision-making. Compared to conventional sensor-based perception, HD maps provide richer semantic information and structured prior knowledge, significantly enhancing the robustness and safety of autonomous systems in complex traffic environments. However, the construction of HD maps still faces numerous challenges. On one hand, different sensors vary in terms of perception range and resistance to interference, and relying on a single sensor often fails to meet the precision requirements of high-quality mapping. On the other hand, the development and validation of novel mapping algorithms require large volumes of diverse, high-quality data, while the acquisition of effective road data remains a major bottleneck due to high collection costs and the complexity of real-world scene modeling, thus limiting the practical deployment of mapping technologies.

To address these challenges, this study participates in the development of an intelligent data acquisition platform and proposes a simultaneous localization and mapping (SLAM) method based on multi-source information fusion. Specifically, data from GPS, LiDAR, and inertial measurement units (IMUs) are fused using Principal Component Analysis (PCA) to enhance the accuracy and robustness of map construction in autonomous driving scenarios. The main contributions of this research are as follows:

(1) A systematic review of the theoretical framework and key technologies of SLAM systems is conducted, focusing on motion modeling, state estimation methods, and multi-sensor data fusion principles. The complementary perception characteristics of millimeter-wave radar and LiDAR are also thoroughly analyzed.

(2) The study is involved in building an intelligent data acquisition platform that integrates multiple types of sensors. Based on the Ubuntu operating system and the Robot Operating System (ROS) framework, a complete data collection, processing, and visualization pipeline has been established. Field data were collected across multiple road segments on the Minhang Campus of Shanghai Jiao Tong University. The research primarily contributes to the back-end data processing module, including the handling of raw sensor data and the unified modeling

of heterogeneous data structures.

(3) A map learning system based on the proposed fusion algorithm is developed. To improve mapping efficiency and localization accuracy, a PCA-based mapping algorithm is introduced and tested using the collected dataset. By fusing multi-source sensor data through PCA, the proposed method enables sparse mapping in dynamic environments and real-time pose estimation, thereby improving both system efficiency and mapping capability. Experimental results demonstrate the practical applicability and reliability of the algorithm in real-world scenarios.

In summary, this work presents an in-depth study on multi-sensor data fusion, mapping algorithms, and system validation, and proposes a high-precision mapping and localization method suitable for intelligent vehicles, with strong potential for real-world deployment.

Key words: Autonomous Driving, Multi-Sensor Fusion, Point Cloud Map, SLAM, LiDAR

目	录
_	

摘	要	•••••		Ι	
Al	ABSTRACT				
第	一章	绪论		1	
	1.1	课题研	究背景及意义	1	
	1.2	课题研	· 究现状	2	
		1.2.1	自动驾驶地图研究现状	2	
		1.2.2	多传感器融合技术研究现状	5	
		1.2.3	同步定位与建图算法研究现状	8	
	1.3	论文主	要内容与章节安排	10	
第	二章	基于	信息融合技术的 SLAM 基础理论	11	
	2.1	SLAM	理论基础	11	
		2.1.1	SLAM 基础概念介绍	11	
	2.2	传感器	测量原理	15	
		2.2.1	毫米波雷达测量原理	15	
		2.2.2	激光雷达测量原理	17	
	2.3	多传感	器融合原理	18	
第	三章	基于	信息融合的建图系统设计与算法研究	22	
	3.1	激光雷	达 SLAM	22	
		3.1.1	2D SLAM	22	
		3.1.2	3D SLAM	24	
	3.2	2 Lidar/Radar 融合算法研究		26	
		3.2.1	时间同步	26	
		3.2.2	激光雷达和毫米波雷达融合算法	26	
第	四章	栅格	地图的数据采集与数据处理	29	

	4.1	实地数	据采集	29
		4.1.1	数据采集车平台搭建	29
		4.1.2	数据采集环境	30
	4.2	数据结	构	31
		4.2.1	RawData	32
		4.2.2	SensorData	33
		4.2.3	VehiclePhaseData	33
		4.2.4	EnvironmentData	34
	4.3	数据处	理流程	34
껔	工辛	建网络	立影与地图再新	36
ЯÌ	卫早			30
	5.1	二维佈	逾栅格地图建图	36
	5.2	运用 P	CA 处理建图和更新	37
第	六章	总结	与展望	41
	6.1	总结		41
	6.2	展望		42
	6.3	非技术	性分析	42
参	考	文	献	43
致		谢		46
英	文大	摘要		47

第一章 绪论

1.1 课题研究背景及意义

伴随社会的不断发展与技术水平的持续提升,汽车已逐渐成为人们工作与生活 中不可或缺的交通工具。然而,与汽车普及并行的交通安全问题、道路拥堵以及能源 消耗等现象,也日益受到公众与研究界的重视。根据世界卫生组织于 2023 年发布的 《全球道路安全状况报告》,每年因交通事故导致死亡的人数大约为 119 万,凸显出道 路交通安全问题的严峻性。分析事故成因可知,驾驶行为不规范及人为操作错误仍是 主要诱因之一。随着汽车智能化程度不断加深,自动驾驶技术被广泛认为是提升道路 行驶安全性与交通运输效率的重要手段。根据美国密歇根大学交通研究所 2015 年的 研究结果,约 85% 的交通事故可以被有效规避;同时,电气与电子工程师协会预测, 到 2040 年,美国市场上高级别自动驾驶新车的使用率将达到约 75%;中国在其智能 网联汽车发展路线图中也提出,到 2030 年,高等级自动驾驶车辆将在新车销售中占 比达到 10% 至 20%。

在自动驾驶系统中,自动驾驶地图被认为是一项核心技术。现阶段智能网联汽车 的诸多功能模块中,该地图不仅用于支持全局车道级路径的规划,还为局部轨迹的设 计与优化提供关键的先验信息,并作为实现基于地图主动定位的前提条件^[1]。与传统 导航地图相比,自动驾驶地图具有更高的信息精度与更全面的环境表达能力,能够向 车辆提供详细且可靠的周边环境数据,有效减轻感知系统的压力,是推动自动驾驶技 术规模化应用的关键支撑^[2]。

通常,自动驾驶地图主要分为矢量地图与点云地图两类。矢量地图以点、线等几 何元素为基础,抽象表达环境结构^[3]。在降低数据存储成本的同时,对场景细节的还 原能力有所牺牲,因此存在一定程度的功能局限。而点云地图则可真实刻画三维空间 中的环境特征,包含了丰富的语义与几何信息,支持车辆实现高精度定位、动态障碍 物识别、可行驶区域提取等功能^[4]。同时,基于点云地图还能够进一步提取多种矢量 化特征,为更多自动驾驶应用提供数据支撑。

值得注意的是,受限于单一传感器所能捕捉的信息维度,仅依赖单一传感器构建的点云地图存在精度与完整性方面的限制^[5]。因此,将视觉图像与激光点云数据进行深度融合,构建多源感知的点云地图,已成为当前研究的一个重要方向。

对于高阶自动驾驶应用而言, 地图具备动态更新的能力尤为重要。车辆在依托地

图实现路径导航与环境理解的同时^[6],还需对环境中的变化进行实时感知与地图同步 更新,以应对高动态交通环境的需求^[7]。然而,目前自动驾驶地图的更新方式仍处于 探索阶段,大多数方法依然依赖于测绘车辆进行重新采集,更新周期长,难以适配快 速变化的道路场景。随着车联网特别是第五代通信技术的兴起^[8],自动驾驶车辆具备 了实时上传感知数据的能力,这为构建高频动态更新的点云地图系统提供了全新的 技术支撑。

本文基于多传感器融合技术,提出了一种针对复杂环境下的无人车地图学习系统。研究针对传统单一传感器在地图构建过程中的感知局限性与鲁棒性不足问题,综合利用激光雷达、IMU 等传感器数据,提出了一种基于主成分分析算法的融合方法,有效提高了系统在复杂环境中的感知精度与鲁棒性。本研究的核心创新在于利用 PCA 对多源信息进行融合,有效解决了不同传感器适用性场景不同给建图带来的挑战,为实时定位与地图构建提供了更加可靠的支持。

总体而言,本文的研究成果为无人车地图构建与环境感知领域提供了一种新的 解决方案,为进一步提高无人车系统的感知精度、稳定性与鲁棒性具有积极意义。

1.2 课题研究现状

1.2.1 自动驾驶地图研究现状

自汽车诞生以来,地图系统便始终伴随其发展,扮演着至关重要的辅助角色。早期的车载地图主要以导航功能为核心,其设计目标是为车辆提供宏观层面的路径规划支持^[9]。然而,这类传统导航地图在信息量和空间精度方面存在明显不足,难以满足智能汽车对于环境认知与决策支持的高精度要求,因而无法有效支撑自动驾驶系统的复杂功能需求。

与常规导航地图相比,自动驾驶专用地图具备更高的精细度与信息密度,不仅 包含对行驶环境的高精度建模信息,还集成了大量关于道路结构和交通规则的语义 数据。因此,此类地图被广泛认为是实现自动驾驶技术不可或缺的核心支撑之一^[10]。 目前,自动驾驶地图通常划分为两种主要类型:矢量地图与点云地图。前者通过抽象 的几何元素(如点、线和面)来表达道路环境结构,而后者则依赖三维空间中的高密 度点集对周边实体进行直观建模,具有更强的还原能力。

在二者之间,矢量地图由于数据量相对较小、存储需求较低,因而在早期自动驾驶系统中得到了优先应用。例如,在 DARPA Urban Challenge 赛事中,主办方提供了

名为 Route Network Definition File (RNDF)的标准化地图格式,向参赛车辆提供包括车道线、道路宽度以及停车标志等基本结构信息^[11]。但是,该类地图在表达周围环境特征(如障碍物、路边设施等)方面仍显不足,限制了其在复杂场景下的实用性。

为实现更广泛的工业标准化,多个国际汽车厂商、地图服务商、零部件供应商与 系统集成商共同组建了 NDS(Navigation Data Standard)协会,并自 2008 年起发布 NDS 标准地图格式。NDS 地图格式已由最初的 0.1 版本演进至当前的 2.5.4 版本,其 覆盖能力和信息结构日益完善。值得注意的是,最初版本的 NDS 地图主要面向传统 导航需求,仅涵盖道路层级的基本信息,难以满足自动驾驶系统的高精度感知和决策 需求。为此,NDS 于 2015 年 3 月发布了针对自动驾驶的 Auto Drive 1.0 版本,引入 了诸如交通信号灯、标志牌等关键元素的矢量信息,以增强地图在自动驾驶场景下的 应用能力^[12]。

在相关研究中,Xiao 等人^[13]利用该类自动驾驶矢量地图,实现了无需全球导航 卫星系统 (Global Navigation Satellite System, GNSS) 辅助的车辆自主定位。尽管该方 法具有一定实用价值,但相较于基于点云地图的定位方案,其在定位精度方面仍存 在一定差距。这主要归因于矢量地图在细节还原能力与信息丰富性方面的天然限制, 难以为车辆提供全方位的环境感知支持。

与此同时,LDM (Local Dynamic Map)作为一种专用于车联网环境下的数据结构,是欧洲 C-ITS 项目 SAFESPOT 中提出的一种矢量地图模型,其设计重点在于支持车辆之间的数据交互和地图信息共享^[14]。与前述传统地图格式相比,LDM 采用了分层的数据组织结构,除了包含基础的静态地理信息外,还引入了准静态层和动态层,从而能够动态集成交通信号状态、道路施工信息以及移动障碍物等内容。该设计理念充分体现了在车-车通信基础上实时更新地图数据的必要性和前瞻性。

在自动驾驶矢量地图的构建初期,研究者通常采用差分 GNSS 设备结合人工测量的方式,在车道中心线选取一系列控制点,并由此生成车道几何模型。然而,这种基于人工干预的方法不仅耗时长、效率低,其测量精度也易受环境干扰而波动。为提升构图效率,卡耐基梅隆大学的 Seo 等人^[15]提出了一种基于正射航拍图像的自动车道提取方法,从遥感图像中识别道路结构并生成矢量地图。尽管该方法在构建路网信息方面取得了一定进展,但其难以覆盖诸如交通标识、障碍物等关键行驶环境要素,功能仍较为局限。

为进一步解决上述问题,NAVTEQ 公司^[16]提出了一种以激光雷达为基础的地图 构建流程。首先通过激光点云重建三维环境,再在此基础上提取车道边界与道路标

识等关键特征信息,由此生成矢量地图。这一方法不仅显著提升了地图生成的效率, 也在精度层面优于传统人工测绘技术。目前,基于激光雷达生成点云地图并从中提取 几何与语义特征,已成为高精度矢量地图生成的主流技术路径,点云地图逐渐在自动 驾驶领域占据了核心地位。

点云地图利用传感器获取的三维数据对环境进行描述,从而能够更加精确地对 物体进行建模。最初,点云地图主要应用于自然环境建模、城市规划和灾害监测等领 域。由于其测量精度极高,点云地图的应用领域迅速扩展^[17]。随着智能汽车技术的 进步,点云地图的构建逐渐转向专注于车辆行驶环境的建模,自动驾驶点云地图应运 而生,并被认为是在自动驾驶环境建模中的关键步骤^[18]。

点云地图的广泛应用也在不断推动智能车辆环境感知技术的发展。Yoneda 等 人^[19]提出了一种基于点云地图的定位方法,可在不依赖 GNSS 的情况下实现车辆自 身位置的估计,显著提升了系统的应用范围。随后,Caselitz 等人^[20]进一步发展出基 于摄像头图像进行地图匹配定位的方法,尽管其在成本方面具有优势,但在精度和鲁 棒性方面仍不及激光雷达。此外,Boyko 等人^[4]利用点云数据中的结构特征实现了可 行驶区域的检测,有效辅助自动驾驶系统进行路径规划。

与矢量地图相比,点云地图具备更强的环境细节还原能力,能够提供丰富的三 维空间结构信息及周围物体表面形态。因此,在高级感知任务中具有重要应用价值。 例如,Uber 与多伦多大学研究团队^[21]结合点云地图中蕴含的空间先验信息,辅助神 经网络进行三维目标检测,其效果显著优于纯视觉方法。

自动驾驶点云地图的另一项显著优势在于其所携带的高精度环境信息,可以根据车辆功能模块的不同需求,灵活地提取所需的矢量特征,或进一步生成结构化的矢量地图。例如,NAVTEQ公司^[16]在其研究中基于点云中的几何特征与反射率数据,成功地从中提取出车道线和交通标识牌的对应点云,使得该类地图不仅具备空间几何信息,还融合了道路规则属性。进一步地,通过对这些目标点云进行加工与压缩,可构建出简洁高效的矢量地图格式。NAVTEQ 提出的点云提取与矢量化策略也成为当前百度、高德、Here 等多家国内外地图企业在构建高精地图时的重要参考路径。

需要指出的是,传统基于激光雷达采集的点云地图,仅包含三维坐标与激光回波 强度信息,在表达语义层面的交通信息(如限速、警示等)方面存在明显不足。为弥 补这一短板, Chen 等人^[16]提出了一种融合视觉信息的多模态方法:首先通过点云中 的反射率与几何尺寸判别出交通标识牌的边界框,然后将该框区域重投影至图像中, 以识别其中的文本信息(如限速数值),最终将识别结果反嵌入至点云地图中。该方

法对点云与图像之间的配准精度要求相对较低,提升了实际应用的可行性。此外,为 了更加高效地从点云中提取如车道线等矢量元素,Gao 等人^[5]进一步引入了有颜色的 点云地图,实现了多种道路环境信息的自动提取,并将提取结果嵌入至地图中,极大 地扩展了点云地图在自动驾驶系统中的适用场景。

早期的三维点云地图主要依赖机载激光扫描系统(Airborne Laser Scanner, ALS) 进行采集,但由于该方式更适用于自然环境(如森林植被)建模,其在城市道路等复 杂交通场景中的应用效果有限。随着移动激光扫描技术(Mobile Laser Scanner, MLS) 的出现,基于车载平台的激光建图系统(Vehicle-based Laser Scanning, VLS)逐渐兴 起,该技术能够对道路结构、道路标线、路边障碍物等元素进行高精度三维建模,显 著推动了点云地图在自动驾驶领域的应用发展。^[22]

目前,自动驾驶点云地图采集车辆通常集成了多种高精传感器,包括激光雷达、 差分 GNSS 系统、惯性测量单元(Inertial Measurement Unit, IMU)以及摄像头等组 件,协同完成环境数据采集任务。点云地图的构建过程可分为两个核心步骤:一是基 于多传感器数据融合的车辆位姿估计,旨在准确还原地图采集过程中每一帧激光数 据所对应的六自由度空间位置与姿态;二是基于上述位姿信息进行激光点云的时空 拼接,并通过视觉与激光雷达之间的信息关联,将场景中的颜色、语义、规则等多模 态信息整合进统一的点云地图中,从而构建出面向自动驾驶应用的高精地图数据集。

1.2.2 多传感器融合技术研究现状

在自动驾驶系统中, 传感器感知功能作为其基础性前提, 对整个系统的性能具 有决定性影响。传感器的测量精度、感知范围以及响应时效等参数, 直接关系到车辆 在实际行驶过程中的感知质量。感知模块所采集的数据不仅影响车辆对环境的理解, 还会显著影响后续的定位与地图构建精度。与此同时, 定位与建图作为路径规划和导 航控制的基础环节, 其准确性对自动驾驶的稳定性和行驶安全具有关键作用。因此, 传感器感知与定位建图在智能驾驶架构中占据核心地位。

在现实的道路场景中,尤其是复杂多变的环境条件下,单一类型的传感器往往难 以实现稳定可靠的定位效果。这种局限性主要源于非结构化道路、环境特征的随机性 以及全球导航卫星信号的不连续性等因素所造成的干扰,导致单一传感器方案在鲁 棒性方面表现欠佳,难以满足复杂场景下的定位需求。

在移动机器人导航系统的设计中,传感器被广泛用于环境建模与自主定位。按 照定位方式的不同,常将传感器划分为两类:相对定位类传感器与绝对定位类传感

器^[23]。前者包括视觉惯性组合系统(视觉里程计)以及惯性测量单元等,主要通过测量移动平台相对于初始位置的变化,实时推算其运动状态。而后者,如全球定位系统(Global Positioning System, GPS)、人工标记导航、激光雷达、超声波定位系统及摄像头等,主要通过获取车辆在全局参考框架下的位置信息,完成绝对定位任务。两类传感器各具优势:绝对定位传感器具有较高的测量精度,但其更新频率较低;而相对定位设备更新速率快,能够捕捉细致的动态信息,但长期使用过程中存在累计误差的问题。

进一步地, 传感器还可根据其所处位置与功能特性划分为自载式动载传感器与 外部绝对定位传感器。动载类设备, 如编码器和 IMU, 能够监测机器人自身的运动 状态变量,包括线速度、角速度与加速度等参数,并在此基础上构建运动学模型, 实 现位置与姿态的估计^[24]。然而,由于积分误差的不可避免积累,该类方法在长时间 运行中会导致显著偏移,限制了其在长期导航任务中的适用性。与之相对,外部式绝 对定位传感器,如激光雷达、摄像头及 GPS 系统,能够提供环境中机器人精确的位 置与方向信息,并常用于滤波器等模型中对动载数据进行实时修正。不过,需要指出 的是,这些传感器本身无法测量机器人自身的动态过程,仅能提供静态或瞬时的位置 信息。

在以往的研究中,环境信息的感知与测量大多依赖于单一类型的传感器。然而, 在动态且复杂的外部环境下,传感器自身的系统性误差及外部噪声因素常常会对感 知结果造成显著干扰,导致测量数据出现较大偏差。因此,为了提升环境感知的可靠 性与准确性,研究者逐渐将多种传感器的数据进行融合处理。多传感器数据融合技术 最初主要应用于军事系统,旨在提升战场态势的综合感知能力和指挥决策的响应速 度。该技术通常基于雷达、电子干扰侦测装置等多源信息输入,通过特定的融合算法 实现了对目标的精确跟踪与航迹的高效估计。

随着该技术的持续演进,研究者逐步攻克了诸如声学传感器与激光传感器状态 估计等技术瓶颈。近年来,多传感器融合方法已在多个领域得到了深入应用,并取得 了显著成果。其中,移动机器人领域成为典型代表场景之一。机器人在未知环境中执 行任务时,需依赖传感器测距完成对障碍物的探测与路径规划,多源数据融合有助于 增强其环境理解与自主决策能力。目前常见的多传感器融合算法包括模糊逻辑方法、 人工神经网络、卡尔曼滤波器、贝叶斯推断方法以及加权平均策略等。

信息融合技术最早可追溯至 20 世纪 70 年代初,美国率先开展相关研究,并在 80 年代逐步形成较为系统化的数据融合框架。其后,信息融合理论与方法在各类工

程和智能系统中迅速发展。G. Yan Hui Dayton 等人^[25]在海军现代作战系统中引入神 经网络以优化目标识别与任务分配流程,实现了海洋作业的自动化监控,从而显著 增强了军事安全性。任伟建等^[26]则将误差反向传播算法 (error BackPropagation, BP) 引入移动机器人平台,通过多传感器联合测距显著提升了测量精度。

在自动驾驶的定位与导航技术中,多源传感器融合方法已得到了广泛应用与验证。王随阳等^[27]通过构建一个以扩展卡尔曼滤波为核心的分层融合架构,将初级滤波器输出的位姿数据作为次级滤波器的初始输入,成功实现了多传感器的紧密耦合定位策略。闫飞等^[28]提出了一种融合激光测距与视觉感知的实时处理方法,该算法基于激光投影与统计推断理论,有效整合了激光与视觉两类信息资源。然而,单独依赖激光雷达和视觉传感器往往难以全面反映环境特征,尤其在低光或恶劣天气条件下,其数据可靠性可能显著下降。相比之下,IMU 具有不受光照及气候影响的优势,因而成为增强 SLAM 鲁棒性的有效补充。

Kang R 等人^[29]引入一种融合 IMU 与视觉里程计的系统,通过构建双自由度运动 模型并进行预积分操作,实现了定位精度的有效提升。为缓解 SLAM 过程中可能出 现的地图漂移问题,Shan T 等^[30]基于因子图优化框架,提出融合激光雷达与 IMU 测 量信息的平滑映射算法,其中预积分的 IMU 数据为激光点云配准提供了约束与初始 估计。Qin C 等^[31]进一步利用 IMU 高频测得的三轴加速度与角速度信息,结合迭代 误差状态卡尔曼滤波方法,将预积分误差与点云配准结果协同处理,弥补了激光雷达 数据频率偏低的缺陷。

近年来,融合视觉、IMU 与轮速计的定位方法逐渐成为研究热点。Liu J 等人^[32]提 出将摄像头、IMU 和轮编码器组合用于汽车定位系统,提升了系统对动态变化的适 应能力。Ye H 等人^[33]则通过构建滑动窗口内的联合优化机制,将 IMU 运动数据与激 光雷达位姿共同纳入优化范畴,并借助回环检测修正姿态漂移,显著降低了长期累计 误差。尽管如此,基于视觉的传感器依旧存在光照敏感的问题,在低光或强光环境下 功能受限,限制了其适用范围。

为了实现对复杂多变场景下的精确定位,亟需配置多类型、互为补充的传感器组合,通过优势互补提高系统的整体性能。Afia A B 等人^[34]利用联合卡尔曼滤波算法整合 IMU、GPS、轮速计与单目视觉 SLAM 信息,采用 IMU 进行状态预测,其余传感器用于修正与校正,形成闭环反馈机制。Liang Y 等人^[35]进一步设计了一种基于激光 雷达、IMU、GNSS 与相机的六自由度姿态估计系统,利用各类传感器提供的冗余信息,全面提升了系统的稳定性与定位精度。

1.2.3 同步定位与建图算法研究现状

同步定位与地图构建(Simultaneous Localization and Mapping, SLAM)问题通常 被定义为:在多源传感器观测的基础上,对移动平台的路径轨迹与周围环境地图进行 联合后验概率的估计。在 SLAM 的典型研究框架中,第一步通常涉及从原始传感数 据中提取关键特征,以建立不同观测之间的关联,并初步估算平台的位姿变换,这一 过程被称为"前端";随后,系统利用前端所提供的约束信息进行运动状态推断与地 图的持续优化更新,该部分则被称为"后端"。

SLAM 问题的研究,在前端处理环节主要聚焦于如何针对平台搭载的多种传感 器类型设计高效的数据处理策略。研究人员已提出多种用于特征提取与数据关联的 方法。以视觉 SLAM 为例,当前主流方案包括基于图像特征的提取方法、直接法以 及光流法等。其中,特征法通常通过检测图像中的关键点并生成相应的描述符,将这 些点作为地图构建的地标^[36]。接下来,通过对特征点进行匹配,并结合随机样本一 致性算法 (Random Sample Consensus, RANSAC)^[37]过滤误匹配,选出满足同一运动 模型的匹配对,实现观测之间的配准与初始位姿的估计。尽管该方法在纹理丰富、结 构清晰的环境中表现良好,但在特征稀疏或纹理模糊的区域往往效果不佳。此外,描 述子的计算开销较大,且未能充分利用图像中非关键区域的信息,导致潜在感知信息 被浪费。

相较之下,直接法^[38]与光流法^[39]则绕过显式特征提取步骤,依据图像亮度在短时间内保持不变的假设,直接从像素级灰度变化中推断位姿。尽管这类方法在图像帧间变化平缓时具有较高的精度表现,但由于其依赖的亮度恒定假设在复杂环境中易被打破,因此当图像亮度剧烈变化时,算法稳定性和鲁棒性大幅下降。

在激光雷达 SLAM 系统中,前端任务通常通过帧与帧之间的点云配准实现数据 抽象。目前应用最广泛的点云匹配方法是迭代最近点(Iterative Closest Point, ICP)算 法,其核心思想是在连续迭代中寻找最近点对,并据此估计两帧之间的刚性变换^[40]。 尽管 ICP 算法仅考虑点与点之间的欧氏距离,未整合局部几何结构信息,但在缺 少高质量环境模型时依然具有一定实用价值。为提升配准的精度,广义迭代最近点 (Generalized ICP, G-ICP)在 ICP 基础上引入了局部平面假设,通过设定不同方向上的 协方差矩阵,更合理地建模点云的局部结构,从而优化匹配损失函数^[41]。另一种替 代方法是正态分布变换(Normal Distribution Transform, NDT),该方法通过将点云所 在空间划分为网格单元,并在每个网格中用高斯分布拟合点的分布特征,以此求解最 佳变换^[42]。NDT 不依赖于明确的点对构建,适合处理非结构化环境场景,但匹配精

度与处理效率通常受限于网格划分的分辨率。此外,部分研究工作还致力于从激光点 云中提取结构性特征,例如快速定位关键区域^[43],以增强前端处理的表达能力和鲁 棒性。

SLAM 系统后端的关键任务在于通过整合传感器观测信息,对移动平台的轨迹 与环境地图状态进行联合概率估计。目前,该领域的主要研究路径可分为两大类:基 于滤波理论的方法和依托图优化的技术。滤波方法依赖于马尔可夫假设,认为平台在 当前时刻的状态仅与其上一个状态以及相应的控制输入相关,因此能够对历史观测 进行有效边缘化处理。此类方法通常采用"预测—校正"的递推结构进行状态估计: 其中,预测阶段利用运动模型对未来状态进行概率推断;而在更新阶段,系统根据新 获取的观测数据,并借助测量模型对当前状态进行修正。

考虑到多数传感器模型和运动过程非线性特征显著,因此标准的卡尔曼滤波 (Kalman Filter, KF) 需要进行线性化处理。扩展卡尔曼滤波 (Extended Kalman Filter, EKF)^[44]通过泰勒展开线性化系统模型,而无迹卡尔曼滤波 (Unscented Kalman Filter, UKF)^[45]采用确定性采样与加权均值实现精确的统计线性化。当系统动态高度非线性 或存在非高斯噪声时,粒子滤波 (Particle Filter, PF)则通过采样与加权方式对状态分 布进行逼近,更加适用于此类情况。典型基于滤波的 SLAM 框架包括快速定位与建 图^[46](Fast Simultaneous Localization and Mapping, FastSLAM)、Google 的 Cartographer 系统等^[47]。

另一条研究路径为基于图优化的后端方法。该方法将传感器观测转化为误差项, 通过求解所有误差的加权和来估计状态,常用的优化方法包括高斯牛顿法和莱文贝 格-马夸特 (Levenberg-Marquardt, LM)方法。随着运行时间延长,状态变量和误差项 迅速增加,导致求解效率下降。不过,由于每一帧通常只能观测到少量地标,导致优 化问题本质上具有稀疏结构,可利用稀疏矩阵求解器进行高效优化^[48]。增量式平滑 和建图方法 (Incremental Smoothing and Mapping, ISAM)则通过因子分解与增量更新 机制,使图优化过程在计算复杂度可控的前提下实现在线更新^[49]。

当前的雷达 SLAM 方法普遍面临几个关键挑战,其中包括在真实场景中的验证 不足,以及缺乏有效的闭环检测机制,从而导致平台在长时间运行过程中累计的位姿 误差较大。相较于已经较为成熟的基于激光雷达和视觉的 SLAM 技术,雷达方案在 定位精度方面尚存在显著差距。因此,为实现具备实用性和高精度的雷达 SLAM 系 统,有必要深入开展闭环检测算法的研究,并推动其在复杂实际环境中的应用落地。

1.3 论文主要内容与章节安排

本文共五章,各章具体内容安排如下:第一章为绪论,主要介绍本课题的研究背 景和研究意义,指出在自动驾驶快速发展的背景下,高精度地图和环境感知能力对无 人系统的重要性。随后对自动驾驶地图、多传感器融合技术及 SLAM 算法的国内外 研究现状进行综述,归纳目前研究中存在的不足,并明确本论文的研究目标和创新 点。

第二章基于信息融合技术的 SLAM 基础理论本章系统阐述 SLAM 的基本原理与 理论框架,涵盖 SLAM 的核心概念与运动模型。重点分析了毫米波雷达和激光雷达 的测量原理及其在建图中的作用,并进一步探讨了多传感器融合的数学原理与实现 方式,为后续系统设计奠定理论基础。

第三章基于信息融合的建图系统设计本章围绕激光雷达与毫米波雷达的融合算 法展开,具体介绍两种传感器在空间与时间上的同步方法,以及如何在算法层面实现 高效的数据融合。特别介绍了基于扩展卡尔曼滤波的融合方法和融合数据下的建图 算法,结合 ROS 系统实现了初步系统原型。

第四章实验平台及实验结果本章介绍了实验平台的软件架构,通过对开源数据 进行建图验证,评估融合算法在复杂环境下的表现,从准确性、鲁棒性与实时性等方 面对系统性能进行了分析与对比验证。

第五章总结与展望本章对全文的研究工作进行了总结,并指出存在的不足,并对 未来的研究方向进行展望。

第二章 基于信息融合技术的 SLAM 基础理论

2.1 SLAM 理论基础

2.1.1 SLAM 基础概念介绍

在 SLAM 问题的研究中,系统依赖于所搭载的各类传感器对外部环境及其自身运动状态进行观测。通过选用合适算法,构建环境地图的同时也完成平台自身位姿的估计。为了达到较高的鲁棒性和估计精度,系统通常采用多种估计方法进行融合优化。

在配备多传感器的 SLAM 平台中,用于描述平台运动的观测数据通常被称为控制输入,记作 *u*_t,表示系统在时刻 *t* 的输入信息。对于运动限制在二维空间的系统,其自由度包括两个方向上的平移速度和一个角速度,其数学形式可参见式 (2-1)。

$$\boldsymbol{u}_t = \begin{bmatrix} \boldsymbol{v}_x & \boldsymbol{v}_y & \boldsymbol{\omega} \end{bmatrix}^T \tag{2-1}$$

与环境交互所获取的信息称为观测值,在时间点 t 记为 z_t,如式(2-2)所示。常见的观测类型涵盖物体与传感器之间的相对距离与方向角。以激光雷达为例,测量数据中还可能包含反射强度以及多普勒速度等辅助信息。

$$z_{t} = \begin{bmatrix} \mathbf{r}_{1} & \mathbf{\theta}_{1} & \mathbf{v}_{d1} \\ \vdots & \vdots & \vdots \\ \mathbf{r}_{N} & \mathbf{\theta}_{N} & \mathbf{v}_{dN} \end{bmatrix}$$
(2-2)

系统轨迹通常以离散时间序列的形式表示,即记录平台在每一时刻的空间位置 与朝向。对于在二维平面上运动的载体,其位姿由全局坐标系下的位置坐标与航向角 共同定义,具体见式(2-3)。

$$\boldsymbol{X}_{t} = \begin{bmatrix} \boldsymbol{x}_{t} & \boldsymbol{y}_{t} & \boldsymbol{\alpha} \end{bmatrix}^{T}$$
(2-3)

若环境信息通过地标点构建地图,则地图可由这些特征点在全局坐标系中的空间位置组成,详见式(2-4)。当采用栅格地图进行建图时,环境被划分为一系列小单元格,每个单元格以占据或空闲状态表征,形成一张离散化的空间地图。

$$\boldsymbol{m} = \begin{bmatrix} l_x 1 & l_y 1\\ \vdots & \vdots\\ l_{xM} & l_{yM} \end{bmatrix}$$
(2-4)

为有效刻画传感器测量过程中的不确定性, SLAM 问题通常被建模为一个关于 后验概率的估计问题,其数学表达如式(2-5)^[50]:

$$P(\mathbf{x}_{1:t}, \mathbf{m} \mid \mathbf{z}_{0:t}, \mathbf{u}_{0:t}, \mathbf{x}_{0})$$
(2-5)

其中, **x**_{1:t} 表示从起始时刻到当前时刻 *t* 的平台运动轨迹, **m** 表示静态环境地图, 因此不随时间变化。**z**_{0:t} 表示传感器从时刻 0 到 *t* 获取的观测信息, **u**_{0:t} 为对应时刻的控制输入, **x**₀ 为已知的初始状态。

借助 Rao-Blackwellized 定理,在基于滤波的 SLAM 方法中,可分解将上述后验 概率形式化为如式(2-6)^[50]:

$$P(\mathbf{x}_{1:t}, \mathbf{m} \mid \mathbf{z}_{0:t}, \mathbf{u}_{0:t}, \mathbf{x}_{0}) = P(\mathbf{m} \mid \mathbf{z}_{0:t}, \mathbf{x}_{0:t}, \mathbf{z}_{0:t}) \cdot P(\mathbf{x}_{1:t} \mid \mathbf{z}_{0:t}, \mathbf{u}_{0:t})$$
(2-6)

进一步考虑到地图的生成与控制输入之间不存在直接相关性,可将其简化为 式(2-7)^[50]:

$$P(\mathbf{x}_{1:t}, \mathbf{m} \mid \mathbf{z}_{0:t}, \mathbf{u}_{0:t}) = P(\mathbf{m} \mid \mathbf{z}_{0:t}, \mathbf{x}_{0:t}) \cdot P(\mathbf{x}_{1:t} \mid \mathbf{z}_{0:t}, \mathbf{u}_{0:t})$$
(2-7)

上述分解策略有效地将 SLAM 问题分为两个子问题: 首先估计系统的轨迹 x_{1:t}, 随后在该轨迹已知的前提下恢复环境地图 m。其中 P(m | z_{0:t}, x_{0:t}) 对应于已知路径下的建图问题。针对不同的地图表示方法(如地标图、栅格图等), 可采用不同的建图 算法来计算该后验概率。

为在滤波框架中递归地估计平台轨迹的后验概率,可将其进一步分解为式(2-8)^[50]所示:

$$P(\mathbf{x}_{1:t} \mid \mathbf{z}_{1:t}, \mathbf{u}_{1:t}) = P(\mathbf{x}_t \mid \mathbf{x}_{1:t-1}, \mathbf{z}_{1:t}, \mathbf{u}_{1:t}) \cdot P(\mathbf{x}_{1:t-1} \mid \mathbf{z}_{1:t}, \mathbf{u}_{1:t})$$
(2-8)

依据贝叶斯定理,可将上式中的条件概率展开为以下式(2-9)^[50]形式:

$$P(\mathbf{x}_t \mid \mathbf{x}_{1:t-1}, \mathbf{z}_{1:t}, \mathbf{u}_{1:t}) = \frac{P(\mathbf{z}_t \mid \mathbf{x}_t, \mathbf{m}) \cdot P(\mathbf{x}_t \mid \mathbf{x}_{t-1}, \mathbf{u}_t) \cdot P(\mathbf{x}_{1:t-1} \mid \mathbf{z}_{1:t-1}, \mathbf{u}_{1:t-1})}{P(\mathbf{z}_t \mid \mathbf{z}_{1:t-1}, \mathbf{u}_{1:t})} \quad (2-9)$$

在此基础上,依据马尔可夫假设——即当前状态仅依赖于上一个状态,可将上述 表达式进一步简化为式(2-10)^[50]:

$$P(\mathbf{x}_{1:t} \mid \mathbf{z}_{1:t}, \mathbf{u}_{1:t}) = \eta \cdot P(\mathbf{z}_t \mid \mathbf{x}_t, \mathbf{m}) \cdot P(\mathbf{x}_t \mid \mathbf{x}_{t-1}, \mathbf{u}_t) \cdot P(\mathbf{x}_{1:t-1} \mid \mathbf{z}_{1:t-1}, \mathbf{u}_{1:t-1}) \quad (2-10)$$

其中η为归一化因子。最终数学形式如(2-11)^[50]所示:

$$P(\mathbf{x}_{t} \mid \mathbf{x}_{1:t-1}) = P(\mathbf{x}_{t} \mid \mathbf{x}_{t-1})$$
(2-11)

以上是 SLAM 问题在概率图模型中的基本建模方式,以及在基于滤波的估计方 法中,如何将包含历史控制与观测信息的联合后验估计任务转化为一个递归求解问 题。接下来将详细介绍系统运动模型,并说明后验概率的计算方法。

对于系统的运动模型,平台运动的概率模型用于表达在已知当前位置与给定控制输入条件下,下一时刻位姿的概率分布,具体如公式(2–12)所示。通常情况下,物体在二维空间中的完整运动需由三个自由度参数刻画。然而,由于运动结构的物理限制,许多平台(如差速驱动或阿克曼转向)可以通过两个控制变量,即线速度*v*和角速度*w*,来描述其在平面内的运动行为,其中控制量记作**u** = [*v*,*w*]^T。

$$P(\mathbf{x}_t \mid \mathbf{x}_{t-1}, \mathbf{u}_t - 1) \tag{2-12}$$

以差速驱动平台为例,其转向动作由左右轮的速度差实现。平台在任意时刻 t 以 半径 $r = \frac{v}{w}$ 的圆弧轨迹进行运动。在理想无噪声情况下,可通过几何推导得出 t+1 时 刻的位姿。然而在实际运行中,无论控制指令 u 来源于控制器或是传感器(如 IMU) 测量,都不可避免地受到噪声干扰。

为描述这类不确定性,首先假设平动与转动速度受到均值为零的高斯噪声影响。 尽管这种建模涵盖了两个控制维度,但由于实际路径可能偏离理想圆弧,仅考虑两个 速度噪声在某些情形下会导致后验概率趋近于零。为解决该问题,需引入对平台最终 朝向的随机偏移,同样假设其服从高斯分布。于是,线速度、角速度及末端偏航角的 噪声可统一建模为零均值高斯分布,如下式(2-13)所示。

$$\begin{cases} n_{\nu} \sim \mathcal{N}(0, \sigma_{\nu}^{2}) \\ n_{w} \sim \mathcal{N}(0, \sigma_{w}^{2}) \\ n_{\gamma} \sim \mathcal{N}(0, \sigma_{\gamma}^{2}) \end{cases}$$
(2-13)

引入上述噪声后,含噪的控制输入表示为(2-14):

$$\hat{v} = v + \delta_{v}$$

$$\hat{w} = w + \delta_{w}$$

$$\hat{\gamma} = \delta_{\gamma}$$
(2-14)

在考虑控制噪声的前提下,可通过几何推导得出 t + 1 时刻平台状态 $\mathbf{x}t + 1 = [xt + 1, y_{t+1}, \alpha_{t+1}]^{\mathsf{T}}$ 的估计值,其运动模型表达式如式 (2-15):

$$\begin{bmatrix} x_{t+1} \\ y_{t+1} \\ \alpha_{t+1} \end{bmatrix} = \begin{bmatrix} x_t \\ y_t \\ \alpha_t \end{bmatrix} + \begin{bmatrix} -\frac{\hat{v}}{\hat{w}}\sin(\alpha_t) - \sin(\alpha_t + \hat{w}\Delta t) \\ \frac{\hat{v}}{\hat{w}}\cos(\alpha_t) - \cos(\alpha_t + \hat{w}\Delta t) \\ \hat{w}\Delta t + n_{\gamma} \end{bmatrix}$$
(2-15)

式中, *Δt* 表示控制持续时间, *î* 和 *ŵ* 为含噪声的平动与转动速度, *î* 为朝向角扰 动项。该模型综合考虑了噪声对平台位姿预测结果的影响,使其更贴近现实运行情况。

在已知当前平台状态及控制输入的条件下,可依据运动模型对下一时刻的位姿进行采样估计。接下来将说明如何在给定平台当前位姿与控制变量的前提下,计算平台在下一时刻位于某一特定位姿 x'的概率值,如公式(2-16)所示。

$$\mathbf{X}' = [x', y', \alpha']^{\top} \tag{2-16}$$

假设平台在单位时间内沿圆弧轨迹移动,则其运动路径与当前位置 \mathbf{x}_t 和目标位 姿 \mathbf{x}' 存在明确的几何联系。首先,平台在 \mathbf{x}_t 处的切线方向应与其朝向 α_t 一致;其 次,平台当前位置与目标位置的连线所对应的中垂线穿过圆弧轨迹的圆心。基于上述 几何关系,可推导圆心坐标 $\mathbf{c} = [x_c, y_c]^{\mathsf{T}}$,如式 (2–17)所示:

$$\begin{bmatrix} x_c \\ y_c \end{bmatrix} = \begin{bmatrix} \frac{x+x'}{2} + \frac{1}{2} \frac{(x-x')\cos\alpha + (y-y')\sin\alpha}{(y-y')\cos\alpha - (x-x')\sin\alpha} (y-y') \\ \frac{y+y'}{2} + \frac{1}{2} \frac{(x-x')\cos\alpha + (y-y')\sin\alpha}{(y-y')\cos\alpha - (x-x')\sin\alpha} (x-x') \end{bmatrix}$$
(2-17)

圆弧半径 r 可由式(2-18)当前位姿和圆心之间的距离求得:

$$r = \sqrt{(x_t - x_c)^2 + (y_t - y_c)^2}$$
(2-18)

平台在该圆轨迹上运行所经历的角度变化 Δα 可通过如式 (2-19) 计算:

$$\Delta \alpha = \arctan \frac{y' - y_c}{x' - x_c} - \arctan \frac{y_t - y_c}{x_t - x_c}, \ \Delta \alpha \in [-\pi, \pi]$$
(2-19)

由此,平台在此段运动中行驶的弧长如式 (2-20):

$$\Delta d = r \cdot \Delta \alpha \tag{2-20}$$

设定运动时间为 Δt ,则估计的线速度 \hat{v} 和角速度 \hat{w} 分别如式(2-21)表示:

$$\hat{v} = \frac{\Delta d}{\Delta t}$$

$$\hat{w} = \frac{\Delta \alpha}{\Delta t}$$
(2-21)

此外,为考虑角度偏差的影响,引入额外的偏航角误差 $\hat{\gamma}$,如式(2-22)所示:

$$\hat{\gamma} = \alpha' - \alpha_t - \hat{w} \cdot \varDelta t \tag{2-22}$$

在假设控制变量的误差项满足高斯分布的前提下,最终可计算平台从 **x**_t 经控制 **u**_t 后达到 **x**' 的概率,如下式 (2-23) 所示:

$$P(\mathbf{x}_t \mid \mathbf{x}_{t-1}, \mathbf{u}_{t-1}) = \varepsilon(\hat{v} - v) \cdot \varepsilon(\hat{w} - w) \cdot \varepsilon(\hat{\gamma})$$
(2-23)

其中 ε(·) 表示高斯概率密度函数。综上所述,本节详细介绍了差分驱动平台的 运动模型推导过程,包括如何根据控制变量与噪声模型对目标位姿进行推测,以及如 何利用几何关系和统计模型计算位姿转移的后验概率。

2.2 传感器测量原理

基于毫米波雷达多传感器融合 SLAM 系统需要获取多种传感器的测量数据,并 将其与毫米波雷达测量的数据进行融合,构建统一的地图数据和位姿坐标系,为此, 需要理解传感器的测量原理。本小节介绍毫米波雷达、激光雷达两种传感器的测量原 理。

2.2.1 毫米波雷达测量原理

毫米波雷达是一种工作在波长范围为1至10毫米之间的高频雷达系统,其频率 覆盖30至300GHz的电磁波段,恰好处于传统厘米波和光波之间。由于其高频特性, 毫米波雷达具备良好的穿透能力,能够有效穿越雨、雾、尘埃等复杂气象环境,同时 具有极强的抗电磁干扰能力。因此,该类传感器在恶劣天气和全天候条件下仍能保持 稳定的工作性能,被广泛应用于智能驾驶、安防监控和航空航天等多个技术领域。

在测速原理方面,毫米波雷达主要依赖多普勒频移效应来获取运动目标的速度 信息。多普勒效应是指当波源与接收器之间存在相对运动时,接收器所接收到的波频 率会因距离变化而发生偏移:当目标向雷达靠近时,回波信号频率升高;反之,当目 标远离雷达时,回波频率则降低。这一原理为雷达系统提供了精确的速度测量能力, 特别适用于高速移动目标的感知与跟踪。

在信号调制方面,毫米波雷达普遍采用调频连续波 (Frequency Modulated Continuous Wave, FMCW)技术。该调制方式通过在每一个调制周期内线性地改变发射信号 频率,从而实现目标距离和速度的同时估计。在 FMCW 调制中,发射信号的频率从 一个起始频点 *f_c* 以恒定斜率 S 增加至调制带宽 B,整个调频过程持续时间为一个周 期 *T_c*。

在该模型下,毫米波雷达发射信号的时域表达与其相位如式(2-24)所示:

$$\mathbf{S}_{\text{transmit}}(t) = A \cos\left(2\pi \left(f_c t + \frac{St^2}{2} + \Phi_0\right)\right), \quad t \in [0, T_c]$$

$$\boldsymbol{\Theta}_{\text{transmit}}(t) = 2\pi \left(f_c t + \frac{St^2}{2} + \Phi_0\right)$$
(2-24)

雷达系统首先利用频率合成器产生 FMCW 信号,并通过发射天线将其发出。当 信号遇到目标物体后,会产生部分回波,该回波由接收天线捕获。随后,发射信号与 接收回波在混频器中进行频率混合,生成中频信号,供后续信号处理模块使用。

在线性调频的时间窗内,发射信号与回波信号在时域的频率差保持恒定,混频输出的中频信号频率 *f*_{IF} 亦保持不变。

回波信号的表达式如式(2-25),其中 *τ* 表示信号往返时间延迟, *K* 为能量衰减 因子:

$$\mathbf{S}_{\text{receive}}(t) = KA \cos\left(2\pi \left(f_c(t-\tau) + \frac{S(t-\tau)^2}{2} + \Phi_0\right)\right), \quad t \in [0, T_c]$$

$$\boldsymbol{\Theta}_{\text{receive}}(t) = 2\pi \left(f_c(t-\tau) + \frac{S(t-\tau)^2}{2} + \Phi_0\right)$$
(2-25)

将发射与接收信号相乘后,可得到差频信号的相位公式 (2-26):

$$\boldsymbol{\Theta}_{\text{beat}}(t) = 2\pi f_c \tau + 2\pi S \tau t - \pi S \tau^2 \tag{2-26}$$

从上述关系可得中频信号的频率 *f*_{IF} 与目标距离之间的映射如式 (2-27):

$$f_{IF} = S\tau = \frac{2SR}{c} = \frac{2BR}{cT_c}$$
(2-27)

因此, 雷达系统可依据回波频率 *f*_{IF} 来推算目标与雷达之间的距离 *R*, 计算公式 为式 (2-28):

$$R = \frac{cT_c f_{IF}}{2B} \tag{2-28}$$

2.2.2 激光雷达测量原理

激光雷达是一种具备高精度空间感知能力的主动传感设备,其核心技术基于激 光发射与距离探测。该设备通过向目标物体发射激光脉冲,并利用接收光信号的往返 时间及光速,计算出目标与自身之间的距离,从而实现对三维环境中物体位置与结构 的精准建模。此外,通过分析目标反射的激光信号在强度、频率、相位以及光谱幅值 等方面的特征,激光雷达能够对物体的三维形态进行精细还原。凭借其在边界轮廓检 测、距离评估、角度计算以及障碍物识别等方面的优异性能,该传感技术已逐渐成为 L4级及以上自动驾驶系统中不可或缺的核心部件之一。

在实际应用中,激光雷达通过扫描环境并实时记录点云信息来构建周围空间的 数字模型。其工作方式包括周期性地向周围空间发射高频激光束,并接收其被物体表 面反射回的信号。通过测定光脉冲的往返时间并乘以光速,可以精确计算出每个被测 物体与传感器之间的距离。该过程在不断重复中形成高密度的三维点云数据,为环境 建图提供关键基础。

相较于依赖光照条件的被动视觉传感器,激光雷达作为主动探测技术,具有出色的抗光干扰能力,即便在低照度或夜间条件下也能稳定运行。进一步而言,通过从不同观察位置获取的点云数据之间的空间对应关系,系统能够估算同一物体在多个观测点下的相对姿态差异。基于这种空间几何变换关系,便可推导出传感器在不同时间 点的位置信息,从而完成车辆在场景中的运动轨迹恢复。

激光雷达通过匹配点云特征来估计运动状态。设激光雷达在两帧之间的初始位 姿变换为 *T_{k,k+1}*,表示从时刻 *t_k* 到 *t_{k+1}* 的运动变换,如式(2-29)该变换在三维空间 中具有六个自由度,包括三个平移分量和三个旋转分量:

$$T_{k,k+1} = [t_x, t_y, t_z, \theta_x, \theta_y, \theta_z]$$
(2-29)

设第 *k* 帧中第 *i* 个点的位姿为 *X*_{*k*,*i*},其采样时间为 *t*_{*a*},相应的位姿变换记为 *T*_{*k*,*a*}, 表示该激光点在 [*t*_{*k*},*t*_{*a*}] 区间内的变换。*T*_{*k*,*a*} 可由 *T*_{*k*,*k*+1} 通过线性插值得到:

$$T_{k,a} = \frac{t_a - t_k}{t_{k+1} - t_k} T_{k,k+1}$$
(2-30)

利用 *T_{k,a}* 可对每帧激光点云进行运动畸变补偿。将第 *i* 个点投影至时刻 *t_k* 后的 坐标表示为 *X_{k,l}*:

$$\bar{X}_{k,l} = R_{k,a}(X_{k,i} - t_{k,a}) \tag{2-31}$$

其中, *R_{k,a}* 和 *t_{k,a}* 分别是从 *T_{k,a}* 中提取的旋转矩阵和平移向量。 距离误差优化公式可简化为点到线与点到面距离误差项:

$$f_E(X_{k,i}, T_{k,k+1}) = d_E, X_{k,i} \in \mathbb{E}$$
(2-32)

$$f_H(X_{k,i}, T_{k,k+1}) = d_H, X_{k,i} \in \mathbb{H}$$
(2-33)

通过 Levenberg-Marquardt 非线性优化算法可求解变换参数:

$$T_{k+1} = T_{k+1} + \Delta T_{k+1} = T_{k+1} - (J^T J + \lambda D^T D)(-Jd)$$
(2-34)

其中, λ 为系数因子, μ 表示半径, D 是系数矩阵, $d = [d_E, d_H]^T$ 是距离。

2.3 多传感器融合原理

多传感器融合技术是指利用计算机系统对来自多个传感器或不同信息源的数据 进行自动解析与综合,以实现对环境的高效感知和辅助决策支持。该方法通过将异构 感知数据在一定准则下进行整合,从而构建更为精确和一致的环境模型,提升系统 在动态场景中的感知鲁棒性与决策可靠性。按照信息处理的不同层级,传统的传感 器融合策略可划分为三种基本形式:数据层融合、特征层融合与决策层融合^[51]。如 图 2–1 所示,这三种融合方式分别处理感知信息的不同阶段,以满足多样化的系统需 求。

在数据层融合过程中,不同传感器对同一目标对象进行独立观测,所获取的原始 信息在未经加工的状态下直接参与融合处理。该融合策略的显著优势在于可最大限 度保留传感器数据的完整性,从而提升环境感知的精度与系统整体的鲁棒性。此外, 由于融合操作作用于最底层数据,其信息冗余程度较低,有助于增强融合结果的可靠 性。然而,此类方法需同时处理大规模原始数据,对系统的计算能力与实时性能提出



图 2-1 多传感器融合方式

了较高要求,因此在实际应用中面临一定的计算资源压力^[52]。特征级融合则属于中 层次的融合方法,其基本流程是先从每个传感器获取的数据中提取出有意义的特征, 再将这些特征向量进行合并和融合,通过进一步的模式识别和处理来得到目标的更 高层次信息^[53]。相对于数据级融合,特征级融合在计算复杂度与信息保留之间取得 了一定的平衡,既能有效减少数据量,又能保留重要的目标信息。决策级融合则是在 最高层次上进行的,该层次首先对来自各传感器的数据进行特征提取和目标识别,随 后对各个传感器所做的识别结果进行综合判定与逻辑推理,最终生成最终的决策^[54]。 决策级融合虽然计算量相对较小,且处理效率较高,但由于放弃了部分原始数据,可 能导致融合后的精度较低。

各层次的融合方法在多传感器融合系统中都有其独特的优势和适用场景。数据 级融合虽然可以提供全面的信息,但由于其高计算量,通常需要较强的计算支持。特 征级融合则在保留数据的关键信息的同时,通过降低计算量来优化系统的性能。决策 级融合则更侧重于快速、有效的决策过程,但可能在精度上有所妥协。

在实际的多传感器融合方法中,基于贝叶斯估计理论的算法得到了广泛应用。卡 尔曼滤波作为一种经典的最优状态估计算法,具有理论严谨、计算效率较高的特点。 然而,卡尔曼滤波的适用性仅限于线性系统,这使得它在实际应用中遇到了较大的限 制,特别是在多源导航系统中,系统往往表现出非线性特征。为了克服这一局限性, 扩展卡尔曼滤波和无迹卡尔曼滤波等非线性滤波方法应运而生。这些方法能够处理

更复杂的非线性系统,增强了多传感器融合在实际场景中的应用效果。除了传统的卡尔曼滤波方法外,近年来还出现了基于人工智能的融合方法,如模糊逻辑推理和人工神经网络等,这些方法通过智能化的推理和学习机制进一步提升了多传感器融合的准确性和鲁棒性。

卡尔曼滤波作为数据层融合中的一种典型算法,其基本思想在于基于系统的先 验状态进行预测,并融合实时观测结果,通过加权机制实现对当前状态的最优估计。 整个滤波过程可划分为两个关键步骤:预测与校正。在预测环节,系统利用上一时刻 的状态信息推断当前状态,并计算相应的预测误差协方差;随后,在校正阶段,将预 测值与实际观测值进行比对,依据卡尔曼增益对估计结果进行修正,从而获得更为精 确的状态输出。该方法在抑制噪声干扰、提高估计精度方面表现突出,特别适用于线 性动态系统中的多源感知信息融合任务。

k时刻的系统状态方程和观测方程为分别如式(2-35)、式(2-36)所示:

$$\mathbf{x}_k = \mathbf{A}\mathbf{x}_{k-1} + \mathbf{B}\mathbf{u}_k + \mathbf{w}_k \tag{2-35}$$

$$\mathbf{z}_k = \mathbf{H}\mathbf{x}_k + \mathbf{v}_k \tag{2-36}$$

其中: - \mathbf{x}_k : k 时刻系统状态向量 - A: 状态转移矩阵 - B: 控制输入矩阵 - \mathbf{u}_k : 控制量 - \mathbf{w}_k : 系统过程噪声 - \mathbf{z}_k : 观测向量 - H: 测量矩阵 - \mathbf{v}_k : 观测噪声

预测方程如式(2-37)所示:

$$\hat{\mathbf{x}}_{k}^{-} = \mathbf{A}\hat{\mathbf{x}}_{k-1} + \mathbf{B}\mathbf{u}_{k} \tag{2-37}$$

预测协方差如式 (2-38):

$$\mathbf{P}_{k}^{-} = \mathbf{A}\mathbf{P}_{k-1}\mathbf{A}^{T} + \mathbf{Q}$$
(2-38)

卡尔曼增益计算公式如式 (2-39):

$$\mathbf{K}_{k} = \mathbf{P}_{k}^{-} \mathbf{H}^{T} (\mathbf{H} \mathbf{P}_{k}^{-} \mathbf{H}^{T} + \mathbf{R})^{-1}$$
(2-39)

状态更新方程如式(2-40)所示:

$$\hat{\mathbf{x}}_k = \hat{\mathbf{x}}_k^- + \mathbf{K}_k (\mathbf{z}_k - \mathbf{H}\hat{\mathbf{x}}_k^-)$$
(2-40)

协方差更新如式(2-41)所示:

$$\mathbf{P}_k = (\mathbf{I} - \mathbf{K}_k \mathbf{H}) \mathbf{P}_k^- \tag{2-41}$$

扩展卡尔曼滤波算法是一种专门用于非线性系统状态估计的方法,其核心思想 在于利用一阶泰勒级数对系统的非线性模型进行线性近似,从而将问题转化为可由 传统卡尔曼滤波方法处理的形式。

非线性状态方程和观测方程如式 (2-42)、式 (2-43):

$$\mathbf{x}_k = f(\mathbf{x}_{k-1}, \mathbf{u}_k) + \mathbf{w}_k \tag{2-42}$$

$$\mathbf{z}_k = h(\mathbf{x}_k) + \mathbf{v}_k \tag{2-43}$$

预测方程如式(2-44)、式(2-45)所示:

$$\hat{\mathbf{x}}_{k}^{-} = f(\hat{\mathbf{x}}_{k-1}, \mathbf{u}_{k}) \tag{2-44}$$

$$\mathbf{P}_{k}^{-} = \mathbf{F}_{k-1}\mathbf{P}_{k-1}\mathbf{F}_{k-1}^{T} + \mathbf{Q}$$
(2-45)

其中 \mathbf{F}_{k-1} 是对状态转移函数关于状态的偏导(雅可比矩阵)。 卡尔曼增益如式(2-46)可得:

$$\mathbf{K}_{k} = \mathbf{P}_{k}^{-} \mathbf{H}_{k}^{T} (\mathbf{H}_{k} \mathbf{P}_{k}^{-} \mathbf{H}_{k}^{T} + \mathbf{R})^{-1}$$
(2-46)

状态更新方程如式(2-47)所示:

$$\hat{\mathbf{x}}_k = \hat{\mathbf{x}}_k^- + \mathbf{K}_k (\mathbf{z}_k - h(\hat{\mathbf{x}}_k^-))$$
(2-47)

协方差更新如式 (2-48):

$$\mathbf{P}_k = (\mathbf{I} - \mathbf{K}_k \mathbf{H}_k) \mathbf{P}_k^- \tag{2-48}$$

其中, \mathbf{H}_k 是观测函数 h 对状态向量的偏导, 亦为雅可比矩阵。

扩展卡尔曼滤波算法在保持卡尔曼滤波高斯递推特性的同时,引入了对非线性 函数的有效处理机制,因而被广泛应用于非线性多传感器信息融合场景中,成为处理 此类系统问题的重要工具之一。

第三章 基于信息融合的建图系统设计与算法研究

3.1 激光雷达 SLAM

3.1.1 2D SLAM

激光 SLAM 分为 2D SLAM 和 3D SLAM, 经典的 2D SLAM 算法有 Gmapping, Hector, Karto 和 Cartographer 等,对比如表所示3–1。

算法	优点	缺点	适用场景
Gmapping	计算资源消耗较低,具有 较快的构图速度	在大规模环境中计算量 急剧上升,且对里程计精 度依赖较高,缺乏闭环检 测能力	适用于小尺度或环境特 征稀疏的场景
Hector	无需依赖里程计信息即 可进行构图,适用于动态 平台	对激光雷达的扫描频率 与精度要求较高	可实现非平整地形的地 图构建
Karto	借助最小二乘法优化建 图过程,提高地图精度	算法运算时间较长,构图 效率相对较低	适用于特征丰富或大尺 度的环境
Cartographer	具备闭环检测机制,可有 效修正累计误差	内存和处理器资源占用 较高,整体计算复杂度大	适用于多种应用场景,具 有较强的泛化能力

表 3-1 主流 2D SLAM 算法优劣分析

其中, Cartographer 是一种由 Google 开发的基于图优化思想的 SLAM 算法,其整体架构可划分为前端与后端两个模块。在前端部分,系统通过连续接收的激光雷达扫描数据构建局部子地图,并利用数据与已有地图之间的匹配关系,不断将新获取的数据纳入以更新子地图内容。后端模块则负责执行闭环检测机制,并通过优化历史扫描帧与子地图之间的约束关系,进一步提升闭环检测的准确性与全局地图的一致性^[47]。具体算法过程如表3-2所示。

在 ROS 平台中, Stage 是一种集成了多种虚拟传感器的仿真工具,能够用于模拟和测试机器人系统的运行情况。本文基于 Stage 环境,对 Cartographer 算法进行了仿真 建图实验。首先,需完成仿真环境的初始化配置。用户需编辑终端配置文件 /.bashrc, 修改其中的 ROS_MASTER_URI 以匹配当前主机设置,并将仿真平台的机器人类型 参数 BASE_TYPE 指定为 "NanoCar"。完成修改后,保存文件并执行 source /.bashrc

表 3-2 Cartographer 算法流程

Algorithm: Cartographer

Input: SD - sensor data, I - initial_pose **Output:** M - map, T - estimating trajectory

1: BEGIN

- 2: Initialize M, S, T = [I];
- 3: Start_sensors();
- 4: While true:
- 5: SD = Get_sensor_data();
- 6: S = Preprocess_data(SD);
- 7: $M, T = Local_slam(S, M, T);$
- 8: $M, T = Global_slam(M, T);$
- 9: Publish_results(M, T);
- 10: **END**



图 3-1 stage_mapping

命令以使配置生效。

随后,对系统的 launch 文件进行相应调整,将 <param name="/use_sim_time" 参数设为 true 以启用仿真时间同步;若该参数设为 false,则表示系统将以真实机器人的时间戳为基准运行。通过配置完成的 launch 文件启动 Stage 仿真系统后,仿真界面显示虚拟机器人在仿真环境中的建图与运动过程。

使用配置完成的 launch 文件启动 Cartographer 算法后,系统即进入建图流程,同时激活可视化工具 rviz 以展示实时建图过程,为了实现对仿真机器人的运动控制,运行命令 rosrun teleop_twist_keyboard teleop_twist_keyboard.py 以启动键盘遥控节点。通过该节点,用户可利用键盘指令操控机器人在仿真环境中移动,从而实现对场景的全面扫描,并逐步构建完整的二维地图,如图3-1所展示。

仿真实验结果表明, Cartographer 算法在地图构建的准确性与成功率方面表现出

较好性能。其通过引入回环检测机制有效修正了累计误差,并对局部子地图进行了 图优化处理,从而显著提升了整体的定位与建图精度。然而,该算法生成的地图仅限 于二维平面,无法完整反映三维空间结构。此外,由于所使用的激光雷达为单线扫描 设备,其波束范围有限,导致在室外开阔区域中存在感知盲区,环境探索能力受限。 因此,若需实现对三维空间更为全面的感知与重建,仍需借助三维激光 SLAM 技术 构建稠密的三维点云地图,以满足复杂环境下的建图需求。

3.1.2 3D SLAM

当前常见的三维 SLAM 方法主要包括基于分割的 SegMatch 与 SegMap 算法,以 及依赖关键点的 LOAM 系列方法,如 LOAM、A-LOAM 与 LeGO-LOAM 等。其中, SegMatch 算法的处理流程可划分为四个关键步骤:点云的分割、特征信息提取、分 割片段的匹配以及几何一致性验证。在此基础上,SegMap 算法进一步扩展为五个模 块,依次为点云分割、特征编码、片段匹配、几何验证和语义信息提取与场景重建。 这两种方法均属于以空间分割为核心的 3D 点云识别策略。

相较之下,LOAM 及其衍生版本则采用关键点驱动的方式进行三维场景理解。标准 LOAM 算法框架由四部分构成:激光特征点提取、雷达里程计估计、建图模块和 位姿融合^[55]。其中,特征提取和里程计计算被视为整个算法流程的核心所在。

LeGo-LOAM 算法是一种针对激光雷达里程计和地图构建的轻量化方案,并特别 针对地面环境进行了优化^[56]。相较于传统的 LOAM 算法, LeGo-LOAM 在提高计算效 率和地面优化方面进行了显著改进。该算法主要由四个模块构成,分别是点云分割、 特征提取、雷达里程计估计以及地图构建。LeGo-LOAM 的整体工作流程示于表3-3。

本研究利用 Ubuntu 18.04 操作系统和 ROS Melodic 版本,结合 Ceres Solver 2.0.0 和 PCL 1.8.1 库,开展了基于 LeGO-SLAM 算法的建图仿真过程。首先,系统在 Ubuntu 18.04 环境下安装配置了所需的软件工具包,并使用 ROS Melodic 进行数据处理与通信。在此基础上,Ceres Solver 2.0.0 被应用于优化算法中的非线性最小二乘问题,而 PCL 1.8.1 则用于处理点云数据和实现特征提取。通过上述工具的协同作用,仿真系统成功实现了高效的地图构建与优化。最终,建图结果如图3-2所示,展示了在所设置环境中的精确地图构建效果。

表 3-3 LeGo-LOAM Algorithm Flow

Algorithm: LeGo-LOAM

Input: L_{low} - low-frequency lidar data, L_{high} - high-frequency lidar data, I - initial_pose **Output:** M - map, T - estimated trajectory

- 1: BEGIN
- 2: Initialize M, T = [I];
- 3: While true:
- 4: $L_{low}, L_{high} = \text{Get_sensor_data}();$
- 5: Extract_features(L_{low}, L_{high});
- 6: For each scan:
- 7: $F_{low} = Extract_low_features(L_{low});$
- 8: $F_{high} = Extract_high_features(L_{high});$
- 9: $P_{low} = Scan_matching(F_{low}, T);$
- 10: $P_{high} = Scan_matching(F_{high}, T);$
- 11: Update_pose(P_{low}, P_{high});
- 12: $T = T + P_{high};$
- 13: $M = Map_update(M, F_{low}, F_{high});$
- 14: Optimize_global(M, T);
- 15: Publish_results(M, T);
- 16: **END**



图 3-2 LeGo_mapping



图 3-3 时间同步流程

3.2 Lidar/Radar 融合算法研究

3.2.1 时间同步

不同传感器具有不同的触发顺序和传输延迟,不同的触发顺序会导致不同传感器的数据在捕获时就存在时间偏移,叠加数据传输的延迟,会导致上位机在接收到数据后无法判断数据的捕获的具体时间,这在后续的处理中会转化为空间上的偏移进而影响算法精度。为此本研究采用硬同步与软同步相结合的方法,实现毫米波雷达和激光雷达的时间同步。首先,将 GNSS 设备接入毫米波雷达和激光雷达的触发器,定时发出脉冲信号,触发毫米波雷达与激光雷达的扫描动作,实现传感器的硬同步,从而消除了传感器间因触发顺序带来的初始时间偏移。然而,数据从传感器发出到上位机接收仍会因总线、网络、缓冲等传输路径产生不可忽略的时延,系统通过匹配相邻时间戳,寻找最接近的时间帧,从而实现数据的同步和时间对齐。该同步流程的详细步骤如图 3–3 所示。

3.2.2 激光雷达和毫米波雷达融合算法

Lidar/Radar 融合算法基于 ROS 分布式架构进行开发与部署。系统首先利用 EKF 模型,对激光雷达和毫米波雷达采集的原始数据进行融合初始化处理。该滤波器的设计结构包含两个核心阶段:预测阶段与观测阶段

扩展卡尔曼滤波算法的核心原理是通过对非线性系统模型进行近似线性化,从 而将其转化为适合卡尔曼滤波框架处理的形式。具体而言,EKF 首先利用泰勒级数 展开对非线性函数进行一阶线性化处理,将系统的非线性动态方程和观测方程近似 为线性模型。在此基础上,通过结合来自各类传感器的观测数据,采用迭代计算的方 式,对系统的状态进行递推估计。每一次迭代中,EKF 会根据当前的预测状态与实 际观测值之间的误差,逐步调整对系统状态的估计,从而实现精确的状态估计。该方 法的优势在于,尽管处理的是非线性系统,但通过线性化的技术,依然能在复杂的动 态环境中提供有效的状态估计,广泛应用于各类自动化控制与多传感器融合问题中。



图 3-4 激光雷达和毫米波雷达融合算法流程图

在实际应用中,激光雷达主要提供目标的相对距离信息,而毫米波雷达除距离测量 外,还可输出目标的径向速度信息。在接收到任一类型传感器数据时,系统即执行状 态初始化操作。具体而言,当系统首先接收到激光雷达信息时,将基于前一时刻的状 态估计执行预测,并根据当前观测结果对状态向量进行校正,从而获取该时刻的最优 估计结果。随后,当毫米波雷达数据到达时,系统以激光雷达所提供的先验状态为基 础进行新的状态预测,并结合毫米波雷达的观测量对状态进行更新修正,再次获得优 化后的状态估计值。

通过对激光雷达与毫米波雷达采集数据的时间序列持续融合处理,实现了传感 器间的协同配合,使系统能够在动态环境中实现连续、高精度的状态估计。整个融合 算法的执行流程如图 3-4 所示。

在完成 EKF 系统架构的搭建后,系统通过 ROS 节点订阅激光雷达和毫米波雷达的数据流。EKF 算法实时地处理并融合来自多个传感器的数据,以实现对不同传感器信息的综合利用和精确估计。在此过程中,需要对 LeGO-LOAM 算法的相关配置进行适配:由于该算法默认订阅的点云话题为 velodyne_points,其坐标系 frame_id 设置为 velodyne,因此必须修改话题名称与坐标系以适配融合后的数据。同时,调整输出点云的数据类型,将其更改为 pcl::PointXYZI point 格式,以匹配 LeGO-LOAM 处理流程的输入要求。

在 LeGO-LOAM 模块成功启动并完成初始化后,系统等待融合后的点云数据输

入。此时,扩展卡尔曼滤波节点开始输出经过融合处理后的激光与毫米波雷达数据, LeGO-LOAM 接收这些优化后的数据,并将其用于后续如建图、姿态估计等功能模块 的运行。

第四章 栅格地图的数据采集与数据处理

4.1 实地数据采集

4.1.1 数据采集车平台搭建

由于本文所研究的领域针对高级别自动驾驶车辆,该车辆需同时具备高精度位 姿估计、点云采集、图像采集、基于自动驾驶点云地图定位以及点云地图更新的功 能。4D 自主雷达感知系统的核心组成之一是面向自动驾驶车辆的数据采集与融合平 台。本研究采使用的智慧数据采集平台如图所示4-1,是由三电底盘搭载工控主机和 4D 毫米波雷达、摄像头、激光雷达以及 GNSS 等车载传感器,能够实现传感器数据 的事实落盘和可视化,并使用搭载的工控机实现建图和无人巡航等任务,实现无人化 的自动数据采集。

1) 雷达:数据采集平台配置了 8 台 Continental ARS548 型号的毫米波雷达,每 台雷达具有 120 度的视场范围,并提供双输出通道,分别用于目标信息(Objects)与 检测信息(Detection)的获取,以实现高精度的环境感知能力。

2)激光雷达:激光雷达模块选用了 Innovusion 的固态激光雷达作为主要的空间 感知传感器。该传感器具备 120 度的视场范围,能够在确保紧凑结构的同时提供高密 度、高精度的点云数据输出,满足复杂道路环境下的感知需求。

3) 摄像头: 在视觉感知模块中,系统选用 SenSing Intelligence 的 8 通道 800 万 像素 YUV 相机阵列,并通过 GMSL (Gigabit Multimedia Serial Link) 高速串行通信



图 4-1 智慧数据采集平台



图 4-2 传感器视场角示意图

板卡实现高精度硬件级时间同步。相机阵列包括 4 台 120° 广角相机与 4 台 60° 视角 相机,组合实现对车辆周边环境的 360° 全覆盖成像,有效支撑后续的多传感器信息 融合与环境建图任务。

4) GNSS: GNSS 模块支持多种卫星导航系统频段,包括北斗(BDS) B1/B2/B3, GPS L1/L2/L5,GLONASS L1/L2,Galileo E1/E5a/E5b,以及 QZSS L1/L2/L5。该模块 用于校准 ROS 系统时间,从而实现各类传感器间的时间同步,确保多源数据融合的 时效性与一致性。

可覆盖的测量数据覆盖范围如图4-2所示:

4.1.2 数据采集环境

针对融合数据集的构建,我们在上海交通大学闵行校区开展初步的数据采集工 作如图所示。采集区域将划分为若干关键驾驶区域,以系统性地开展数据采集实验, 确保覆盖多样化的驾驶场景和环境条件。如图 4-3 所示为地图数据采集的三个场景, 包括直道、弯道、空旷路段、有障碍物(如自行车和电动车等)的路段等多种场景。



图 4-4 数据车采集过程



(a) 电院内部二号楼通路





(c) 电院环路

图 4-3 数据采集场景

(b) 电院大草坪

数据采集的过程如图4-4所示,无人车可以通过人工遥控沿需要采集的路线行驶, 也可以通过设定的路线自动行驶并采集数据:

4.2 数据结构

因数据传输带宽存在一定限制,数据结构设计具有重要意义,为满足数据处理与标注信息的需求,必须对数据结构进行合理压缩。为支持多传感器数据融合和自动驾驶数据分析,本研究设计了一套通用的数据结构,用于存储来自雷达、激光雷达、GNSS、摄像头、IMU等传感器的原始数据,同时记录车辆状态和环境信息。该结构以 RawData 为顶层入口,采用面向对象思想组织数据,具有良好的扩展性和模块化特性。数据结构以 RawData 为核心节点,整合三类信息:传感器数据 (SensorData)、车辆运行状态 (VehiclePhaseData)、环境信息 (EnvironmentData)。其中 SensorData 为抽象基类,派生出五种类型的传感器子类,分别为雷达数据 (RadarData)、激光雷



图 4-5 数据结构示意图

达数据(LidarData)、相机数据(CameraData)和 GNSS 数据(GNSSData)与 IMU 数据(IMUData)。针对每类数据,设计了适用于在线预览与处理的数据格式,相较于对原始数据进行压缩,该方法在数据访问效率和处理性能方面更具优势。整体数据结构如图4-5所示。

4.2.1 RawData

结构体 RawData 在其设计中引入了字段 sensorType,用于标识当前传感器数据(sData)所对应的具体传感器类型,例如雷达(Radar)、激光雷达(Lidar)、摄像头(Camera)、GNSS 或惯性测量单元(IMU)。该字段通常基于枚举类型定义,用于明确传感器类别,从而在系统读取或解析 sData 时,可依据 sensorType 的取值动态选择相应的数据处理逻辑。此类设计在实现强类型约束的同时,增强了模块之间的解耦性,提高了系统的可扩展性与灵活性。

sData 字段是一个多态对象,基类为 SensorData,其派生类根据不同的传感器类型实现具体的数据结构。例如 RadarData 存储雷达张量数据,LidarData 存储点云帧,GNSSData 包含地理位置与导航真值等。借助面向对象的继承与多态机制,系统可以在不修改原有结构的前提下,便捷地添加新的传感器类型,提升了数据结构的可扩展性与维护性。

此外,每条 RawData 实例代表系统在某一时刻的整体感知快照(snapshot),即该时 刻车辆状态、外部环境及某一类传感器的数据。SensorData 中含有统一的 TimeStamp 字段,多个 RawData 实例在时间上可构成一系列连续的、带时间轴的数据帧,为后 续的多传感器数据配准、融合与时间序列分析提供了良好的基础。

4.2.2 SensorData

为统一管理和描述多源传感器采集的信息,设计了 SensorData 数据结构,用于 封装来自不同类型传感器的原始观测数据及其相关元信息。该结构体定义如下字段:

SensorDataID: 唯一标识每一条传感器数据的标识符,用于数据索引与追踪;

sensorType: 整型枚举值,用于标识传感器的类型(如雷达、激光雷达、视觉相机等),以支持异构数据的统一处理;

MetadataID:关联元数据的外键,用于指向该数据对应的设备参数(如设备型号、 采样频率、视场角等),实现数据的上下文关联;

time:时间戳信息,记录数据采集的准确时间,支持多源数据的时间同步与排序 处理。

而为满足多源异构传感器数据的处理需求,本文对各类传感器采集信息的数据 结构进行了统一建模。不同类型的传感器数据结构分别封装了与其物理特性相对应 的观测信息。

类型	字段	描述
RadarData	RadarRADTensor	雷达张量,含距离/速度等
LidarData	LidarPointcloudFrame	点云帧,三维坐标信息
GNSSData	GnssPos / GroundTruth	经纬度与速度三轴分量
IMUData	roll/pitch/yaw	角度变化与加速度信息

表 4-1 各类传感器数据结构字段说明

4.2.3 VehiclePhaseData

VehiclePhaseData 结构用于表示车辆在特定时间点的运行状态信息。其字段包括 车辆编号(vehicleID)、车辆类型(vehicleTypeID)、当前档位(gear)、行驶速度 (velocity)以及方向盘转角(steering)。该结构有助于刻画车辆的动态行为特征,支 持对驾驶意图、车辆控制状态及行为模式的分析,是理解整车运动学状态的重要基础 数据。

4.2.4 EnvironmentData

EnvironmentData 结构用于记录与感知数据采集时所处环境相关的上下文信息, 作为系统在处理多源传感器数据时的重要辅助变量。其主要字段包括:

dayOrNight: 昼夜状态标识,通常以布尔型或枚举值表示当前采集时段属于白天 或夜间。该变量对于感知系统中的图像亮度调整、夜间雷达回波增强及激光雷达点云 滤噪等模块具有重要影响,有助于提升模型在不同光照条件下的鲁棒性。

weather: 天气状态标识, 通常通过离散编码表示不同的天气类型(如晴、阴、雨、 雪、雾等)。传感器性能在不同气象条件下可能出现明显差异, 例如雨雪天气会降低 激光雷达有效距离, 雾霾会影响摄像头成像清晰度, 因此准确记录天气状态对于训练 具备泛化能力的感知模型尤为关键。

location:记录当前数据采集对应的地理区域或道路类型,如"城市道路"、"高速公路"、"隧道入口"、"山区弯道"等。不同地理环境对交通场景结构具有决定性作用,直接影响目标分布密度、遮挡概率和动态物体行为模式。通过引入地理语义,有助于在训练与测试阶段进行区域差异建模,从而提升感知算法的区域适应能力与泛化效果。

EnvironmentData 模块为感知系统提供了丰富的环境上下文信息,其合理嵌入可显著增强多源传感器融合算法的适应性,支持针对特定天气、光照或地形条件下的性能优化与策略调整。同时,该数据结构也为后续开展领域自适应学习(Domain Adaptation)、条件生成增强(Conditional Augmentation)等研究工作提供了关键基础。

4.3 数据处理流程

为了更好地处理数据流,将数据分为四类:(1)传感器数据(SensorData),即直接从数据采集平台的传感器收集的数据。这通常是从车辆传感器收集的未经处理的原始数据。(2)原始数据(RawData),即在数据中心进入处理阶段之前的数据,尚未进行诸如聚合或清洗等实质性处理。(3)源数据(OriginalData),即经过一定程度的预处理的数据,使其更易于使用,但仍保留了数据的原始特性。这些预处理包括格式化、简单的清洗和数据库标注,以便后续的分析和处理。(4)元数据(MetaData),即关于数据本身的信息,例如数据的来源、时间戳以及是否完成时间同步等细节。

对于这四类信息,数据平台后端数据处理模块中对原始数据(RawData)的处理,



图 4-6 数据处理流程示意图

如图4-6所示。原始数据处理模块主要负责接收并解析存储于 Data.h5 文件中的多源 传感器数据,包括毫米波雷达、激光雷达、摄像头、IMU、GNSS 以及车辆控制区域 网(CAN)信号等感知信息,同时结合存储于 Environment.json 的环境上下文信息和 VehicleMeta.json 中的车辆元数据信息。该模块通过后端解析框架对原始数据进行结 构化提取,提炼关键信息,为后续的数据融合、感知建模与行为分析提供基础支持。

鉴于毫米波雷达、激光雷达与摄像头数据具有高维度和大体量的特点,为优化系统内存与带宽使用,并便于嵌入面向特定数据特性的处理算法,系统对上述三类传感器数据采用模块化独立处理方式。而针对 IMU、GNSS 及 CAN 信号等数据量相对较小的传感器,统一由 calculateVPeriod 模块进行解析。该模块不仅负责上述数据的预处理,还承担多源数据时间戳校验与周期一致性验证等任务,以保证系统数据的时间同步精度。

在数据解析过程中,sqlLabel模块负责生成并维护数据标签体系,同时将处理完成的各类原始数据与相应标签进行绑定,并统一写入结构化的 SQL 数据库。系统为每条记录分配唯一地址 ID,实现原始数据与处理结果的一致性管理与高效索引。最终,所有解析与计算完成的数据,包括带有地址标识的雷达、激光雷达、摄像头原始帧及车辆运行周期信息,均以标准化格式存储至 MySQL 数据库中。该数据库不仅保障了数据管理的规范性和扩展性,也为后续的算法开发、数据查询与可视化分析提供了高效接口,实现了从多源感知数据解析到数据库管理的有机联动与高效集成。

第五章 建图实践与地图更新

5.1 三维稀疏栅格地图建图

首先使用自定义结构 SparseGrid3D (MyCell) 创建稀疏三维占据栅格地图并 初始化。每个栅格单元存储一个 MyCell 实例,仅包含一个属性 num,表示该格子的 占据概率,采用 log-odds 表示:

使用自定义结构 SparseGrid3D(MyCell)来构建一个稀疏三维占据栅格地图,其中 每个栅格单元由类 MyCell 表示,仅包含一个属性 num,用于记录该单元格的 log-odds 占据概率值。

地图尺寸由变量 grid_limit = [100, 200, 200] 决定,分别对应 Z、X、Y 三个方向。 再将地图的几何中心设为 heart = grid_limit / 2,用于将实际空间坐标映射到地图索引。

在 log-odds 表示法中,一个单元格的占用状态以对数形式存储,且为防止数据溢出,先规定 log-odds 取值范围为 (-50, 50):

$$\log_{odds} = \log\left(\frac{p}{1-p}\right)$$

其中 p 为该栅格被占用的概率。

地图尺寸由变量 grid_limit = [100, 200, 200] 指定,分别对应 Z、X、 Y 三个方向。地图中心定义为:

$$heart = \frac{grid_limit}{2}$$

初始化后,从HDF5文件中读取三组激光雷达数据lidar0、lidar1、lidar2,通过read_data_from_hdf5函数实现,每组数据包含三维空间坐标。

为模拟传感器的空间布局,对lidar1和lidar2进行绕 X 轴旋转 ±120°的坐标变换:

 $R_{x}(\theta) = \begin{bmatrix} 1 & 0 & 0 \\ 0 & \cos \theta & -\sin \theta \\ 0 & \sin \theta & \cos \theta \end{bmatrix}$

三组点云数据(measurements0, measurements1, measurements2)作为np.vstack函数的输入,输出结果为*M*×3数组,再采用二元贝叶斯滤波模型,通过binary_bayes_filter_update函数更新稀疏地图。接着将每个激光点(*x*, *y*, *z*)映射到地图索引:

$$(x_{idx}, y_{idx}, z_{idx}) = \lfloor (x, y, z) + heart \rfloor$$

再根据贝叶斯定理对占用状态进行概率更新:

$$\log_{odds} + = \log\left(\frac{p}{1-p}\right)$$

其中 p = 0.7 表示观测命中占用的概率。建图完成后,将 log-odds 转换为占用概率:

$$p = \frac{1}{1 + \exp(-\log_{\circ} \text{odds})}$$

最终输出保存在三维数组 outputdata 中,由于设备算力限制,选择把 output 投影到二维再经过可视化后,结果如图5-1所示,可以看到:通过与对栅格地图分析



图 5-1 栅格地图建图结果

和与数据采集的场景对比可以看出5-2:

5.2 运用 PCA 处理建图和更新

为系统地建模自动驾驶车辆传感器中存在的不确定性,本文提出一种融合主成 分分析 (PCA)、线性建模和误差修正机制的框架,具体流程如图 (5-2) 所示。该框



图 5-2 栅格地图图像分析

架旨在从大量多源传感器数据中提取影响不确定性的主导因素,并建立精确的不确定性表达模型,进而实现对环境、物理设备误差等因素的解耦与量化。

系统首先从车队采集多模态传感器数据,包括车辆动力学状态、GPS 位姿、激光 雷达点云(LiDAR)、控制器(MPC)信息以及发动机参数等。由于原始数据维度高、 特征冗余严重,直接建模存在很大困难,因此引入主成分分析(PCA)进行降维与特 征筛选,主要目的是在降低数据的复杂程度前提下,将高维数据转为低维数据,尽可 能减少数据中有效信息的损失,以达到通过较少的运算量处理传感器数据的目的。

Step	Operation		
Input	Data matrix $X \in \mathbb{R}^{n_{\text{samples}} \times n_{\text{features}}}$, number of principal components N		
1. Centering	Compute mean vector $\mu = \frac{1}{n} \sum_{i=1}^{n} X_{i,:}$		
	Center the data: $X_{\text{centered}} = X - \mu$		
2. Covariance Matrix	Calculate covariance matrix $C = \frac{1}{n-1} X_{\text{centered}}^{\top} X_{\text{centered}}$		
3. Eigen Decomposition	Compute eigenvalues λ and eigenvectors V of covariance matrix C		
4. Sorting and Selection	Sort eigenvalues λ in descending order and select the top N eigenvectors V_{selected}		
5. Data Projection	Project data: $X_{\text{PCA}} = X_{\text{centered}} \cdot V_{\text{selected}}$		
Output	Transformed data $X_{PCA} \in \mathbb{R}^{n_{samples} \times N}$		
	(Optional) Eigenvectors V_{selected} and eigenvalues λ		

PCA 过程将高维传感器数据压缩至主要的 2 或 3 个正交方向, 在保留最大方差



图 5-3 PCA 降维

信息的同时减少数据维度。投影后的主成分向量通常对应于影响系统不确定性的关键物理量,如轮胎气压、偏航角、安装偏差与传感器偏置等,如图所示5-3。

令特征向量 n_components=2,当环境发生改变时,可以看到 PCA 处理后通过回 环检测不断修正,逐渐发生改变更新结果如图5-4所示:



图 5-4 更新过程

各主成分的方差贡献率如图 5-5所示。由图可见,其中一个主成分的方差占比较 接近于零,表明其在表征原始数据中的信息量极为有限。因此,将数据降维至二维空 间时几乎不会造成有效信息的损失。

表 52	主成分口	占比分析

更新次数	主成分1占比	主成分 2	主成分 3	
1	0.7615	0.2365	0.0020	
3	0.7047	0.3893	0.0019	
7	0.6565	0.3418	0.0017	
10	0.6090	0.3893	0.0017	

随着回环检测次数的逐步增加,数据主成分的方差占比发生了显著变化,具体结果如表 5-2所示。可以观察到,第三主成分的方差占比呈持续下降趋势,其在整体数



图 5-5 主成分占比柱状图

据结构中的贡献逐渐减弱。这表明数据在该方向上的变化趋于收敛,呈现出更高的集 中性,反映出建图系统的运行状态日趋稳定。

第六章 总结与展望

6.1 总结

本文针对复杂环境下单一传感器在地图构建过程中存在的感知局限性与鲁棒性 不足等问题,综合考虑激光雷达与毫米波雷达在感知精度、环境适应性及数据互补性 等方面的优势,构建了一套基于多传感器融合的无人车地图学习系统。系统设计过程 中,本文采用主成分分析算法对激光雷达的信息进行滤波和,有效提高了环境感知的 准确性与鲁棒性,提高了并在 LeGo-LOAM 框架基础上实现了三维空间中的实时定 位与地图构建功能。相关研究与实验表明,该融合方法在多源信息处理与复杂场景下 的建图精度方面具有较为显著的性能。

具体而言,本文主要完成了以下几个方面的工作:

(1) 系统性学习了 SLAM 相关理论和算法,包括毫米波雷达和激光雷达的测量 原理,以及 SLAM 系统的基本结构、关键技术与常用算法,并对 SLAM 在无人驾驶 系统中的作用与挑战进行了系统分析;在 2D SLAM 部分,对主流的 Cartographer 算 法进行了建图仿真与性能评估;在 3DSLAM 方面,对 LeGo-LOAM 算法开展了实测 验证。

(2) 深入理解并分析了信息融合技术的理论基础,多传感器的在数据级、特征级、决策级的融合原理,包括传感器数据处理、状态估计理论及其在滤波框架中的应用,重点研究了卡尔曼滤波器和扩展卡尔曼滤波的适用性;对卡尔曼滤波和扩展卡尔曼滤波算法有了深入研究。

(3)参与搭建了搭载激光雷达、毫米波雷达、摄像头等多个传感器的智慧数据采 集平台,参与在上海交通大学校园内的数据采集实践,完成了传感器的数据处理工 作。

(4)提出并验证了一种基于 PCA 的信息融合建图算法,能够实现对动态环境的 稀疏建图与实时位姿估计,实验结果表明该方法在提升建图准确性与速度方面具有 良好表现。

6.2 展望

尽管本文提出的基于主成分分析 (PCA) 与迭代建模相结合的地图学习方法在多 传感器融合的 SLAM 地图构建中取得了初步成果,验证了其在特征降维与不确定性 建模方面的有效性,但仍存在以下几方面的局限性和改进空间:

首先,本文在融合方法选择上尚不充分。当前方法未对 PCA 与经典状态估计算法(如卡尔曼滤波 Kalman Filter, KF,扩展卡尔曼滤波 Extended Kalman Filter, EKF,以及粒子滤波 Particle Filter, PF)等多种信息融合策略在地图更新精度、鲁棒性及计算复杂度方面进行系统对比分析。因此,未来工作应在统一评估框架下,引入多种融合算法进行横向对比,明确 PCA 方法在高维状态空间处理中的优势与不足。

其次,本文目前仅使用了激光雷达(LiDAR)与惯性测量单元(IMU)传感器进行信息融合,未能充分利用平台上搭载的其他传感器数据,如摄像头、毫米波雷达等。

6.3 非技术性分析

本论文以车载无人系统中的地图构建为切入点,探讨了技术如何更好地服务于 公共出行和社会发展。在信息技术迅速演进的当下,无人驾驶的兴起不仅是科技进步 的体现,更折射出社会对于安全、高效、绿色出行方式的迫切需求。

在我国进入全面建设社会主义现代化国家新征程的大背景下,自动驾驶等智能 技术的发展契合了国家推动交通强国建设和绿色发展的战略需求。无人驾驶技术的 普及,有助于提升交通运输效率,保障人民群众的出行安全,体现了以人民为中心的 发展思想。

然而,每一次技术变革也都伴随着新的挑战。自动驾驶所引发的隐私保护、数据
 安全、法律责任等问题正在逐步显现;我们在推动技术发展的同时,也必须深刻思考:如何保障人们的信息权利?当机器做出决策时,谁该为其结果负责?这些都提醒
 我们,技术不能脱离人本位的思考,伦理和规范同样是现代工程的重要部分。

从环境角度来看,智能交通的推广也为绿色出行开辟了道路。在能源结构亟待 转型的当下,自动驾驶与新能源技术的结合,预示着一种更清洁、更可持续的出行方 式。本论文所探讨的地图学习与更新机制,虽只是其中一环,却也代表了我们对效率 与环保双重目标的积极回应。

参考文献

- WOLCOTT R W, EUSTICE R M. Visual localization within lidar maps for automated urban driving[C] / /2014 IEEE/RSJ International Conference on Intelligent Robots and Systems. IEEE, 2014: 176-183.
- [2] JO K, SUNWOO M. Generation of a precise roadway map for autonomous cars[J]. IEEE Transactions on Intelligent Transportation Systems, 2014, 15(3): 925-937.
- [3] KAMMEL S, ZIEGLER J, PITZER B, et al. Team annieway' s autonomous system for the 2007 darpa urban challenge[J]. Journal of Field Robotics, 2008, 25(9): 615-639.
- [4] BOYKO A, FUNKHOUSER T. Extracting roads from dense point clouds in large scale urban environment[J]. ISPRS Journal of Photogrammetry and Remote Sensing, 2011, 66(6): S2-S12.
- [5] GAO Y, ZHONG R, TANG T, et al. Automatic extraction of pavement markings on streets from point cloud data of mobile lidar[J]. Measurement Science and Technology, 2017, 28(8): 085203.
- [6] 谢诗超. 多传感器融合的自动驾驶点云地图构建与更新方法研究[D/OL]. 清华大学, 2019. DOI: 10.27266/d.cnki.gqhau.2019.000224.
- [7] AIJAZI A, CHECCHIN P, TRASSOUDAINE L. Detecting and updating changes in lidar point clouds for automatic 3d urban cartography[G]//ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences: Volume 2. s.n., 2013: 7-12.
- [8] 李克强, 戴一凡, 李升波, 等. 智能网联汽车 (ICV) 技术的发展现状及趋势[J]. 汽车安全与节 能学报, 2017, 08(1): 1-14.
- [9] 张涛,杨殿阁,李挺,等.导航电子地图中路口的交通矩阵与路束模型[J].武汉理工大学学报 (交通科学与工程版),2009,33(5):822-825.
- [10] SEIF H G, HU X. Autonomous driving in the iCity—HD maps as a key challenge of the automotive industry[J]. Engineering, 2016, 2(2): 159-162.
- [11] BACHA A, BAUMAN C, FARUQUE R, et al. Odin: Team VictorTango' s entry in the DARPA Urban Challenge[J]. Journal of Field Robotics, 2008, 25(8): 467-492.
- [12] NDS Association. 12.12.2018: Release of NDS Version 2.5.4[EB/OL]. 2018. https://www.nds-a ssociation.org/#news.
- [13] XIAO Z, JIANG K, XIE S, et al. Monocular vehicle self-localization method based on compact semantic map[C]//2018 21st International Conference on Intelligent Transportation Systems (ITSC). IEEE, 2018: 3083-3090.
- [14] SHIMADA H, YAMAGUCHI A, TAKADA H, et al. Implementation and evaluation of local dynamic map in safety driving systems[J]. Journal of Transportation Technologies, 2015, 5(2): 102.
- [15] SEO Y W, URMSON C, WETTERGREEN D. Ortho-image analysis for producing lane-level highway maps[C] / / Proceedings of the 20th International Conference on Advances in Geographic Information Systems. ACM, 2012: 506-509.
- [16] CHEN X, KOHLMEYER B, STROILA M, et al. Next generation map making: geo-referenced ground-level lidar point clouds for automatic retro-reflective road feature extraction[C]// Proceedings of the 17th ACM SIGSPATIAL International Conference on Advances in Geographic Information Systems. ACM, 2009: 488-491.
- [17] WEHR A, LOHR U. Airborne laser scanning—an introduction and overview[J]. ISPRS Journal of Photogrammetry and Remote Sensing, 1999, 54(2–3): 68-82.
- [18] GEHRUNG J, HEBEL M, ARENS M, et al. A framework for voxel-based global scale modeling

of urban environments[J]. International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences, 2016, 42.

- YONEDA K, TEHRANI H, OGAWA T, et al. Lidar scan feature for localization with highly precise
 3-D map[C]//2014 IEEE Intelligent Vehicles Symposium Proceedings. IEEE, 2014: 1345-1350.
- [20] CASELITZ T, STEDER B, RUHNKE M, et al. Monocular camera localization in 3D lidar maps [C]//2016 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS). IEEE, 2016: 1926-1931.
- [21] YANG B, LIANG M, URTASUN R. HDNet: Exploiting HD maps for 3D object detection[C] / / Conference on Robot Learning. s.n., 2018: 146-155.
- [22] HYYPPÄ J, JAAKKOLA A, HYYPPÄ H, et al. Map updating and change detection using vehiclebased laser scanning[C] / /2009 Joint Urban Remote Sensing Event. IEEE, 2009: 1-6.
- [23] AL KHATIB E I, JARADAT M A K, ABDEL-HAFEZ M F. Low-cost reduced navigation system for mobile robot in indoor/outdoor environments[J]. IEEE Access, 2020, 8: 25014-25026.
- [24] 李俊杰. 面向飞机大部件测量的移动机器人导航与定位技术[D/OL]. 南京航空航天大学, 2020. DOI: 10.27239/d.cnki.gnhhu.2020.001500.
- [25] YAN H D, SPLIT M R, ZHANG X L. Neural network model of the sensor data fusion applications[J]. Intelligence Command and Control Systems and Simulation Technology, 1994(6): 33-38.
- [26] 任伟建, 陈奕君. 基于神经网络的移动机器人多传感器数据融合研究[J/OL]. 电子设计工程, 2014, 22(12): 5-8. DOI: 10.14022/j.cnki.dzsjgc.2014.12.105.
- [27] 王随阳, 蒋林, 雷斌, 等. 基于多传感器融合的室内机器人定位研究[J/OL]. 组合机床与自动 化加工技术, 2020(10): 72-75+89. DOI: 10.13462/j.cnki.mmtamt.2020.10.018.
- [28] 闫飞, 庄严, 王伟. 移动机器人基于多传感器信息融合的室外场景理解[J]. 控制理论与应用, 2011, 28(08): 1093-1098.
- [29] KANG R, XIONG L, XU M, et al. Vins-vehicle: A tightly-coupled vehicle dynamics extension to visual-inertial state estimator[C]//2019 IEEE Intelligent Transportation Systems Conference (ITSC). IEEE, 2019: 3593-3600.
- [30] SHAN T, ENGLOT B, MEYERS D, et al. Lio-sam: Tightly-coupled lidar inertial odometry via smoothing and mapping[C]//2020 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS). IEEE, 2020: 5135-5142.
- [31] QIN C, YE H, PRANATA C E, et al. LINS: A lidar-inertial state estimator for robust and efficient navigation[C]//2020 IEEE International Conference on Robotics and Automation (ICRA). IEEE, 2020: 8899-8906.
- [32] LIU J, GAO W, HU Z. Visual-inertial odometry tightly coupled with wheel encoder adopting robust initialization and online extrinsic calibration[C]//2019 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS). IEEE, 2019: 5391-5397.
- [33] YE H, CHEN Y, LIU M. Tightly coupled 3D LiDAR inertial odometry and mapping[C]//2019 International Conference on Robotics and Automation (ICRA). IEEE, 2019: 3144-3150.
- [34] AFIA A B, ESCHER A C, MACABIAU C. A low-cost GNSS/IMU/visual MonoSLAM/WSS integration based on federated Kalman filtering for navigation in urban environments[C]// Proceedings of the 28th International Technical Meeting of The Satellite Division of The Institute of Navigation (ION GNSS+). 2015: 618-628.
- [35] LIANG Y, MÜLLER 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 (IROS). IEEE, 2020: 1661-1668.

- [36] KLEIN G, MURRAY D W. Parallel Tracking and Mapping for Small AR Workspaces[C]//IEEE and ACM International Symposium on Mixed and Augmented Reality. Nara, Japan, 2007: 1-10.
- [37] RAGURAM R, FRAHM J M, POLLEFEYS M. A Comparative Analysis of RANSAC Techniques Leading to Adaptive Real-Time Random Sample Consensus[C] / /European Conference on Computer Vision (ECCV). Marseille, France, 2008: 500-513.
- [38] ENGEL J, SCHÖPS T, CREMERS D. LSD-SLAM: Large-Scale Direct Monocular SLAM[C] / / European Conference on Computer Vision (ECCV). Zurich, Switzerland, 2014: 834-849.
- [39] YIN Z, SHI J. GeoNet: Unsupervised Learning of Dense Depth, Optical Flow and Camera Pose[C] //IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Salt Lake City, USA, 2018: 500-513.
- [40] BESL P J, MCKAY N D. Method for Registration of 3-D Shapes[C] / /Sensor Fusion IV: Control Paradigms and Data Structures: vol. 1611. SPIE, 1992.
- [41] SEGAL A, HAEHNEL D, THRUN S. Generalized-ICP[C]//Robotics: Science and Systems (RSS): vol. 2: 4. 2009.
- [42] BIBER P, STRASSER W. The Normal Distributions Transform: A New Approach to Laser Scan Matching[C] / /IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS). Las Vegas, USA, 2003: 2743-2748.
- [43] TIPALDI G D, ARRAS K O. FLIRT Interest Regions for 2D Range Data[C]//IEEE International Conference on Robotics and Automation (ICRA). Anchorage, USA, 2010: 3616-3622.
- [44] BAILEY T S. Consistency of the EKF-SLAM Algorithm[C]//IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS). Beijing, China, 2006: 3562-3568.
- [45] HUANG G, MOURIKIS A I, ROUMELIOTIS S I. On the Complexity and Consistency of UKFbased SLAM[C] / /IEEE International Conference on Robotics and Automation (ICRA). Kobe, Japan, 2009: 3878-3885.
- [46] MONTEMERLO M, THRUN S, KOLLER D. FastSLAM: A Factored Solution to the Simultaneous Localization and Mapping Problem[C]//National Conference on Artificial Intelligence (AAAI). Edmonton, Alberta, Canada, 2002: 593-598.
- [47] HESS W, KOHLER D, RAPP H. Real-Time Loop Closure in 2D LIDAR SLAM[C] / /IEEE International Conference on Robotics and Automation (ICRA). Stockholm, Sweden, 2016: 1271-1278.
- [48] POLOK L, ILA V, ŠOLONY M. Incremental Block Cholesky Factorization for Nonlinear Least Squares in Robotics[C]//Robotics: Science and Systems (RSS). Berlin, Germany, 2013.
- [49] KAESS M, JOHANNSSON H, ROBERTS R. iSAM2: Incremental Smoothing and Mapping Using the Bayes Tree[J]. The International Journal of Robotics Research, 2012, 31(2): 216-235.
- [50] GRISETTI G, STACHNISS C, BURGARD W. Improved Techniques for Grid Mapping With Rao-Blackwellized Particle Filters[J]. IEEE Transactions on Robotics, 2007, 23(1): 34-46.
- [51] 吴艳. 多传感器数据融合算法研究[D]. 西安: 西安电子科技大学, 2003.
- [52] 周芳, 韩立岩. 多传感器信息融合技术综述[J]. 遥测遥控, 2006, 27(3): 1-7.
- [53] 祝宏,曾祥进.多传感器信息融合研究综述[J]. 计算机与数字工程, 2007, 35(12): 46-48.
- [54] 姜万录, 李冲祥, 刘继刚. 多传感器数据融合技术的现状及展望[J]. 机床与液压, 2003(3): 16-19.
- [55] ZHANG J, SINGH S. LOAM: Lidar Odometry and Mapping in Real-time[C]//Robotics: Science and Systems Conference (RSS). Berkeley, CA, 2014.
- [56] SHAN T, ENGLOT B. LeGO-LOAM: Lightweight and Ground-Optimized Lidar Odometry and Mapping on Variable Terrain[C]//Proceedings of the 2018 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS). Madrid, Spain, 2018: 4758-4765.

致 谢

本科四年,没有什么轰轰烈烈的事迹,也没有耀眼夺目的光环。但在这段平凡而 真实的旅程中,我收获了许多值得铭记的经历:能学习自己热爱的知识,结识良师益 友,见识更广阔的世界,也看见了一个逐渐成长、不断丰富的自己。这些日子的点滴, 共同塑造了今天的我。

首先,我要衷心感谢我的导师袁汀教授。袁老师是我踏入学术世界的引路人。在 我不算长的本科科研旅程中,老师始终耐心指导,细致讲解,从研究选题、实验设计 到论文撰写,每一步都给予了我莫大的帮助。正是袁老师的悉心教导和学术引领,让 我初识科研的模样,理解了学术探索的价值与魅力。袁老师严肃活泼的治学风格、深 邃的思维方式,也将持续影响我很久很久。

感谢实验室的两位师兄——陈晓俊和陈国飞。在毕业设计的整个过程中,他们给 予我无私的帮助,无论是实验指导还是论文修改,都让我倍感温暖与鼓励。

感谢王召健老师,作为我们班的班主任,他在学业和生活中都给予了我们许多耐心的支持与关怀。感谢电子信息与电气工程学院的每一位老师,正是你们平易近人而 又学识渊博的身影,让我坚定地喜欢上了这个专业。也感谢上海交通大学所有曾经教 导过我的老师们,是你们的言传身教,让我真正领悟到"知识"背后的精神力量。

我也想特别感谢我的家人。是你们始终坚定地站在我身后,给予我无条件的支持 和理解。感谢我开明的父母,无论是高考志愿填报、专业选择,还是后来放弃读研、 选择工作的决定,你们总是在我最需要的时候给予建议与鼓励,尊重并支持我所做的 每一个选择。感谢所有关心和爱护我的家人,是你们构筑了我最坚实的后盾,是我不 断前行的源源动力。

感谢所有陪伴我走过这段旅程的朋友们。感谢那些老朋友,即使分隔不同城市, 依然能常常倾诉心事;也感谢大学四年中遇到的新伙伴,大家在课业中互相鼓励,在 生活中彼此照应,一起度过了许多难忘的时光。每一位同学、每一份陪伴,都是我青 春岁月中不可或缺的一部分。最后,我想感谢那个始终热爱生活、努力坚持的自己。 或许这四年里也有遗憾,不是所有故事都有圆满的结局,但我相信,那些美好的回忆 已成为我心中温柔的光。而前路还长,仍需笃定前行。

英文大摘要

With the accelerated development of intelligent transportation systems and the increasing deployment of autonomous vehicles, the construction of high-definition (HD) maps has become a critical technological bottleneck. These maps not only serve as a reference for global navigation but also play a pivotal role in local perception, trajectory planning, obstacle avoidance, and real-time vehicle control. Unlike traditional navigation maps, HD maps used in autonomous driving must possess centimeter-level geometric accuracy and contain rich semantic information about lane boundaries, road signs, traffic signals, and surrounding infrastructure. However, constructing and maintaining such maps dynamically-especially in complex, changing environments—remains a formidable challenge. The limitations of relying on a single type of sensor for simultaneous localization and mapping (SLAM) have become apparent in scenarios involving sensor occlusion, variable lighting, adverse weather, or urban clutter. In light of these challenges, this thesis proposes a robust vehicle-mounted autonomous map learning system based on multi-sensor information fusion. The system integrates LiDAR and millimeter-wave radar data using an Extended Kalman Filter (EKF) framework, achieving reliable, real-time, and high-fidelity mapping in both indoor and outdoor environments.

The motivation for this research stems from the observation that no single sensor can provide both the high spatial resolution and environmental adaptability required for robust autonomous perception. LiDAR sensors, which offer precise 3D structural measurements, are susceptible to environmental interference and have high power and cost demands. Millimeterwave radar, on the other hand, excels in detecting dynamic objects and performs reliably under adverse weather conditions, but suffers from lower resolution and noisier data. By fusing the complementary features of these sensors, the proposed system aims to combine LiDAR' s geometric fidelity with radar' s robustness to environmental variation, thereby improving both the stability and the accuracy of vehicle localization and map construction.

The theoretical backbone of the proposed system lies in the probabilistic modeling of the SLAM problem. SLAM is formulated as a recursive Bayesian estimation task, in which the objective is to estimate both the trajectory of the vehicle and the structure of the surrounding

environment using time-sequenced control inputs and sensor observations. The state vector comprises the vehicle' s pose and the map representation, while observations are treated as stochastic variables influenced by sensor noise and environmental uncertainty. The motion model captures the system dynamics over time, typically involving linear and angular velocities, and the observation model represents the relationship between sensor readings and map features. In the proposed approach, the fusion of LiDAR and radar data is handled through an EKF, which linearly approximates the nonlinear SLAM equations and iteratively refines the state estimates as new observations become available.

A central challenge addressed in the system design is achieving precise temporal synchronization and spatial alignment between heterogeneous sensor inputs. Time stamps from LiDAR and radar are aligned to a common clock, and sensor data are transformed into a unified coordinate frame using extrinsic calibration parameters. This enables data-level fusion in a consistent reference system, preserving the spatial relationships necessary for accurate point cloud construction and pose estimation. The radar data, providing Doppler velocity and object detection, is used to refine the dynamic motion model, while LiDAR point clouds are employed to anchor the map to static structural features.

The mapping framework developed in this thesis is implemented on a mobile platform consisting of LiDAR, millimeter-wave radar, an inertial measurement unit (IMU), and a global navigation satellite system (GNSS) module. The software stack runs on the Ubuntu operating system and utilizes the Robot Operating System (ROS) middleware for sensor data handling, fusion processing, and real-time visualization. Data from the sensors is first preprocessed, filtered for noise, and converted into compatible formats for use in MATLAB, where custom algorithms perform mapping and pose estimation. ROS nodes are customized to subscribe to radar topics and perform interpolation for missing or asynchronous data, while LiDAR frames are used to construct occupancy grids and register point cloud data with the existing map.

To enhance computational efficiency and mapping stability, a keyframe-based map updating strategy is proposed. Rather than storing every sensor frame, the system identifies and stores only those frames that contribute significantly to pose change or environmental coverage. These keyframes are used as anchor points for local submap construction and global map integration. Within each keyframe, a two-stage scan matching approach is adopted: a coarse alignment using low-resolution grid features is followed by fine-tuned registration in a high-resolution map. This strategy reduces computational overhead without sacrificing localization accuracy. A spatial windowing technique ensures that only regions near the current pose are included in the map update, further streamlining the process and allowing for near-real-time operation.

Another innovative element is the application of principal component analysis (PCA) in filtering and optimizing point cloud data. PCA is used to reduce dimensional redundancy and extract dominant structural features from LiDAR frames, especially useful in indoor corridor-like environments where linear walls and orthogonal intersections are prevalent. This helps remove transient noise caused by dynamic objects and improves the sharpness of mapped features. The system also leverages the high refresh rate of radar to estimate short-term motion velocity, which is then used to compensate for pose drift during LiDAR scan intervals.

To evaluate the proposed system, both simulated and real-world experiments are conducted. The simulation environment is constructed using standard SLAM evaluation datasets, including KITTI, and employs open-source packages such as Cartographer and Stage for benchmarking. In real-world trials, data are collected from various scenarios including narrow indoor hallways and outdoor urban streets. The resulting maps exhibit high structural fidelity and consistency, with minimal drift over extended trajectories. Compared to singlesensor SLAM systems, the fusion-based approach demonstrates superior resilience to occlusion, smoother trajectory estimates, and clearer reconstruction of vertical and horizontal surfaces.

In corridor mapping tasks, the system successfully captures narrow passageways and corner turns, creating accurate sparse 3D grid maps that reflect walls, door frames, and object boundaries. In outdoor tests, it adapts to changing illumination and dynamic obstacles, filtering out moving vehicles and pedestrians while preserving static infrastructure. Loop closure detection is implicitly supported through pose graph optimization, although not explicitly implemented in this prototype. The experiments confirm that radar improves pose prediction under conditions where LiDAR signal quality is poor, while LiDAR enhances spatial granularity where radar alone is insufficient.

The integration with LeGO-LOAM (Lightweight and Ground-Optimized LiDAR Odom-

etry and Mapping) further enhances system robustness. LeGO-LOAM' s modular design allows for efficient feature extraction, ground segmentation, and real-time loop closure, making it suitable for embedded deployment. The thesis modifies this framework to incorporate radar-based velocity priors and aligns radar detections with LiDAR-derived edge and plane features. As a result, the fused system produces more accurate, temporally stable maps even in challenging lighting or weather conditions, outperforming pure LiDAR SLAM in both precision and reliability.

In concluding its contributions, the thesis emphasizes that the fusion of millimeter-wave radar and LiDAR under a probabilistic SLAM framework significantly improves the operational robustness of autonomous map learning systems. The combination addresses key weaknesses of individual sensors and enables effective deployment in real-world scenarios where environmental unpredictability is common. The system maintains high localization accuracy, adapts to scene variability, and scales well across different vehicle speeds and trajectories.

Looking ahead, the thesis envisions several future enhancements. The integration of semantic perception capabilities through deep learning models could enable the system to recognize and map labeled entities such as traffic signs, road markings, and pedestrians. This would transition the system from geometric mapping to semantic understanding. Incorporating lifelong learning mechanisms would allow the system to update its maps continuously over time, accommodating roadwork, seasonal changes, and long-term environmental evolution. Additionally, implementing edge computing strategies and lightweight inference engines could allow for real-time processing on embedded platforms, further facilitating deployment in commercial autonomous vehicles. Finally, the thesis highlights the potential of vehicle-to-vehicle and vehicle-to-infrastructure communication in enabling cooperative mapping across fleets, where distributed agents share observations to construct richer and more comprehensive environmental models.

In summary, this thesis makes a substantial contribution to the field of autonomous driving by designing, implementing, and validating a real-time vehicle-mounted SLAM system that fuses LiDAR and radar data. Through rigorous theoretical modeling, system integration, algorithmic innovation, and empirical evaluation, it demonstrates that multi-sensor fusion is not only feasible but essential for achieving the high reliability and adaptability required by modern autonomous vehicles. The work lays a strong foundation for future research in robust perception systems and scalable autonomous navigation infrastructure.