

分类号: TP242

密 级: 公开

学校代码: 10363

学 号: 2220120106



安徽工程大学

Anhui Polytechnic University

硕士学位论文

题 目 基于多传感器融合的移动平台

精确定位与环境感知技术研究

论 文 作 者 徐亮亮

校 内 导 师 王建平 研究员

校 外 导 师 陈峰 高级工程师

专业学位类别 机械工程

研究方向(领域) 信息融合与感知

论文提交日期: 2025 年 5 月 20 日

分类号：TP242

学校代码：10363

密 级：公开

学 号：2220120106

基于多传感器融合的移动平台精确定位
与环境感知技术研究

Nondestructive evaluation of thermal barrier coatings
microstructures based on terahertz technology

学生姓名： 徐亮亮

校内导师： 王建平 研究员

校外导师： 陈锋 高级工程师

专 业： 机 械 工 程

研究方向： 信息融合与感知

论文答辩日期： 2025 年 5 月 10 日

安徽工程大学学位论文原创性声明

本人郑重声明：我恪守学术道德，崇尚严谨学风。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。除文中已明确注明和引用的内容外，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及成果的内容。论文为本人亲自撰写，我对所写的内容负责，并完全意识到本声明的法律后果由本人承担。

学位论文作者签名：

日期： 年 月 日

安徽工程大学学位论文版权使用授权书

学位论文作者完全了解学校有关保留、使用学位论文的规定，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，允许论文被查阅或借阅。本人授权安徽工程大学可以将本学位论文的全部或部分内容编入有关数据库进行检索，可以采用影印、缩印或扫描等复制手段保存和汇编本学位论文。

保密 ☐，在 年解密后适用本版权书。

本学位论文属于

不保密 ☐。

学位论文作者签名：

指导教师签名：

日期： 年 月 日

日期： 年 月 日

基于多传感器融合的移动平台精确定位 与环境感知技术研究

摘 要

随着生活中自动化需求的增加，自动驾驶技术也在不断发展。实现自动驾驶的核心之一是同步定位与建图技术（Simultaneous Localization And Mapping, SLAM），依靠单一传感器的 SLAM 技术在日益复杂的应用场景中，难以保障定位与建图的精度。融合多种传感器数据的 SLAM 技术成为研究的热点。为提高 SLAM 算法的定位与建图精度并增强多传感器融合算法的鲁棒性，本课题聚焦室外大场景下移动平台多传感器融合的精确定位与环境感知技术的研究，主要研究内容如下：

（1）针对传统基于的回环检测算法计算量较大、对初值敏感的问题，设计了一种基于 LIDAR SYM 关键帧描述子的回环检测算法。将三维关键帧点云投影到二维平面，并通过二维网格编码，将点云转化为简洁的描述子。提升回环检测算法的运算速度，提高了 SLAM 算法的整体效率。

（2）针对 SLAM 算法位姿求解精度较低的问题，设计了一种惯性测量单元（Inertial Measurement Unit, IMU）与轮速里程计（Odometry, ODO）联合预积分模型，通过数据融合，充分利用两

者的互补特性，提高移动平台的位姿精度并为点云畸变校正提供了精确初值。

（3）针对固定间隔的关键帧选取策略导致计算量大、实时性低的问题，设计了一种基于运动阈值的关键帧选取策略，通过动态评估帧间相对运动，避免选取过于密集或稀疏，提高算法的效率和实时性，提升算法的整体性能。

（4）针对单一传感器在复杂环境下难以保障建图精度和鲁棒性的问题，设计了一种基于多传感器融合的 SLAM 算法，通过将激光雷达、IMU、ODO 以及全球卫星导航系统（Global Position System, GPS）数据紧耦合，有效提高 SLAM 算法的建图精度和鲁棒性。

（5）采用公开 KITTI 数据集对算法精度和鲁棒性进行了仿真验证。搭建了移动测试平台，对多传感器融合算法进行实车验证，结果表明相关算法在真实复杂环境中具有良好建图精度和鲁棒性。

关键词： 移动平台，SLAM，预积分，回环检测，多传感器融合

RESEARCH ON PRECISE POSITIONING AND ENVIRONMENTAL PERCEPTION TECHNOLOGY FOR MOBILE PLATFORMS BASED ON MULTI-SENSOR FUSION

ABSTRACT

With the increasing demand for automation in daily life, autonomous driving technology has been continuously evolving. One of the core technologies enabling autonomous driving is Simultaneous Localization and Mapping (SLAM). However, SLAM systems relying on a single sensor struggle to ensure sufficient localization and mapping accuracy in increasingly complex application scenarios. Consequently, multi-sensor fusion SLAM has become a focal point of research. To enhance localization and mapping accuracy while improving the robustness of multi-sensor fusion algorithms, this study focuses on precise localization and environmental perception technologies for outdoor large-scale mobile platforms. The main research contributions are as follows:

(1) To address the high computational complexity and sensitivity to initial values in traditional loop closure detection algorithms, a loop closure detection method based on the LIDAR SYM keyframe descriptor is designed. This approach projects 3D keyframe point clouds onto a 2D

plane and encodes them into a 2D grid, transforming point cloud data into a compact descriptor. This improves the computational efficiency of loop closure detection and enhances the overall efficiency of the SLAM system.

(2) To improve the accuracy of pose estimation in SLAM, an Inertial Measurement Unit (IMU) and Odometry (ODO) joint pre-integration model is developed. By integrating data from both sensors, the complementary characteristics of IMU and ODO are effectively leveraged, enhancing the accuracy of mobile platform pose estimation and providing a precise initial value for point cloud distortion correction.

(3) To address the limitations of fixed-interval keyframe selection, which leads to excessive computational load and reduced real-time performance, a motion-threshold-based keyframe selection strategy is proposed. By dynamically evaluating the relative motion between frames, this approach prevents overly dense or sparse keyframe selection, improving algorithmic efficiency and real-time performance while optimizing overall system performance.

(4) To mitigate the challenges of ensuring mapping accuracy and robustness in complex environments using a single sensor, a multi-sensor fusion SLAM algorithm is designed. This algorithm tightly integrates data from Light Detection and Ranging (LiDAR), IMU, ODO, and the Global Positioning System (GPS), significantly improving both mapping accuracy and system robustness.

(5) The proposed algorithm's accuracy and robustness are validated through simulations using the publicly available KITTI dataset. Additionally, a mobile testing platform is constructed for real-world vehicle experiments. Experimental results demonstrate that the proposed multi-sensor fusion SLAM algorithm achieves high mapping accuracy and robustness in real-world complex environments.

KEY WORDS: mobile platform, SLAM, pre-Integration, loop closure detection, multi-sensor fusion

目录

第 1 章 绪论.....	1
1.1 研究背景与意义.....	1
1.2 国内外研究现状.....	3
1.2.1 国外研究现状.....	3
1.2.2 国内研究现状.....	4
1.3 主要研究内容.....	5
1.4 章节安排.....	6
第 2 章 多传感器融合 SLAM 技术原理分析.....	8
2.1 引言.....	8
2.2 传感器种类及其功能.....	8
2.2.1 三维激光雷达 (3D Lidar)	8
2.2.2 惯性测量单元(IMU)	10
2.2.3 轮速里程计 (ODO)	11
2.2.4 全球导航卫星系统(GPS).....	12
2.3 坐标系定义及转换原理.....	13
2.3.1 坐标系定义.....	13
2.3.2 位姿变换.....	15
2.4 多传感器融合算法基本框架.....	16
2.4.1 点云预处理.....	16
2.4.2 点云配准.....	17
2.4.3 回环检测.....	18
2.4.4 图优化理论.....	20
2.5 本章小结.....	21
第 3 章 基于多传感器融合的回环检测算法.....	22
3.1 激光点云数据预处理.....	22
3.2 传统的回环检测算法.....	23
3.3 基于描述符 LIDAR SYM 的回环检测.....	26

3.4 本章小结.....	28
第 4 章 基于多传感器融合的移动平台的 SLAM 算法.....	29
4.1 引言.....	29
4.2 IMU-ODO 预积分.....	30
4.2.1 IMU 与 ODO 测量模型	30
4.2.2 基于 IMU 与 ODO 联合预积分方法研究	31
4.3 融合 IMU 数据去除点云畸变.....	33
4.3.1 点云畸变原因分析.....	33
4.3.2 高频 IMU 与激光雷达的数据融合	35
4.3.3 时间同步的误差及优化.....	36
4.4 基于多传感器融合的 SLAM 算法.....	37
4.4.1 关键帧选取.....	38
4.4.2 图优化框架.....	39
4.5 本章小结.....	41
第 5 章 移动实验平台搭建与实验分析.....	42
5.1 移动实验平台搭建.....	42
5.2 软件平台.....	43
5.3 基于 KITTI 公开数据集的算法验证	44
5.3.1 公开数据集及仿真平台介绍.....	44
5.3.2 算法精度评价指标.....	45
5.3.3 KITTI 数据集实验与分析	46
5.4 校园场景下的实车实验.....	52
5.5 本章小结.....	55
第 6 章 总结与展望.....	56
6.1 总结.....	56
6.2 展望.....	57
参考文献.....	58
攻读硕士学位期间取得学术成果.....	66
致谢.....	67

第 1 章 绪论

1.1 研究背景与意义

随着自动驾驶技术的快速发展^[1]，各类自主移动平台也逐步进入人们的视野，基于激光雷达的多传感器融合技术也在不断进步，并被逐渐应用于无人汽车以及无人物流、无人巡检等领域^[2-5]。无人驾驶出租车提高了出行的便捷性；无人配送车提高了物流的时效性；无人巡检车提高了巡检作业的安全性，各类自主移动平台如图 1-1 所示。



图 1-1 自主移动平台

实现各类移动平台自动驾驶的前提^[6-8]，是依靠移动平台搭载的传感器构建高精度定位与建图，即SLAM技术^[9-13]。基于SLAM技术的多传感器融合方法，能够实施移动平台的全方位感知。通过对多种传感器数据进行融合处理，实现高精度定位与建图。基于多传感器融合的SLAM技术能够构建具有时空一致性的精确环境地图，为实现移动平台的自动驾驶提供了技术支撑。

目前，随着各类传感器^[13-15]如激光雷达^[16-17]、双目相机^[18-19]、深度相机^[15]、惯性测量单元（Inertial Measurement Unit, IMU）^[20-21]、轮速里程计（Odometer, ODO）^[22-23]及全球定位系统（Global Positioning System, GPS）^[24-25]等传感器的不断研发和迭代，SLAM 算法的研究也在不断深入，视觉传感器因低廉的价格，

丰富的数据信息常被应用于 SLAM 算法中。视觉传感器在使用过程中受限于外部环境条件，尤其是在拍摄角度、光照强度及天气状况等不可控因素的影响下，其对场景特征的获取能力降低。使得图像特征的有效获取面临较大挑战。特别是在动态变化的环境中，这种问题更加显著。与视觉传感器相比，三维激光雷达（LiDAR）对外界环境光线和天气的变化不敏感，激光雷达通过发射激光束并测量其返回时间，能够获取高精度的三维空间信息。激光雷达 SLAM 算法因其独特优势，已成为当前研究领域的热点方向。

激光雷达虽然能够提供高精度的定位与点云地图，但其主要关注场景结构信息。在某些特定空旷的郊区环境，场景的结构特征较少，激光雷达的位姿估计精度会显著下降。为了进一步提高自主移动平台定位与建图的稳定性和鲁棒性，融合多传感器信息的 SLAM 算法成为研究的重点。

通过将激光雷达与IMU、ODO、GPS 数据进行有效融合，有效克服了单一传感器的局限性。不仅提升了解算效率，同时提高了定位与建图的精度。尽管基于激光雷达的多传感器融合技术取得了显著进展，但建图实时性较低、长距离下产生累计误差的问题，需要对 SLAM 技术做进一步的研究。

SLAM 技术是指移动平台在未知环境中，通过搭载的多种传感器，实时采集环境数据并进行位姿的估计，根据实时的位置信息，不断更新并构建环境的增量地图，实现在未知环境下的定位与建图。这项技术的实现需要各传感器数据的有效结合，多种传感器根据实际需要采集不同数据，通过整合不同传感器的数据，有效避免因信息不足而导致的位姿估计误差，提升了整体定位精度，多传感器数据的融合流程如图 1-2 所示。




图 1-2 多传感器融合算法流程图

流程图中展示了多传感器融合的 SLAM 算法中不同类型数据的多层次、多维度的信息整合与优化，构建出对环境的统一描述。多传感器融合消除了单一传感器 SLAM 系统中的不确定性，提供了精确的观测结果，并将各类传感器信息进行融合，实现了移动平台在各类场景下的精确定位与建图。

1.2 国内外研究现状

1.2.1 国外研究现状

对 SLAM 相关技术的探索最早源于国外。在技术发展的初期阶段，研究者针对 SLAM 系统中的状态估计问题，主要运用扩展卡尔曼滤波（Extended Kalman Filter, EKF）方法来^[26-27]来解决这类问题。EKF 将非线性函数通过一阶泰勒公式进行线性化处理，通过卡尔曼滤波的流程求解最优估计^[28]。但在实际应用中，移动平台的状态方程通常并不服从高斯分布这一假设。因此，基于粒子滤波的 SLAM 算法逐渐受到关注。粒子滤波（Particle Filter）^[29]本质上是一种蒙特卡洛方法，能够通过大量样本近似估计状态的概率分布，从而更有效的处理非线性问题。

在粒子滤波 SLAM 的发展历程中，Montemerlo 等人于 2002 年引入了 FastSLAM^[30]算法，随后于 2003 年进一步提出了 FastSLAM 2.0^[31]算法。该算法通过粒子滤波技术对 SLAM 系统中的非线性概率密度分布进行了有效估计，在非线性和估计方面展现出较高的适应性。但粒子退化问题仍对算法精度构成一定影响。针对这一局限，FastSLAM 2.0 采用了扩展卡尔曼滤波（EKF）方法，对移动平台的位姿进行递归更新，在一定程度上减缓了粒子退化的速率。Grisetti 等人于 2007 年提出的 Gmapping^[32]算法通过改进提议分布并对点云重采样次数进行合理限制，有效降低了粒子损失现象的发生。随着研究的深入，图优化方法逐渐成为提升 SLAM 算法精度的关键技术。1997 年，Lu 等人首次提出了图优化框架，设计了一种基于图优化框架的 SLAM 算法^[33]，减小了累计误差。相较于粒子滤波方法，图优化技术通过构建包含位姿节点和约束关系的因子图框架，将原本的非线性最优化问题转化为基于最小二乘的优化问题。这种方法充分利用历史数据对系统状态进行优化处理，从而减少了传统递推估算中计算的复杂度。Kato 等人在 2010 年提出了 KartoSLAM 算法，该算法采用非迭代的分解方法，

实现了 SLAM 系统方程的快速求解。然而，该算法需要预先生成子图并进行匹配，降低了其整体运算效率。因此，KartoSLAM 更适合用于小范围的环境建图^[34]。近年来，Google 公司于 2016 年推出了广泛应用的 Cartographer 算法，该算法采用扫描与地图的匹配 scan-to-map 方法，并通过分支定界策略识别重叠位置，通过添加回环约束，有效减少了累积误差，提升了系统的精度和稳定性^[35]。Cartographer 的高精度建图，标志着 SLAM 算法在实际场景中的进一步成熟与发展。国外自主移动平台如图 1-3 所示。



图 1-3 国外自主移动平台

1.2.2 国内研究现状

在国内 SLAM 算法研究领域，学者们通过持续深入研究，取得了丰富的创新成果。上海交通大学的孙作雷于 2010 年提出了一个面向滞后状态信息的融合滤波框架，通过将条件随机场激光匹配技术与采样积不确定性相结合，深入探讨了其在构建大规模地图方面的潜力与优势^[36]。哈尔滨工业大学的宋春林于 2014 年提出了一种基于地标环境的扩展卡尔曼滤波（EKF）方程，将数据关联技术与联合相容分枝定界法及最近邻方法相结合，进一步提升了 SLAM 算法在复杂环境下的适应能力与定位精度^[37]。

香港大学的刘峥等人于 2021 年提出了一种名为 BALM（Beam Adjustment LiDAR Mapping）的 SLAM 算法框架，该框架创新性地引入了光束平差方法，将激光雷达数据进行精确点云匹配，优化了地图构建过程，有效降低了由于传感器累积误差导致的建图精度问题^[38]。香港大学的徐威等人分别于 2021 年和 2022 年提出了 fast-lio^[39]及其改进版 fast-lio2^[40]。fast-lio 算法通过建立一种迭代

误差状态的卡尔曼滤波架构，实现了激光雷达与惯性测量单元（IMU）数据的紧密融合，显著提升了建图系统的精确度。**fast-lio2** 引入增量 **Kd-tree** 数据结构，提高了点云与地图匹配效率，增强了算法的稳定性与适用性。

浙江大学的王阳于 2022 年提出了一种基于位姿图优化的后端处理方法。该方法利用列文伯格-马夸尔特（Levenberg-Marquardt, L-M）算法将传感器数据与约束条件相结合，降低了大场景下的里程计累积误差。同时，探索性地引入了基于分支界定的像素匹配方法，用于回环检测与误差校正，进一步提升了算法在复杂环境中的稳定性与准确性^[41]，国内自主移动平台如图 1-4 所示。



图 1-4 国内自主移动平台

1.3 主要内容

为满足自主移动平台在实际运行中对高精度定位与建图的需要，本研究立足于实际需求，开展了面向多传感器紧耦合的 SLAM 算法研究。研究的核心目标在于实现 3D 激光雷达、IMU、ODO 及 GPS 等传感器的数据高效融合，实现移动平台在室外大场景下的高精度的定位与地图构建。本研究所采用的验证方法基于 KITTI 对所提出的算法性能进行了全面评估与验证分析^[42]，并在实际校园场景中搭建移动测试平台进行实车建图验证^[43-45]。通过多层次的验证策略，确保算法在不同场景下的适用性与稳定性，研究内容的具体构成如下：

多传感器融合技术的原理与算法设计：通过对激光雷达、IMU 和 GPS 的数学模型进行详细分析，重点研究了多传感器数据紧耦合技术对定位与建图的优

化。构建了一种因子图优化框架，有效融合激光雷达、IMU 和 GPS 数据，进一步提升了定位与建图的精度。同时为确保融合结果的准确性和稳定性，分析传感器误差模型的建立方法，采取相应的补偿措施。

IMU 与 ODO 联合预积分模型的建立：IMU 高频数据能够有效去除激光雷达由于运动产生的点云畸变，ODO 为移动平台提供了准确的相对位移信息。IMU 与 ODO 的联合预积分模型基于固定频率对位姿进行优化求解，避免因频率不同导致的计算复杂度问题^[46]。本文在第四章将深入探讨 IMU 与 ODO 的联合预积分理论，提出并构建 IMU-ODO 联合预积分模型。进一步推导联合预积分的残差方程，提升移动平台的定位与建图精度和效率^[47]。

基于多传感器融合的回环检测算法研究：提出了一种基于 LiDAR SYM 特征描述子的回环检测算法，提升算法在复杂室外环境中的检测性能。解决传统的回环检测算法在面对复杂场景时容易受到环境变化干扰的问题，降低检测算法对初值的敏感度，提升回环检测算法在复杂场景下的检测能力，进一步提高定位与建图的准确性和鲁棒性，消除长距离下的累计误差。

移动平台精确定位与环境感知算法的实现与验证：在机器人操作系统（ROS）^[48-49]环境下，采用公开的 KITTI 数据集进行算法可行性的验证。搭建了移动实验平台，通过在复杂真实场景中的实地测试，对算法的定位和建图性能进行全面的验证，确保算法在真实应用场景中的性能表现。

1.4 章节安排

本文共分为六章：

第一章阐述了本课题的研究背景及其理论与实践意义，系统梳理了国内外的研究进展，并明确了论文的整体结构安排。概述了基于多传感器融合的 SLAM 算法研究框架，为全文的理论研究奠定了基础。

第二章主要介绍了多传感器融合技术的核心理论与实现方法。分析了各类传感器的工作原理及坐标系变换方法和点云匹配算法的实现策略，并对基于图优化框架的多传感器信息紧耦合算法进行了全面阐述。同时，对多传感器融合算法中的关键技术及其相关理论基础进行分析与总结，为后续的算法研究与优化提供了理论支撑。

第三章介绍了减少原始点云冗余信息的体素滤波下采样方法^[50-52]，通过质心法降低激光点数量，提高算法效率。分析了基于距离和基于点云特征的回环检测算法的基本原理和不足，并提出了一种基于 LIDAR SYM 描述子的回环检测算法，详细介绍了描述子的构建过程和检测原理。

第四章介绍了融合 IMU 数据去除点云畸变的算法，设计了基于运动阈值的关键帧选取策略，通过构建因子图框架，将各传感器数据以因子约束的形式纳入统一模型中，利用图优化方法实现整体位姿的最优化处理^[53-56]。

第五章使用公开 KITTI 数据集对本文算法与主流算法进行测试，全面分析了各项误差参数，通过误差对比图直观展示算法性能的优劣。同时，为验证算法在实际场景中的适用性，搭建了移动测试平台，开展实车验证实验，并对实验结果进行了深入分析。

第六章是对整篇论文的总结与展望，回顾和总结论文的主要工作和研究成果，重点概述了在多传感器融合算法研究领域的突破与贡献。提出对多传感器融合算法的展望和建议，为多传感器融合 SLAM 算法研究提供新思路。

第 2 章 多传感器融合 SLAM 技术原理分析

2.1 引言

多传感器融合 SLAM 算法的深入研究推动了自动驾驶技术领域的发展，通过将三维激光雷达、IMU、ODO、GPS 等多传感器数据有效融合到统一的因子图模型中，实现了复杂环境的精准定位与建图。这种多模态数据的融合方法，不仅提升了环境感知的准确性与可靠性，也为自动驾驶系统在实际应用场景中的稳定运行提供了坚实的技术支撑。关于因子图框架的建立，本文在 4.4 节进行了详细的叙述。

在自动驾驶场景下，多传感器的时空同步、非线性状态估计以及分布式计算的挑战尤为突出。对多传感器融合 SLAM 的理论与技术实现路径的深入探索，为构建更精准、更可靠的自主导航系统奠定了基础。

多传感器融合算法的研究推动了自动驾驶技术在自动驾驶、物流配送、工业巡检等领域的应用。本章系统性地叙述多传感器融合 SLAM 的基本流程和方法论框架，通过理论创新与工程实践的深度结合，持续推动 SLAM 技术向更高层次迈进，为自主移动平台提供更加高效、鲁棒的多传感器融合算法。

2.2 传感器种类及其功能

2.2.1 三维激光雷达（3D Lidar）

自主移动平台所采用 SLAM 系统需要通过移动平台搭载的多种传感器来实现空间认知与同步定位功能。其中三维激光雷达凭借其多维空间解析能力成为环境建模的核心传感单元。该设备基于飞行时间测量原理^[57-58]，通过多线束发射机制实现空间点云的全景式采集，构建环境三维点云图。

本研究选用了速腾聚创公司研发的 Helios 16 激光雷达，如图 2-1 所示，Helios 16 是一款 16 线三维激光雷达，拥有 30° 的垂直视场角，360° 的水平视场角，依托雷达先进的测距技术，实现全方位环境感知和精准检测。其模块化架构设计优化了物理结构，近距离盲区小于 0.2m，支持车载以太网数据输出，兼具高性能与低功耗特性。为移动平台的高精度建图提供稳定感知基础。



图 2-1 Helios 16 激光雷达

Helios 16 激光雷达采用自主研发的无刷电机技术，有效减少机械摩擦与噪声，确保运行可靠性。其视场角内 16 线均匀分布，符合车规级标准，通过机械冲击、随机振动、低温启动等多项测试验证，性能参数见表 2-1。

表 2-1 16 线激光雷达

性能	参数
线数	16
激光波长	905nm
测距能力	0.2m 至 150m 型号：M3508 P19
转速	300/600/1200rpm 标准放电电流：4500mAh
帧率	5Hz/10Hz/20Hz
出点数	576000pts/s(单回波模式)
	1152000pts/s(双回波模式)

三维激光雷达采集的原始距离信息是以探测器为中心建立的球面坐标系下的方位角与测距值。对这些观测数据的空间可视化分析，采用球坐标转换公式解算出目标点在笛卡尔坐标系中的空间位置参数。目标点坐标解算如式（2-1）所示：

$$\begin{cases} x = r \cdot \cos \theta_v \cdot \sin \theta_h \\ y = r \cdot \cos \theta_v \cdot \cos \theta_h \\ z = r \cdot \sin \theta_v \end{cases} \quad (2-1)$$

式中 r 表示激光飞行时间解算的目标径向距离， θ_v 表示垂直扫描角度， θ_h 表示水平方向旋转编码器角度。

2.2.2 惯性测量单元(IMU)

惯性测量单元（IMU，Inertial Measurement Unit）是一款高精度状态传感器，在机器人、无人驾驶领域都起着重要作用。IMU 融合了加速度计、陀螺仪技术，实现了对载体的加速度与角速度变化的高精度测量^[59-60]。通过对加速度和角速度数据的积分，能够精确解算物体的运动状态。为载体提供了全面且准确的运动信息，确保了复杂环境下移动平台的精确定位与位姿估计。

本文采用的 IMU 型号为广州星宇 iNav2，如图 2-2 所示，该传感器是一款 9 轴传感器，集合了三轴加速度计、三轴陀螺仪和三轴磁力计，满足了算法对速度和角速度数据的高精度需求。



图 2-2 iNav2 IMU

iNav2 IMU 的加速度计量程为 $\pm 6g$ ，在角速度测量方面展现出广泛的动态范围，能够准确测量移动平台的角速度变化，体现出较高的灵敏度和稳定性。IMU 性能参数如表 2-2 所示。

表 2-2 IMU 性能参数

性能	参数
陀螺仪量程	$\pm 300^\circ/s$
陀螺仪零偏稳定性	$905nm \leq 10^\circ/h$
加速度计量程	$\pm 6g$
加速度计零偏稳定性	10mg
频率	100Hz

2.2.3 轮速里程计 (ODO)

在移动平台定位中，轮速里程计 (Odometer, ODO) 是基础的测量传感器，其测量原理基于对车轮旋转信息的采集，通过车轮旋转估算移动体在水平面上的位移量和运动方向。为了实现定位估计，系统需要建立自身的坐标系模型，坐标系构建以移动平台重心作为坐标系原点，运动方向设为 x 轴，横向移动方向定义 y 轴，垂直轴为 z 轴构成完整的三维参考系。轮速里程计的原理图如 2-3 所示，定位系统通过精确测量车轮的转速信号及其旋转方向，结合轮毂半径等几何参数，实现对移动平台运动状态的准确估计。如图 2-3(a)所示，图中 LED 指示灯与传感器固定于车体，确保测量过程中的稳定性。通过驱动电机带动编码磁盘随车轮转动，能够实现精确的运动捕捉。如图 2-3(b)所示，编码磁盘表面均匀分布多个穿孔，这一设计使得传感器能够在磁盘转动过程中采集到稳定的信号，这种基于编码器的测量方法，通过精确的数据采集，为定位系统提供了可靠的位姿数据。




图 2-3 轮速里程计原理图

ODO 传感器作为移动平台位姿估计的基础传感器，具有一定的局限性。当移动平台出现打滑或行驶在颠簸路面时，可能导致位姿估算出现偏差，降低定位精度。此外，ODO 仅能测量移动平台相对于初始位置的相对运动信息，无法获取绝对位置数据，限制了其独立工作的适用性。因此，为了实现更为完整与可靠的运动状态感知，通常将其与其他传感器数据进行融合。通过与激光雷达、惯性测量单元等多源感知设备的协同工作，系统可以实现对移动平台运动状态的全面感知与精确估计。

在 SLAM 系统中，经常使用 ODO 的数据作为初始的位移估计，与 IMU、

激光雷达进行数据融合，一定程度上解决了 GPS 信号丧失或退化情况下的定位问题，辅助校正机器人的位置与姿态，避免了 IMU 预积分过程中出现的漂移问题，弥补了各传感器的不足。ODO 传感器通过与其它传感器融合为移动平台在复杂场景的定位与建图提供了高精度数据。

2.2.4 全球导航卫星系统(GPS)

全球定位系统（Global Positioning System，GPS）通过接收卫星信号，为移动平台提供精确的绝对位置坐标^[61]。理想情况下，GPS 定位精度能够达到厘米级，在应用自动驾驶技术的领域中为移动平台提供了精确定位。

本文采用的 GPS 是 CGI220 Pro 是上海华测导航技术股份有限公司研发的 CGI220 Pro，如图 2-3 所示，CGI220 Pro 集成了全系统全频点 GNSS 基带板卡，采用华测先进的紧耦合算法引擎，通过融合 GNSS、INS 和 DR 数据，提供高精度、鲁棒性的导航解算。能输出连续稳定的位置、速度和姿态信息，克服多径效应与信号遮挡的影响。CGI220 Pro 的具体参数如表 2-3 所示。



图 2-4 CGI220 Pro 实物图

表 2-3 CGI220 Pro 参数

性能	参数
姿态精度	0.1°
DGPS 定位精度	0.4m
RTK 定位精度	1cm+1ppm
数据更新率	100Hz
输出电压	9~36VDC

GPS 的定位在地下车库、隧道等复杂环境下会受到建筑物遮挡、信号衰减等因素的影响，使得单独依赖 GPS 存在一定的局限性。为了弥补 GPS 传感器的不足，将 GPS 数据与如轮速里程计、IMU、激光雷达等进行数据融合，弥补 GPS 信号受限时的不足，提高 SLAM 算法建图精度和鲁棒性。

2.3 坐标系定义及转换原理

2.3.1 坐标系定义

在多传感器融合的 SLAM 系统中，移动平台搭载的不同传感器获取的数据通常以自身坐标系进行测量和表达。为了简化后端的数据融合，需要将来自不同传感器的数据统一到同一坐标系下，这个过程涉及到坐标变换，确保来自不同传感器的数据能够统一坐标系，从而实现数据在统一空间内进行融合。

移动平台搭载的各类传感器采用独立的坐标系进行数据采集与处理，如图 2-5 所示。这些坐标系的构建依据传感器的实际安装位置、空间取向及其物理工作机制。其中，激光雷达通过扫描机制获取基于激光雷达自身的坐标系下的点云数据。IMU 则基于其惯性原理，输出在其特定坐标系下的加速度与角速度数据。ODO 基于车轮的几何参数，提供机器人运动平台相对于初始位置的相对位移信息，其数据参考系建立在机器人本体坐标系中。而 GPS 的数据具有特殊性，其数据基于地球坐标系，通过精确的坐标变换方法实现与其他传感器数据的有效融合与互补。




图 2-5 各传感器坐标示意图

传感器的坐标变换通常包括旋转和平移两个步骤。激光雷达的数据一般以极坐标形式输出点云数据。在坐标系变换过程中，激光雷达与目标坐标系之间的对齐需要通过旋转与平移操作实现。首先需要构建一个旋转矩阵，该矩阵能

够将激光雷达坐标系的坐标轴与目标坐标系的轴对齐。并引入平移向量用于调整两者之间的位置关系，使激光雷达坐标系的原点与目标坐标系的原点重合。基于线性代数的变换方法，实现不同坐标系间的严格对齐，确保传感器数据的协调运作。在实际应用中，这种坐标系变换方法是实现多传感器融合的关键技术之一。

IMU 作为关键传感器，能够实时输出移动平台的加速度与角速度信号。这些信号需要进行复杂的信号处理与积分运算。对角速度信号进行单积分运算确定移动平台的姿态参数，对加速度信号进行两次积分运算，确定位移信息。通过基于积分的算法策略，实现对移动平台在空间中的相对位置与姿态的估计与准确定位。IMU 预积分的原理在 4.2 节进行了详细的叙述。预积分的位置信息和姿态数据通过旋转矩阵进行坐标变换，将 IMU 数据从 IMU 坐标系转换到目标坐标系。

ODO 提供移动平台相对于起始位置的位移和旋转信息，这些数据的获取基于移动平台的本体坐标系。将移动平台在载体坐标系下的位移信息与载体的姿态信息相融合并通过坐标变换转换到全局坐标系中，解算移动平台在全局坐标系中的位移，从而完成其在三维空间中的定位计算与状态估计。各传感器坐标变换示意图如图 2-6 所示。




图 2-6 坐标变换示意图

在 SLAM 系统中，坐标变换是实现高精度位姿估计与地图构建的关键步骤。通过旋转矩阵和平移向量对传感器数据进行坐标变换，实现了从传感器坐标系到大地坐标系的转换，确保数据能够在同一空间中进行有效融合，通过多种传

传感器数据的几何变换与融合，使得 SLAM 系统能够在复杂动态环境中实现高效、可靠的定位与地图构建。

2.3.2 位姿变换

在移动平台行驶过程中，精确求解移动平台在不同时刻的位姿状态变换是实现精确定位的关键^[62]。移动平台在行驶中存在位置与朝向的变化，关于移动平台位姿的描述主要包含旋转变换和平移变换。旋转变换描述了移动平台朝向的改变，通常通过旋转矩阵、欧拉角或四元数的方式进行表示。平移变换描述了移动平台的位移，平移变换常通过平移向量的方式进行描述。移动平台位姿变换示意图如图 2-7 所示。通过多种传感器对环境的实时感知，实现移动平台姿态的动态计算，为后续定位与建图提供了数据支持。




图 2-7 移动平台位姿变换示意图

由于移动平台搭载各传感器自身坐标系不同，需要对各传感器先进行坐标转换。再通过位姿变换将移动机器人从当前的坐标系转换到目标坐标系，移动平台位姿的变换可以通过一个旋转矩阵 R 和一个平移向量 T 来表示。对于一个点在当前坐标系中的位置 $P = [x, y, z]^T$ ，将其变换到目标坐标系后的位置 P' 可表示为：

$$P' = R \cdot P + T \quad (2-2)$$

式中 R 是一个 3×3 的正交矩阵，它描述了坐标系之间的旋转关系； $T = [t_x, t_y, t_z]^T$ 为三维向量，表示坐标系之间的平移。

然而，旋转矩阵 R 在描述三维框架旋转时较为复杂，导致计算效率较低，可以通过引入欧拉角的方法对空间坐标系旋转变换进行简化处理，通过将旋转矩阵九个数来表达的三维空间旋转简化为三个数的描述形式，但欧拉角俯仰角为 90° 或者 -90° 时，会出现万向锁问题，为了避免这个问题，可以采取四元数来描述旋转变换。

四元数主要应用在复杂计算以及数值不稳定的问题中，通过高效的表示和处理旋转关系，避免了欧拉角的万向锁问题。四元数的表达式如下所示：

$$q = w + xi + yj + zk \quad (2-3)$$

式中， w 是实部， x, y, z 是三个虚部， i, j, k 是虚数单位，满足下列关系式：

$$\begin{aligned} i^2 = j^2 = k^2 = ijk = -1 \\ ij = k, jk = i, ki = j \\ ji = -k, kj = -i, ik = -j \end{aligned} \quad (2-4)$$

无论是旋转矩阵、欧拉角还是四元数，都是位姿变换中不可或缺的工具。旋转矩阵形式直观，欧拉角运算简单而四元数在实时性、高效性和稳定性方面更具优势。在实际算法中，灵活选择表示方法，确保系统的鲁棒性和精度。

2.4 多传感器融合算法基本框架

2.4.1 点云预处理

本文激光雷达采用速腾聚创公司自主研发的 Helios 16 激光雷达，通过激光雷达扫描能够生成环境的三维点云数据。这些点云数据中包含了大量的环境信息，但也存在一些噪音、离群点和鬼影点，这些激光点增加了数据处理的复杂性，降低了地图构建和定位的效率，需要在点云预处理过程中进行优化。同时，三维激光雷达扫描周围环境过程中，由于移动平台的运动，雷达发出的各激光点的位置产生差异，进而造成点云的畸变^[63]。

针对上述问题，提出了一种结合 IMU 和 ODO 数据的点云校正方法。以解决移动平台在运动过程中激光雷达扫描数据出现的畸变问题。通过对 IMU 传感器提供载体的加速度和角速度信息进行积分计算，获得载体的位姿变化。同时，ODO 传感器提供载体的相对位移信息，系统通过融合 IMU 和 ODO 的数据，求解精确位移和速度信息。利用这些信息对每一帧点云数据进行插值处理，有效

减少了点云畸变。

通过将 IMU 和 ODO 数据融合计算得到的每一时刻激光点的变换矩阵，并将该变换矩阵应用于扫描过程中每个激光点数据，将激光点从当前坐标系转换到初始坐标系，从而去除由于载体运动产生的点云畸变。通过对点云的优化处理，提升了后续地图构建和定位的效率与鲁棒性，为移动平台的自主定位与环境感知提供可靠的基础。

2.4.2 点云配准

在 SALM 算法中，点云配准目的是实现不同坐标系下的点云关键帧的精确对齐。由于移动平台的实时运动，激光雷达采集的点云帧处于不同的坐标系，存在位姿、方向和尺度的差异。

为了构建全局一致性的点云地图，需要对激光点云数据进行配准，将关键帧点云统一到同一坐标系下^[64-65]。点云配准算法通过计算不同点云帧之间的变换关系，实现点云数据的精确对齐，构建高精度的三维环境地图，局部点云配准图如图 2-8 所示。




图 2-8 局部点云配准图

点云位姿优化是通过优化关键帧的位姿参数，提升地图构建和定位的精度。然而，这一过程通常涉及非凸优化问题，同时，初始矩阵的选择不当可能导致算法陷入局部最优解，影响系统性能。

为避免陷入局部最优解，采用正态分布变换（Normal Distributions Transform, NDT）算法是一种求解位姿变换的有效方法^[66]。NDT 算法流程如图 2-9 所示。




图 2-9 NDT 点云匹配算法流程图

NDT 算法通过将点云数据表示为多元高斯分布, 利用统计方法进行点云配准。将源点云和目标点云采用多元高斯分布模型表示, 通过最大似然估计计算两者最小配准误差。NDT 算法通常结合多分辨率金字塔结构, 通过在不同尺度下进行配准, 逐步细化优化结果, 从而增强了算法的鲁棒性和避免陷入局部最小值的能力, NDT 算法的点云划分方式有效提升了算法效率和匹配准确性, 进一步提高了算法的定位与建图精度。

2.4.3 回环检测

在 SLAM 系统中, 移动平台的位姿估计通常采用递推方式, 融合来自不同传感器的数据, 估计移动平台的位姿。位姿估计由于传感器噪声、环境变化、测量误差及计算精度等因素产生误差。并随着时间和空间的变化逐渐积累, 影响定位与建图精度, 降低 SLAM 系统的整体性能。

针对大规模场景中的误差累积问题, 通过引入回环检测 (Loop Closure Detection) 算法减少长距离移动平台的累计误差。通过识别当前位姿是否与历史位姿重合, 并添加约束条件优化位姿估计。

系统依赖激光雷达等传感器扫描周围环境, 生成点云数据, 并提取环境特征。通过比对当前特征与历史数据, 判断是否发生回环。如图 2-10 所示, 一旦

检测到回环，系统会增加约束条件，修正位姿估计，进而有效降低误差累积，显著提升 SLAM 系统的精度与地图构建质量。




图 2-10 回环检测示意图

相较于后端优化方法，回环检测在约束应用上具有更为紧凑、高效的优势。在 SLAM 系统中引入回环检测算法，不仅能够有效提升定位系统的精度，还能显著优化地图构建的整体效果。但传统的基于距离的回环检测算法存在计算量大，算法实时性低，针对传统算法的问题，创建 LIDAR SYM 描述子的回环检测方法^[67]，该算法的原理如图2-11所示，通过将关键帧点云简化为LIDAR SYM描述子，有效解决了传统回环检测算法计算量大，实时性不高的问题。




图 2-11 LIDAR SYM 原理示意图

基于 LIDAR SYM 描述子的回环检测，充分利用点云数据的几何信息并将其转化为图像化的特征，避免了传统方法中由于点云对齐误差导致的误差，更好地应对环境中的变化和传感器噪声^[68]，通过将关键帧点云转化为 LIDAR SYM 描述子，提高了回环检测的效率，消除了 SLAM 系统的累计误差。

2.4.4 图优化理论

在 SLAM 系统的多传感器融合过程中，通常会涉及非线性优化问题，而位姿估计的精度对整个系统至关重要。为提高估计精度，本文采用图优化方法，通过将优化问题表示为图结构，从而简化计算过程^[69]。如图 2-12 所示，图优化结构由特定形式的节点和边组成，其中圆形节点用于表示系统变量，矩形节点代表约束条件，而连接边则描述变量与约束之间的误差关系。基于这些变量和约束的相互作用，系统能够有效求解最优位姿状态估计。在求解过程中，将非线性优化问题^[70]转换为最小二乘问题^[71]，使求解过程更加高效。




图 2-12 图优化结构示意图

求解最小二乘问题时，常采用迭代优化方法，逐步逼近最优解。常见的迭代优化算法包含最速下降法^[72]、高斯-牛顿法^[73]和列文伯格-马夸尔特法（Levenberg-Marquardt, L-M）^[74]。其中，L-M 算法因其良好的收敛特性和鲁棒性，被广泛应用于优化求解。

最速下降法的基本思想是沿着当前估计点的梯度方向进行更新，并通过调整步长逐步优化目标函数。然而，由于该方法仅依赖于目标函数的一阶梯度，收敛速度较慢，且在接近局部极小值时可能出现锯齿现象，从而降低优化效率。相比之下，高斯-牛顿法利用最小二乘问题的结构特点，利用二阶近似加速收敛，减少了算法计算。尽管高斯-牛顿法在大多数情况下比最速下降法收敛更快，但其收敛速率仍为线性，且对初始估计的依赖性较强，若初始值偏差较大，可能

导致优化结果偏离最优解，甚至出现发散问题。

L-M 法是一种兼具高效性和稳定性的优化策略。在优化过程中，L-M 算法通过动态调整迭代参数，在梯度下降与二阶近似之间取得平衡，从而提升收敛速度和鲁棒性，使其成为解决非线性最小二乘问题的主流方法之一。L-M 方法相较于其它优化方法具有明显的优越性，在处理非线性优化问题时，它通过引入“置信域”概念，在每次迭代中调整步长，从而在保证收敛性的同时提高优化精度。L-M 方法会根据误差的大小动态调整置信域的范围，这使得它能够在不精确的初始估计下依然稳定收敛，在优化过程中克服了高斯-牛顿法可能导致的迭代发散问题。同时有效抑制了最速下降法在收敛阶段出现的振荡现象，确保在逼近极小值时保持稳定的收敛效率。

这种因子图优化策略不仅改善了系统的收敛速度与稳定性，还在保证高精度的同时提升了解算效率。通过 L-M 方法为移动平台提供了更加精准的位姿估计，同时有效提升了 SLAM 系统的整体性能表现。

2.5 本章小结

本章主要探讨了多传感器融合技术在 SLAM 中的应用原理，阐述了多种传感器的工作原理及其优缺点。通过结合点云预处理、回环检测、NDT 配准算法以及基于图优化框架的数据融合方法，提升了定位和建图的精度与鲁棒性。

在 2.1 小节中，主要叙述了多传感器融合算法在 SLAM 技术中的优越性。在 2.2 小节中，主要叙述了移动平台搭载的多种传感器的具体原理和优缺点。在 2.3 小节中，主要叙述了将各传感器坐标系统一到目标坐标系下的坐标变换原理，并详细叙述了移动平台的位姿变换原理。在 2.4 小节中对多传感器融合算法的关键步骤进行了原理的分析和优化，阐述了点云预处理方法及点云匹配算法的理论基础和实施流程。在回环检测算法研究中，设计了一种基于 LIDAR SYM 特征描述子的方法，提升检测精度。在后端优化部分，构建了图优化框架，采用因子图形式将多源传感器数据进行紧耦合，通过优化计算实现对移动平台位姿的精确估计。

第3章 基于多传感器融合的回环检测算法

3.1 激光点云数据预处理

激光点云数据通过三维激光雷达采集生成，在采集的原始点云数据中包含了大量的三维空间信息。然而，这些原始的点云数据会受到噪声、采样率、环境条件等因素的影响，导致在进行激光点云配准时引入额外的噪音，降低了点云配准的准确率和定位与建图的精度，甚至导致回环检测匹配失败，因此，去除原始点云数据中的离群点、噪音点，对于提高定位与建图精度至关重要。

三维激光雷达扫描频率较高，采集的原始点云数据存在信息冗余问题，为增强算法效率，采取体素下采样方法对点云数据进行优化。通过划分三维空间的体素并计算体素格子内的质心，显著减少激光点的数量，同时最大限度地保持原始点云的几何特征。体素滤波器能够提升数据处理的效率，还在一定程度上去除了噪声点及离群点，确保了后续处理的数据质量，体素下采样方法的流程如图 3-1 所示：




图 3-1 体素下采样方法示意图

首先将原始点云数据根据位置分配到三维空间中的边长固定的立方体(体素)中，单个体素中通常包含多个激光点。对于划分的每个体素利用质心法计算每个体素的质心点，并用这个新点取代体素内其他的数据点，体素滤波下采样法通过将点云划分为体素，并体素网格 $\mathcal{V}_i$ 内的点集，通过质心法计算其质心作为体素新点，质心法公式如 3-1 所示：

$$\hat{p}_i = \frac{1}{|\mathcal{V}_i|} \sum_{p \in \mathcal{V}_i} p \quad (3-1)$$

式中 $\mathcal{V}_i$ 为体素网格 i 内的点集， $\hat{p}_i$ 为体素的中心点， $|\mathcal{V}_i|$ 为体素内点的数量。

通过体素滤波下采样处理，降低了点云数据的密度和计算复杂度，并最大程度保持点云的几何特征，降采样法处理后的点云数据激光点分布均匀，点云特征保留完整，提高了后续点云的处理效率。

通过体素下采样的方法得到的对比图如图3-2所示，左侧为未降采样点云模型，右侧为使用体素下采样方法后的点云模型，对比得出体素下采样法在减少激光点数量的同时，点云的几何特征也得到了较好的保留。




图 3-2 体素下采样方法对比图

3.2 传统的回环检测算法

回环检测的目标是重识移动平台之前经过的位置，增加回环在大场景下对消除累计误差尤为重要。传统的回环检测方法主要分为基于距离匹配和基于特征匹配的回环检测算法，基于距离算法的原理图如3-3所示。




图 3-3 基于距离的回环检测示意图

目前主流的 SLAM 算法如 cartographer^[75]、LOAM^[76]、ORB-SLAM^[77]均采用基于距离的回环检测算法。

基于距离匹配的算法通过计算当前帧和历史帧之间的欧氏距离判断是否接近先前访问的位置，当两帧之间的距离满足设置的距离阈值 d ，则可能是回环。基于距离的匹配方法计算量相对较小，适用于较为简单的回环检测场景。回环检测的距离度量可以使用欧氏距离来衡量当前点云与历史点云之间的相似性，移动平台的位姿轨迹可以表示为 $\mathbf{X} = \{\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_n\}$ ，其中 $\mathbf{x}_i$ 表示移动平台第 i 帧的位姿，对于当前帧 $\mathbf{x}_t$ ，计算其与历史帧的欧氏距离，通过设置合理的距离阈值 d ，比较两帧的距离是否满足阈值，距离计算公式如 3-2 所示：

$$d_{th} = \sqrt{(x_t - x_h)^2 + (y_t - y_h)^2 + (z_t - z_h)^2} \quad (3-2)$$

若两帧距离 $d_{th} < d$ ，则使用点云配准算法，配准公式如下：

$$\mathbf{T}^* = \arg \min_{\mathbf{T}} \sum_i \|\mathbf{T} p_{t,i} - p_{h,j(i)}\|_2^2 \quad (3-3)$$

计算两帧点云的配准误差：

$$e = \frac{1}{N} \sum_{i=1}^N \|\mathbf{T}^* p_{t,i} - p_{h,j(i)}\|_2 \quad (3-4)$$

若 e 小于所设置的配准误差，则证明两帧点云满足回环约束，并将 $\mathbf{T}^*$ 作为回环约束因子引入到图优化框架中，对全局位姿进行优化。

基于距离的回环检测算法，要配准满足距离阈值的所有关键帧，计算量较大，同时该方法对初值敏感，长距离的累积误差会导致回环检测失败，难以应用于室外大场景下的回环检测。

基于特征匹配的回环检测方法主要依赖点云的特征提取、描述和匹配，并结合全局优化算法优化全局轨迹。通过体素滤波下采样处理后的激光点云数据保留了主要的几何特征，利用基于特征匹配的回环检测算法提取点云的曲率特征，用于识别点云数据中角点和面点的关键特征。

对于点云曲率的计算首先要选择距离小于 p_i 的邻域点集 $\mathcal{N}(i)$ ，并计算邻域点集 $\mathcal{N}(i)$ 的质心 $\bar{p}_i$ ，计算公式如 3-5 所示：

$$\bar{p}_i = \frac{1}{|\mathcal{N}(i)|} \sum_{p_j \in \mathcal{N}(i)} p_j \quad (3-5)$$

式 3-5 中, $|\mathcal{N}(i)|$ 为邻域点集的大小, p_j 为点集中的点, $\bar{p}_i$ 为点集的几何中心。

基于邻域点集 $\mathcal{N}(i)$ 和质心 $\bar{p}_i$, 计算协方差矩阵 C_i , 公式如下:

$$C_i = \frac{1}{|\mathcal{N}(i)|} \sum_{p_j \in \mathcal{N}(i)} (p_j - \bar{p}_i)(p_j - \bar{p}_i)^T \quad (3-6)$$

式 3-6 中 $(p_j - \bar{p}_i)$ 是点 p_j 相对于质心的偏移向量; $(p_j - \bar{p}_i)(p_j - \bar{p}_i)^T$ 是一个 3×3 的外积矩阵; C_i 协方差矩阵是对称矩阵, 描述了邻域点集的分布特性。

对 C_i 进行特征值分解, 得到特征值 $\lambda_1 \geq \lambda_2 \geq \lambda_3 \geq 0$ 和对应的特征向量 $\mathbf{v}_1, \mathbf{v}_2, \mathbf{v}_3$, 并通过特征值去点云曲率进行估计, 公式如下:

$$C_i = \frac{\lambda_3}{\lambda_1 + \lambda_2 + \lambda_3} \quad (3-7)$$

式 3-7 中 λ_3 反映了点集在法向上的变化程度, $\lambda_1 + \lambda_2 + \lambda_3$ 表示点集的总方差。

由于 $\lambda_3 \leq \lambda_2 \leq \lambda_1$, 以通过 $C_i > 0.01$ 的点作为关键特征点。通过构建曲率特征描述子, 利用曲率特征描述子构建历史帧数据库, 搜索与当前关键帧相似的候选帧, 历史帧搜索公式如下:

$$P_B = \arg \min_{P \in \mathcal{H}} D(\mathbb{F}(P_A), \mathbb{F}(P)) \quad (3-8)$$

式 3-8 中 $\mathbb{F}(P_A)$ 为当前帧点云描述子, $\mathbb{F}(P)$ 为历史帧点云描述子, D 为当前帧与历史帧之间的欧式距离, $\mathcal{H}$ 为历史帧集合。

通过对当前帧和候选帧的曲率特征进行匹配, 如图 3-4 所示, 提取紫色面点和绿色角点, 找出候选帧中最相似的历史帧, 添加回环约束优化全局位姿。




图 3-4 点云特征提取图

基于曲率特征匹配的回环检测算法能够在复杂环境中提供鲁棒的回环检测性能，但基于特征的回环检测算法依赖点云局部区域的几何结构，容易受到噪音的影响，导致对点云特征的误判。同时，特征提取的检测算法计算量巨大，导致 SLAM 系统运算效率较低，影响了 SLAM 系统的实时性能。

3.3 基于描述符 LIDAR SYM 的回环检测

在 SLAM 系统中，移动平台长时间的运行容易产生累计误差，回环检测算法是确保全局一致性的关键步骤。当 SLAM 系统中检测车子闭环时，系统通过点云配准方法计算两帧之间的相对位姿变换，并构建回环因子加入因子图优化框架中，提升定位和建图的精度。当路径的回环范围较小时，里程计的累积误差较低。此时，基于距离或特征的回环检测算法能够有效识别邻近历史关键帧中的回环候选帧^[78]。但随着系统运行时间的增加，存储的历史关键帧数量不断增加。若继续使用距离或者特征的检测算法进行回环搜索，会导致负载过大降低系统效率。此外，两帧之间的累计误差较大时，点云配准由于缺乏良好的初始值，容易陷入局部最优解，导致回环检测失败。

针对基于距离和特征的回环检测算法存在的问题，采取了一种基于 LIDAR SYM 描述子的回环检测算法，通过对关键帧点云二维投影并进行编码构建的方式，构建了一个鲁棒的描述子，有效地提高回环检测的效率和准确性。LIDAR SYM 描述子通过高效的特征表示，降低了计算负载，提高了回环检测的效率和室外大场景下的检测精度。

LIDAR SYM 描述子的构建过程涉及将单帧三维激光点云数据投影至传感器坐标系下的 XY 平面，提取关键特征。如图 3-5 所示，将点云分布聚焦于水平空间分布。 (x,y,z) 转换为极坐标 (ρ, θ) 其中 $\rho = \sqrt{x^2 + y^2}$ 表示点到原点的水平距离， $\theta = \arctan2(y, x)$ 表示点的方位角，基于极坐标系，根据方位角将点云划分为 S_N 个扇面，根据半径将点云划分为 R_N 个环，扇形区域与环形区域的交叉作用形成一个二维网格结构，共计 $S_N \times R_N$ 个格子，该网格能够有效地组织点云数据，使其具备一定的空间结构信息，每个格子对应于特定的 (ρ, θ) 范围，记为 $B(i, j)$ 。同时提取每个格子区域内点云的最大 Z 值，即该格子内的最高高度值，若格子区域内无点云则取零，通过对关键帧点云的分割处理，将三维点云数据投影到

二维平面。




图 3-5 点云投影分割示意图

本文使用的 S_N 为 50， R_N 为 20，由于点云是按固定间隔划分的，所以远离传感器的格子的物理面积比近的更大。但两者都被同等地编码到 LIDAR SYM 描述子的单个像素中。因此，扇形的划分方式弥补了由于远点稀疏导致的信息量不足问题，并剔除了附近的动态物体。使用每个格子内激光点云的最大高度来对格子赋值，并将空闲的格子赋值为零。通过这种方式得到了如图 3-6 所示的二维图，其中格子颜色越趋近红色则代表着该格子区域内最大高度越大，通过这种方式，LIDAR SYM 描述子被表示为一个二维矩阵 $D \in R^{R_N \times S_N}$ ，其中元素 $D(i,j)$ 对应于每个格子的最大高度。




图 3-6 LIDAR SYM 回环 z 轴信息

通过上述步骤，将三维关键帧点云数据转换为二维矩阵，通过比较两个点

云帧描述子之间的相似度来判断是否存在回环，对于两个关键帧点云描述符的相似度计算公式如 3-9 所示：

$$d_{\text{euclidean}}(SYM_i, SYM_j) = \sqrt{\sum_{k=1}^m \sum_{l=1}^n (SYM_i(k, l) - SYM_j(k, l))^2} \quad (3-9)$$

式 3-9 中 SYM_i 和 SYM_j 分别代表两个关键帧点云的 LIDAR SYM 描述子， m 和 n 分别代表了 LIDAR SYM 描述子矩阵的行数和列数。

LIDAR SYM 描述子融合了关键帧点云的全局结构信息，相较于基于距离和特征的回环检测方法，它对局部噪声和场景变化具有更强的鲁棒性。LIDAR SYM 描述子通过将关键帧构建成矩阵的数据结构降低了算法的计算量，提高了算法的高效性和鲁棒性。

3.4 本章小结

本章旨在优化 SLAM 算法的关键步骤，提升算法运算效率，提高定位与建图精度。在 3.1 小节中，针对原始点云数据中数据冗余和噪音点较多的问题，采用体素滤波下采样的降采样方法，降低了激光点数量、去除了噪音点和离群点，提高了建图效率。在 3.2 节介绍了传统的回环检测算法，详细叙述了算法的计算流程，针对传统的回环检测算法存在的计算量大、匹配精度低的问题，在 3.3 节介绍了基于 LIDAR SYM 描述子的回环检测算法，通过将三维点云进行二维编码的形式提高了检测的准确率和响应速度。因此，基于 LIDAR SYM 描述子的回环检测算法为多传感器融合算法提供了更高效的算法，并通过基于公开 KITTI 数据集和校园数据集进行测试实验，算法的建图效果和误差分析将在第五章实验部分进行展开。

第 4 章 基于多传感器融合的移动平台的 SLAM 算法

4.1 引言

在前面的章节中介绍了移动平台搭载的各类传感器的基本参数和工作原理，并通过坐标变换将各传感器转换到统一坐标系下，为后续各传感器数据的融合提供了保障，针对大场景长距离环境下移动平台位姿累计的问题，通过引入 LIDAR SYM 描述子的形式，进行回环检测算法，通过添加回环约束，降低了累计误差，提高了整体的建图效果，然而由于激光雷达的测量噪音和其它因素的影响，通过关键帧点云匹配算法解算出的位姿并不完全等同于移动平台的真实位姿，导致每次解算的位姿变换都引入了误差，这些误差随着时间和距离的推移不断累计，导致定位与建图出现“漂移”的情况。

针对位姿变换过程中的累积误差问题，本研究通过引入关键帧选取策略、IMU 与 ODO 联合预积分方法以及因子图优化策略，从多维度改进了 SLAM 算法的性能表现。这些策略的综合应用有效解决了定位精度及建图稳定性方面的问题，通过图优化的框架实现多传感器数据的有效融合，解决大场景下定位漂移和地图一致性问题。

在后端图优化模块中，以激光里程计生成的关键帧和子地图为基础，构建激光里程计约束网络。此外，系统集成了回环检测后的子地图信息、GPS 地理坐标约束，以及 IMU 和里程计的预积分约束，形成多维度的约束条件。通过非线性最小二乘优化方法，实现对 SLAM 系统的高精度位姿估计。为了应对原始点云数据扩大可能导致的计算负担，本章引入基于运动阈值的关键帧选取策略，通过动态选择关键帧和子地图，避免了密集或稀疏的节点分布，有效控制了优化问题的规模，从而保障了系统的运算效率。这种方法能够自适应地调整关键帧的选择，为后端图优化提供高质量的输入数据，同时在后端采取因子图的优化方式，充分挖掘多传感器数据的互补性，为复杂环境下的高精度位姿估计与地图构建提供了可靠的技术支撑。

4.2 IMU-ODO 预积分

4.2.1 IMU 与 ODO 测量模型

在移动平台的精确定位与建图系统中，IMU 和 ODO 作为两种核心传感器，具有独特的功能与优势，共同为实现高精度的位姿估计提供了关键支持。IMU 的主要功能是实时测量移动平台的角速度和加速度。通过对数据的定位解算以及旋转运动的处理为移动平台的位姿变换提供了可靠的支持。然而，IMU 传感器在应用过程中存在一定局限性。由于其测量数据容易受到噪声和偏置影响，长时间的积分计算会导致误差不断累积，从而显著降低定位精度。ODO 的主要功能是通过测量轮子的旋转圈数并结合轮径参数，精确计算机器人在前进方向上的位移。然而，ODO 的功能也存在局限性，ODO 传感器仅能提供沿前进方向的位移信息，而无法捕捉其他方向的运动或姿态变化。

针对 IMU 与 ODO 传感器各自的局限性，本章提出了一种 IMU-ODO 联合预积分融合方法，充分发挥两者的互补特性，提高定位精度并简化后端优化计算。通过在时间域内对 IMU 与 ODO 数据进行积分处理，消除时间间隔对观测数据的影响，提升位姿估计的稳定性与准确性。

在预积分过程中，IMU 提供的角速度与加速度数据用于计算相邻时间步长之间的相对旋转增量及位移变化。同时引入 ODO 传感器的里程信息对增量进行约束和优化，进一步抑制累积误差的影响。通过融合 IMU 与 ODO 传感器的优势，生成更精确的位姿估计结果，提高 SLAM 的定位与建图的精度。

IMU 与 ODO 的联合测量模型，提供了更加全面、精确的位置和姿态估计，从而支持高精度的定位与环境建图任务^[79]。在该模型中，IMU 依托其高频采样能力，能够实时获取角速度与加速度信息，对短时间内的细微运动变化响应迅速。相比之下，ODO 通过测量相对地面的累积位移，为长时间或远距离运动提供稳健的位移估计。联合测量模型通过将 IMU 的预测数据与 ODO 的校正信息相结合，显著提升了 SALM 系统的精度与可靠性。

IMU 的角速度和加速度数据在进行融合前需要先通过积分运算，生成移动平台位置和姿态的预测增量。随后将 ODO 提供的位移测量值作为外部校正因子，用于调整 IMU 积分结果中的累积误差。这种互补融合策略有效整合了 IMU 的

动态响应能力和 ODO 的长期稳定性，降低了单一传感器测量误差对系统性能的影响。

安装于移动平台上的 IMU 以实时方式输出当前时刻的角速度 $\omega(t)$ 和加速度 $a(t)$ ，传感器数据通常受到包含真值、白噪声和零偏误差的影响。IMU 的测量值如 4-1、4-2 所示：

$$\tilde{\omega}(t) = \omega(t) + b_g(t) + n_g(t) \quad (4-1)$$

式 4-1 中， $\tilde{\omega}(t)$ 为陀螺仪的测量值， $\omega(t)$ 为陀螺仪的真实值， $b_g(t)$ 为陀螺仪的零偏， $n_g(t)$ 为高斯白噪音，满足 $n_g(t) \sim N(0, \sigma_g^2)$ 。

$$\tilde{a}(t) = a(t) + b_a(t) + n_a(t) \quad (4-2)$$

式 4-2 中， $\tilde{a}(t)$ 为加速度计的测量值， $a(t)$ 为真实值， $b_a(t)$ 为加速度计的零偏， $n_a(t)$ 为高斯白噪声，满足 $n_a(t) \sim N(0, \sigma_a^2)$ 。

与此同时，ODO 的测量模型主要提供线速度信息 $v(t)$ ，其输出受标度因子和噪声的影响，可表示为：

$$\tilde{v}(t) = k_v \cdot v(t) + n_v(t) \quad (4-3)$$

式 4-3 中， $\tilde{v}(t)$ 为 ODO 的测量线速度， k_v 为标度因子， $v(t)$ 为真实线速度， $n_v(t)$ 为测量噪声，服从高斯分布 $n_v(t) \sim N(0, \sigma_v^2)$ 。

通过上述测量模型，IMU 数据经积分生成移动平台位置和姿态的初级估计，ODO 数据则通过标度校正和噪声滤波，为系统提供外部约束。IMU-ODO 联合测量模型的核心在于将这两类数据进行融合，通过图优化方法，综合估计机器人的位置 $p(t)$ 、速度 $v(t)$ 和姿态 $R(t)$ 等状态变量。

联合预积分方法不仅降低了 IMU 的漂移误差，还弥补了 ODO 在非平坦路面或轮胎打滑场景下的局限性。IMU 与 ODO 的联合测量模型通过科学建模与数据融合，充分利用了两种传感器的数据优势，为移动平台定位与建图提供了高效、精确的解决方案。

4.2.2 基于 IMU 与 ODO 联合预积分方法研究

在多传感器融合的定位与建图技术中，IMU 与 ODO 具有独特的功能和优点。针对 IMU 在预积分中产生的累计误差和 ODO 对环境依赖性的问题，本章引入联合预积分方法，将 IMU 和 ODO 的观测数据在时间维度上进行整合，生

成更稳定的位姿增量。联合预积分方法基于 IMU 的角速度和加速度数据，通过计算相邻时间 t_k 到 t_{k+1} 之间的相对位姿增量，其中包含求解旋转增量 $\Delta R_{k,k+1}$ 、位移增量 $\Delta p_{k,k+1}$ 和速度增量 $\Delta v_{k,k+1}$ 及旋转增量 $\Delta R_{k,k+1}$ 的计算基于角速度的积分，利用李群表示，其表达式为：

$$\Delta R_{k,k+1} = \exp \left(\int_{t_k}^{t_{k+1}} [\omega(t) - b_g(t) - n_g(t)]^\wedge dt \right) \quad (4-4)$$

式 4-4 中 $[\omega(t) - b_g(t) - n_g(t)]^\wedge$ 表示将三维向量转换为 3*3 的反对称矩阵。位移增量 $\Delta p_{k,k+1}$ 的计算基于加速度和速度的二重积分，其公式为：

$$\Delta p_{k,k+1} = \int_{t_k}^{t_{k+1}} \left[v(t) + \frac{1}{2} R(t) [a(t) - b_a(t) - n_a(t)] dt \right] dt \quad (4-5)$$

式 4-5 中 $v(t)$ 为速度； $R(t)$ 为当前姿态旋转矩阵，用于将加速度从传感器坐标系转换到世界坐标系； $a(t) - b_a(t) - n_a(t)$ 为加速度的真实值减去零偏和噪声。

速度增量 $\Delta v_{k,k+1}$ 的计算是基于加速度的积分，其公式为：

$$\Delta v_{k,k+1} = \int_{t_k}^{t_{k+1}} R(t) [a(t) - b_a(t) - n_a(t)] dt \quad (4-6)$$

将 IMU 的预积分结果组成一个位姿增量向量 $\Delta x_{k,k+1}$ ：

$$\Delta x_{k,k+1} = [\Delta R_{k,k+1}, \Delta p_{k,k+1}, \Delta v_{k,k+1}]^T \quad (4-7)$$

将 ODO 提供的位移增量 $\Delta d_{k,k+1}$ 作为外部校正因子，与 IMU 预积分结果进行融合。通过非线性优化方法实现 IMU 预积分与 ODO 预积分结果的融合，本文采取图优化的方法来实现两者的融合，使得误差项取得最小值，误差项公式如下：

$$e_{IMU} = \| \Delta x_{IMU} - \Delta x_{pred} \|_{P_{IMU}}^2 \quad (4-8)$$

式 4-8 中 Δx_{IMU} 为 IMU 预积分的位姿增量， Δx_{pred} 为基于运动模型的预测位姿增量， P_{IMU} 为 IMU 观测的协方差矩阵。

$$e_{ODO} = \| \Delta d_{ODO} - \Delta p_{IMU} \|_{P_{ODO}}^2 \quad (4-9)$$

式 4-9 中 Δd_{ODO} 为 ODO 提供的位移增量， P_{ODO} 为 ODO 观测的协方差矩阵。

本文提出的联合测量模型通过整合近百组 IMU 和 ODO 的离散观测数据，将其融合为一个整体观测量，从而有效降低减少了后端优化所需的计算资源，提升了优化效率，使 SLAM 系统在复杂环境下的实时性与稳定性得到显著增强。具体的优化目标函数可表示为：

$$J = \sum_k (\|e_{IMU,k}\|_{P_{IMU,k}}^2 + \|e_{ODO,k}\|_{P_{ODO,k}}^2) \quad (4-10)$$

式 4-10 中， $P_{IMU,k}$ 和 $P_{ODO,k}$ 分别为 IMU 和 ODO 观测的协方差矩阵，用以加权不同传感器的置信度。

通过优化该目标函数，系统能够在复杂动态环境中实现快速、精确的定位与建图。该联合测量模型在移动平台自动驾驶场景中，特别适用于城市道路、高速公路或非结构化环境下的实时定位与建图。IMU 能够快速响应移动平台的转弯、加速和减速动态，而 ODO 则确保长距离行驶的位移精度。结合预积分与优化框架，系统能够迅速处理传感器数据，满足移动平台在定位与建图中对实时性的严格要求。

IMU 与 ODO 的联合测量模型通过科学的数据融合与预积分技术，充分发挥了两种传感器的优势，为移动平台的定位与建图技术提供了高效、鲁棒的解决方案。并在大场景复杂动态环境下的定位精度和实时性表现优异，IMU-ODO 联合预计分方法不仅适用于自主移动平台，还可推广至智能机器人、自动驾驶汽车、无人机等领域，拓展了该方法的应用场景。

4.3 融合 IMU 数据去除点云畸变

4.3.1 点云畸变原因分析

在环境感知系统中，3D 激光雷达技术作为关键设备，在自动驾驶系统中扮演着重要角色。通过这种技术，传感器以旋转扫描的方式发射激光束，并接收其反射信号，从而构建环境的三维空间模型。这种精确的点云数据为自动驾驶平台的多项任务提供了基础支持，包括路径规划的精确性、障碍物的有效识别，以及环境地图的高效构建。然而在实际运行场景中，三维激光点云往往会因为移动平台的运动产生点云畸变，这直接影响感知精度和系统可靠性。

三维激光雷达点云产生畸变的主要原因为雷达通过旋转分时方式采集点云

数据时，通常假设移动平台处于静止状态。在这种理想情况下，激光雷达以固定轴心和恒定角速度旋转一周，生成的点云数据在二维平面内形成一个完整且闭合的圆形轨迹，反映了周围环境的静态几何特征。然而，在移动平台的实际运行场景中，平台通常处于直线前进、转弯、加速或减速等运动状态，甚至可能因道路颠簸产生震动。这种运动会使激光雷达在扫描周期内的不同时间点采集的点云数据位于不同的坐标系中，导致采集的点云数据时空不一致性。

移动平台搭载的三维激光雷达的扫描周期通常在几十毫秒到数百毫秒之间，在这一时间段内，如果车辆以一定速度或角速度移动，激光雷达发射的激光束会因平台的位移或姿态变化而偏离预期位置。导致点云数据在空间上出现拉伸、扭曲或偏移，破坏了点云的几何一致性。点云产生畸变的示意图如图4-1所示，当车辆直线前进时，点云沿运动方向拉长，形成椭圆形或不规则线状轨迹；当车辆原地旋转时，点云出现旋转扭曲，形成螺旋形或不闭合的轨迹。这种时空不一致性是点云畸变的最主要成因。自主移动平台的动态运动具有高度复杂性和多样性，进一步加剧了点云畸变的问题。




图 4-1 点云畸变示意图

当移动平台以恒定或变化的线性速度沿某方向移动时，激光雷达扫描的点云会因平台的位移而沿运动方向拉伸。当移动平台以角速度进行转弯或原地调整方向时，激光雷达的局部坐标系相对于全球坐标系发生动态旋转。扫描点因时间戳不同而对应不同的旋转角度，导致点云形成扭曲或不规则的轨迹，当移动平台角速度较大时，点云畸变更严重。当平台在加速或减速时，线性加速度会改变速度分布，进一步影响点云的采集位置。

为了满足移动平台在各种场景下的应用，对于非平坦路面的应用场景，平台可能因震动产生微小但快速的姿态变化，导致激光雷达扫描点在高度或水平

方向上出现随机偏移。这种随机扰动会使点云数据产生噪声或局部畸变。三维激光雷达的扫描过程是分时完成的，在一次扫描周期内，激光束以一定角度间隔逐点发射和接收反射信号。扫描周期内的每个点对应不同的时间戳，时间跨度可能达到几十毫秒甚至更长。若平台在这一时间段内产生运动，导致早期采集的激光点和晚期采集的激光点处于不同的空间位置，进而造成点云畸变。

针对移动平台在产生线性运动、旋转运动及震动时与激光雷达分时扫描的时序特性共同作用导致点云的畸变，本章通过引入高频 IMU 传感器采集的实时姿态和位置信息，与激光雷达数据进行时空校正，进而消除因移动平台运动引起的点云畸变。通过融合高频的 IMU 数据，实现高精度的畸变校正。

4.3.2 高频 IMU 与激光雷达的数据融合

在传感器数据采集过程中，IMU 与激光雷达的采样频率存在显著差异。IMU 的数据采集频率通常高达 100Hz 以上，相较之下，激光雷达的点云数据采集频率一般在 10Hz 至 50Hz 之间。这种频率差异导致传感器数据的时间戳无法实现精确对齐。在实际应用中，为实现高精度数据融合，需要采用有效的时间同步方法，将 IMU 的高频数据与激光雷达的点云数据按照时间序列进行对齐同步。通过将 IMU 数据映射至激光雷达点云数据的时间戳，实现两类传感器数据的高效融合与精确对齐。

本文采取时间戳插值法对 IMU 数据和激光雷达点云数据进行时间戳同步，将 IMU 数据和激光雷达数据的时间戳转换为相同的时间基准，来实现它们之间的数据对齐。使用时间戳插值法，将 IMU 的高频数据插值到激光雷达的采样时间点。插值法示意图如 4-2 所示。




图 4-2 时间戳插值法示意图

假设激光雷达点云数据的时间戳为 t_{lidar} ，而 IMU 的数据时间戳为 t_{imu} ，数据的采样频率为 f_{imu} ，激光雷达数据的采样频率为 f_{lidar} 。为了将 IMU 数据与激

光雷达点云对齐，需要选择一个参考时间点，通过插值将该时间点附近的 IMU 数据与激光点云数据对齐。对某一时间戳，IMU 的插值公式为公式 4-11 所示：

$$\mathbf{a}_{imu}(t_{lidar}) = \mathbf{a}_{imu}(t_{imu_1}) + \frac{(t_{lidar} - t_{imu_1})}{(t_{imu_2} - t_{imu_1})} (\mathbf{a}_{imu}(t_{imu_2}) - \mathbf{a}_{imu}(t_{imu_1})) \quad (4-11)$$

式 4-11 中 $\mathbf{a}_{imu}(t_{lidar})$ 是需要在 t_{lidar} 时刻得到的 IMU 数据， $\mathbf{a}_{imu}(t_{imu_1})$ 和 $\mathbf{a}_{imu}(t_{imu_2})$ 分别是与 t_{lidar} 最接近的两个 IMU 数据的加速度， t_{imu_1} 和 t_{imu_2} 是两个 IMU 数据的时间戳。

通过时间插值法，可以得到与激光雷达点云时间戳 t_{lidar} 对应的 IMU 数据，从而实现 IMU 数据与激光雷达数据的同步。

4.3.3 时间同步的误差及优化

时间戳插值法虽然简单有效，但其准确性受到传感器时间戳误差、插值精度等因素的影响。为了提高时间戳插值法的同步精度，提出了一种误差模型对同步过程中的误差进行建模和优化。IMU 和激光雷达的时间戳误差可以表示为：

$$\Delta t_{imu-lidar} = t_{imu} - t_{lidar} \quad (4-12)$$

式 4-12 中 $\Delta t_{imu-lidar}$ 为 IMU 与激光雷达数据时间戳之间的误差。

时间戳误差源可能来自于移动平台自身传感器的内部延迟以及移动平台工控机由于硬件同步不精确，导致的时间戳漂移。或由于操作系统调度的原因，导致传感器数据的时间戳存在偏差。为了校正以上因素带来的误差，引入了卡尔曼滤波 (Kalman Filter) 对这些误差进行降低，通过传感器数据输入和同步信息的不断更新，估计时间戳误差 $\Delta t_{imu-lidar}$ 。进而求解最小化时间戳同步误差，得到更加精确的同步结果。对于 IMU 和激光雷达的数据同步，引入卡尔曼滤波可以通过对系统状态进行估计，进一步减少同步误差。卡尔曼滤波的状态更新公式如 4-13、4-14 所示：

$$\hat{\mathbf{x}}_{k+1} = \mathbf{A}\hat{\mathbf{x}}_k + \mathbf{B}\mathbf{u}_k + \mathbf{w}_k \quad (4-13)$$

$$\mathbf{z}_k = \mathbf{H}\hat{\mathbf{x}}_k + \mathbf{v}_k \quad (4-14)$$

式 4-13 中 $\hat{\mathbf{x}}_k$ 代表滤波器的状态向量，用于表示时间戳误差， $\mathbf{A}$ 是状态转移矩阵， $\mathbf{B}$ 是控制矩阵， $\mathbf{u}_k$ 是系统的控制输入， $\mathbf{w}_k$ 表示过程噪声。

式 4-14 中 $\mathbf{v}_k$ 为观测噪声， $\mathbf{z}_k$ 是由激光雷达和 IMU 数据中观测到的时间戳误差。

IMU 与激光雷达点云数据的同步与融合是提高自动驾驶系统环境感知精度的关键。通过时间插值、同步误差建模、卡尔曼滤波等优化方法，可以有效地同步 IMU 和激光雷达数据，从而为后续的融合提供精确的时间基准。进一步提高 IMU 数据与激光雷达点云数据的融合，提升了定位精度和环境感知能力。

时间戳插值法将高频的 IMU 数据与点云数据进行同步，调整每个时间点上的激光点的位置，消除了移动平台由于运动产生的点云畸变，利用本文提出的去畸变算法的实验效果图如图 4-3 所示，左侧为未去畸变点云，红色框内为移动平台运动导致的未闭合点云轨迹，右侧为融合 IMU 数据去除运动畸变的点云图，通过对比本文提出的点云去畸变算法，融合高频 IMU 数据的去畸变算法成功的校正了移动平台在运动过程中产生的单帧点云畸变。




图 4-3 点云去畸变对比图

4.4 基于多传感器融合的 SLAM 算法

在搭载多种传感器的移动平台中，多传感器融合是实现高精度定位与建图的核心技术之一。通过整合惯性测量单元 IMU、激光雷达 LiDAR、轮速里程计 ODO、GPS 等传感器的数据，可以克服单一传感器在复杂环境下的局限性，如 IMU 的漂移、LiDAR 的动态障碍物干扰、ODO 长距离下的累计误差等。然而，多传感器数据通常涉及非线性关系，由于激光雷达点云配准、IMU 数据预积分等涉及复杂的非线性关系，直接求解全局最优解非常困难，因此需要通过优化方法求解最优位姿估计。本文采取图优化的方式将非线性优化问题转化为图的形式，将各传感器数据转换为因子，同时连接状态节点和因子节点，形成稀疏的因子图结构，将多传感器融合的非线性优化问题转化为最小二乘问题，并通

过迭代方法求解全局最优解。

4.4.1 关键帧选取

在 SLAM 系统的定位与建图中，若算法对每一帧点云数据都进行完整处理，会导致系统运行速度下降，难以满足系统的实时性要求。为此，本文引入关键帧机制，在算法效率与精度之间实现优化平衡。关键帧的选取策略至关重要：若间隔过大，局部地图的完整性可能受到影响，导致后续优化中的约束减少，从而降低系统的精度；若选取频率过高，则会增加计算负担，影响建图的实时性。因此，设计一种既稳健且高效的关键帧选取方法，成为提升 SLAM 系统性能的关键问题之一。

传统的关键帧选择方法通常以固定的间隔进行，例如每隔 5 帧或 10 帧选取一帧作为关键帧。该方法的实现简单，但在关键帧的分布上容易出现不均衡，缺乏稳定性。例如当平台移动速度过慢或静止时，固定间隔选取可能导致连续关键帧之间重叠度过高，产生冗余。或者移动平台停留在某位置，相邻关键帧的观测数据几乎相同，增加了无意义的计算。同时，关键帧的间隔也不能过大，如果平台移动速度过快时，相邻关键帧的点云数据差异显著，配准难度增加，甚至因特征不足而导致建图失败。固定间隔选取关键帧的策略忽略了车辆实际运动状态，无法自适应动态环境，在复杂场景中表现欠佳。

针对固定间隔选取关键帧策略的局限性，本章提出了一种基于移动平台位移和旋转变化的自适应关键帧选取策略。该方法通过监测车辆的相对运动状态，动态确定关键帧，兼顾效率与精度。本课题研究的移动平台主要的应用场景在较为开阔的室外环境，因此相对位移阈值 Δd_{th} 设为 1m，旋转角度阈值 $\Delta \theta_{th}$ 设为 5° ，作为关键帧选取的判定依据。以当前已保存的关键帧 f_k 作为基准，其位姿记为 $\mathbf{T}_k = [\mathbf{R}_k | \mathbf{p}_k]$ 。利用公式 4-15 对后续每一帧 f_{k+1} 计算其相对于基准帧的相对位移 $\Delta d_{k,k+i}$ ：

$$\Delta d_{k,k+i} = \|\mathbf{p}_{k+i} - \mathbf{p}_k\|_2 \quad (4-15)$$

后续每一帧 f_{k+1} 计算其相对于基准帧的相对旋转 $\Delta \theta_{k,k+i}$ 的计算公式为 4-16 所示：

$$\Delta \theta_{k,k+i} = \arccos\left(\frac{\text{trace}(\mathbf{R}_k^T \mathbf{R}_{k+i}) - 1}{2}\right) \quad (4-16)$$

对于每一帧 f_{k+1} 若 $\Delta d_{k,k+i} > 1\text{m}$ 或 $\Delta \theta_{k,k+i} > 5^\circ$ ，则将该帧设为新的关键帧，并舍弃两个关键帧之间的非关键点云帧，若 $\Delta d_{k,k+i} \leq \Delta d_{th}$ 且 $\Delta \theta_{k,k+i} \leq \Delta \theta_{th}$ 时则继续判断下一帧。

在多传感器融合算法中，逐帧处理点云数据虽能提供丰富信息，但计算复杂度高，难以满足实时性要求。基于运动阈值的关键帧选取策略，根据应用场景设定位移阈值 1m 和旋转阈值 5° ，动态评估帧间相对运动，自适应选取关键帧。这种方法克服了传统固定间隔策略的局限性，避免了关键帧过于密集或稀疏的问题。在效率与精度间取得平衡，为后续因子图优化提供了高质量的输入数据，提升了多传感器融合算法的整体性能。

4.4.2 图优化框架

因子图优化是实现多传感器紧耦合的关键，通过构建图优化框架，能够同时处理多传感器数据，实现对移动平台运动轨迹与环境地图的统一表达。在图优化框架中，每个因子对应一种观测约束，如激光雷达扫描、IMU 预积分数据、ODO 测量、GPS 定位以及回环检测结果。基于高斯噪声假设构建的误差函数，将所有观测联系起来，形成一个非线性最小二乘问题，从而达到全局一致性的优化目标。

在图优化框架中，每个因子将移动平台在各个时刻的位姿与传感器观测数据之间的关系进行数学建模，形成一系列残差项。采用列文伯格-马夸尔特法（Levenberg-Marquardt, L-M）迭代优化算法逐步降低这些残差，实现更精确的位姿估计。充分利用各传感器之间的互补优势，使 SLAM 系统在精度、实时性以及计算效率上得到显著提升。在保持全局一致性的前提下，通过最小化因子图整体误差，降低轨迹估计偏差与地图重构误差，为移动平台提供精确定位与建图。

因子图框架如图 4-4 所示，框架图中包含状态节点、里程计因子、预积分因子、GPS 因子以及回环因子，图中圆形代表移动平台状态量，蓝色正方形代表关键帧，绿色正方形代表非关键帧，里程计因子与 IMU 预积分因子为相邻两个关键帧提供帧间约束，黄色回环检测因子为两个回环点之间的关键帧提供约束，GPS 因子在某一时刻引入计算，为优化器中所有状态节点提供全局约束。




图 4-4 因子图框架示意图

基于图优化框架的多传感器融合 SLAM 算法的目标是求解状态变量合集 $\mathcal{X} = [x_1 \ x_2 \ x_3 \ \dots \ x_n]$ ，其中 x_i 表示第 i 个时刻的位姿，由于各传感器基于高斯噪声模型假设且观测量条件独立，通过因子与状态变量关联，求解 MAP 等价于求解非线性最小二乘问题，其目标函数如 4-17 所示：

$$\arg \min_{\mathcal{X}} \left\{ \sum_{i=1}^k \|r_P\|^2 + \sum_{i=1}^k \|r_O\|^2 + \sum_{i=1}^k \|r_L\|^2 + \sum_{i=1}^k \|r_G\|^2 \right\} \quad (4-17)$$

式 4-17 中， r_P, r_O, r_L, r_G 分别代表预积分因子、里程计因子、回环因子和 GPS 因子。

该公式的求解依赖于迭代方法，通过不断逼近误差最小值获得最优解。常见的迭代优化方法包括最速下降法、高斯-牛顿法以及列文伯格-马夸尔特法（Levenberg-Marquardt, L-M）。本文使用 2.4 所提出的列文伯格-马夸尔特法进行求解。

L-M 法通过引入阻尼因子，有效抑制了最速下降法中迭代路径的震荡现象；同时解决了高斯牛顿法可能出现的非奇异性问题，从而提升了优化过程的稳定性与收敛效率。L-M 法本质为信赖区域方法，通过对 Δx 的范围进行定义，从而限制 Δx 的大小。通过定义误差变化率 ρ 来判断结果近似是否准确，如 4-18 所示：

$$\rho = \frac{f(x + \Delta x) - f(x)}{J(x)\Delta x} \quad (4-18)$$

如果 ρ 较小，则需要缩小信赖区域，如果 ρ 较大，则需要增大信赖区域，通过迭代不断精确结果。L-M 算法的流程如下所示：

- (1) 定义状态变量 x_0 和半径 μ ，并引入初始阻尼因子 λ ；
- (2) 迭代法求解当前帧的误差向量 $f(x)$ 和雅可比矩阵 $J(x)$ ；
- (3) 求解增量方程 Δx : $(J(x)^T J(x) + \lambda I) \Delta x = -J(x) f(x)$ ；
- (4) 计算误差变化率 ρ ，并进行评估判断。若 $\rho > 3/4$ ，则减小阻尼因子 $\lambda \leftarrow 2\mu$ ；若 $\rho < 1/4$ ，则增大阻尼因子 $\lambda \leftarrow 1/2\mu$ ；
- (5) 若误差变化率 ρ 大于设定的阈值，则更新状态，公式如下：

$$x_{k+1} = x_k + \Delta x_k \quad (4-19)$$

- (6) 若结果收敛，则结束迭代，若结果不收敛，则转到步骤 2 继续计算雅可比矩阵和误差项。

4.5 本章小结

本章主要介绍了多传感器融合 SLAM 算法涉及的各类优化问题，重点阐述了图优化理论在数据融合优化中的关键作用。在 4.1 小节中，简要介绍了关键帧选取策略和多传感器融合优化对提高移动平台定位与建图的重要性。在 4.2 小节中，介绍了基于 IMU-ODO 联合预积分方法，设计了两种传感器数据的融合模型。在 4.3 小节中，介绍了激光雷达产生畸变的原因，引入高频 IMU 数据，通过时间戳插值法去除点云畸变。在 4.4 小节中阐述了基于距离的关键帧选取策略存在的不足之处，针对其局限性提出了一种基于运动阈值的关键帧选取策略。介绍了应用于 SLAM 算法后端优化的图优化框架和 L-M 法求解非线性最小二乘优化问题的具体实现过程。

本章设计的多传感器融合 SLAM 算法，以及在图优化与关键帧选择方面的创新设计，为实现移动平台的高精度与高效率定位与建图提供了更为高效和可靠的解决方案。

第 5 章 移动实验平台搭建与实验分析

5.1 移动实验平台搭建

本章通过实验验证第四章所提出的多传感器融合 SLAM 算法的有效性，实验验证基于搭载了激光雷达、IMU 和 GPS 的移动实验平台，图 5-1 展示了平台外观及各类传感器的安装示意图，测试平台参数如表 5-1 所示，主要硬件组件包括 BRAV-7521 工控机、三维激光雷达、IMU、ODO 以及 GPS 等设备。



图 5-1 移动实验平台

表 5-1 测试平台基本参数

设备	参数
整机尺寸	2040×1052×1750 mm
整车重量	300kg
电机	直流无刷电机 型号：M3508 P19
电池	型号：车规级磷酸铁锂电池 额定电压：48V 标准放电电流：4500mAh
车架结构	桁架式高强度车架片
最大车速	20km/h

移动实验平台 BRAV-7521 工控机用于对多传感器的各项数据融合计算，求解全局一致性位姿和三维地图构建，BRAV-7521 工控机的实物图如 5-2 所示，相关参数如表 5-2 所示，BRAV-7521 工控机构建 Linux 操作系统，搭载了 Ubuntu

18.04 操作系统，同时工控机可连接外部设备，便于实验数据采集及移动平台状态的实时控制与监测。




图 5-2 BRAV-7521 工控机

表 5-2 工控机参数

性能	参数
CPU	i7-9700
硬盘	256 G
RAM	16G
显卡	GTX1660
CAN 卡	PCM-26D2CA
显示器接口	HDMI

5.2 软件平台

本章实验环境基于 Ubuntu 18.04 操作系统，以机器人操作系统（ROS，Robot Operating System）为平台进行搭建。所有算法均采用 C++语言开发与调试。核心功能包包含 Rviz 可视化工具，实现传感器数据、机器人位姿以及生成的地图的实时可视化，为实验提供直观的数据展示；Gazebo 用于构建虚拟实验场景，支持算法在仿真环境中的验证与测试；TF 用于实现传感器间坐标系转换保各传感器，确保数据的统一性与一致性；ROSBAG 包用于储存和管理原始传感器数据；Rviz 可视化工具用于环境建模及调试系统参数，为算法优化和实验验证提供支持。

这些软件的协同工作，为实验提供了完整的功能支持，确保了实验结果的科学性和可靠性。

5.3 基于 KITTI 公开数据集的算法验证

5.3.1 公开数据集及仿真平台介绍

KITTI 数据集被公认为自动驾驶与 SLAM 算法研究领域最具权威性的公共数据集。该项目由德国卡尔斯鲁厄理工学院联合丰田工业大学共同资助，旨在为自动驾驶技术的进步奠定坚实的数据基础。KITTI 数据集包含长达 6 小时的真实交通场景记录，整合了多种经过精确校准与同步的传感器信息，例如雷达扫描、高精度 GPS 定位以及 IMU 惯性测量数据，使其成为国际上规模最为庞大的自动驾驶场景评估基准。

该数据集在多传感器融合与视觉、激光相关任务的性能评估中具有广泛应用，涵盖了视觉里程计、三维物体检测、激光里程计以及多传感器融合建图等领域。该数据集对三维激光雷达的相关任务提供了强有力的支持，包括高精度环境建模、动态物体检测与跟踪、以及基于激光雷达的定位与地图构建等。这些特性使得 KITTI 数据集成为车载环境下技术验证的宝贵资源。KITTI 数据采集平台如图 5-4 所示。



图 5-3 KITTI 数据集采集平台

KITTI 数据采集平台搭载的各传感器参数如表 5-3 所示。移动采集平台通过配备的各种传感器，实现在各种场景采集三维激光点云数据，KITTI 数据集中的点云数据中存在多种复杂场景，并伴随不同程度的遮挡与截断，展现了真实的复杂室外环境。

整个数据集包含城市场景、城市与郊区结合场景以及郊区场景，通过其丰富的内容和高质量的采集质量，KITTI 数据集为自动驾驶与多传感器融合研究提供了无可替代的作用。

表 5-3 KITTI 采集平台传感器参数

传感器	参数
Velodyne HDL-64E	20Hz,角分辨率为 0.09°,度水平视场 360°,垂直视场 26.8°,水平视场 360°
OXTS RT3003 组合导航系统	9 轴,100Hz,分辨率为 0.02 米,精度 0.1°
NovAtel SPAN-NEO V2 GPS	10 Hz
PointGray Flea2 彩色相机	一百四十万像素

本实验基于 Intel Core i5-12600KF 处理器进行搭建，硬件配置包括 Nvidia GeForce RTX4060 Ti 显卡和 16GB 内存，以确保 SLAM 算法的高效运行与数据处理能力。实验环境基于 Linux 操作系统，选择 Ubuntu20.04 版本作为运行平台，该系统因其良好的兼容性与完善的功能支持，成为当前主流 SLAM 算法开发的理想选择。

实验环境搭载基于 ROS Noetic 机器人操作系统，为提升数据处理与优化能力，实验过程中还采用了 PCL 点云处理库，用于高效处理三维点云数据。采用 OpenCV 计算机视觉库，提供丰富的图像处理及优化等功能。以及 Eigen 线性代数库，用于矩阵运算与优化，以及用于自动化编程的 make 构建工具。

5.3.2 算法精度评价指标

SLAM 的核心是运动估计问题，因此评估整体算法的准确性主要体现在对轨迹估计精度的衡量，即比较 SLAM 算法估计的轨迹 T_i^{esti} 和真实 T_i^{gt} 轨迹的差别，其中 $i=1, 2, \dots, N$ 。借助于开源工具 evo 工具包，轨迹误差的判断采用了绝对位姿误差 (Absolute Pose Error, APE) 来进行测评^[80]，APE 用于计算估计轨迹与真实轨迹在几何空间中的误差，能够有效衡量二者的全局一致性^[81]。轨迹的绝对位姿误差定义如下：

$$APE_{all} = \sqrt{\frac{1}{N} \sum_{i=1}^N ||\log_e(T_{g,i}^{-1} * T_{esti,i})^V||_2^2} \quad (5-1)$$

式 5-1, $\log_e$ 中表示对括号内部表达式对数映射。

式 5-1 可以刻画两条轨迹平移误差, 从而定义绝对平移误差 (Absolute Position Error, APE) 如 5-2 所示:

$$APE = \sqrt{\frac{1}{N} \sum_{i=1}^N ||trans(T_{g,i}^{-1} * T_{esti,i})||_2^2} \quad (5-2)$$

5.3.3 KITTI 数据集实验与分析

为了更加客观的验证本文提出的算法的建图误差, 并对提出的基于 LIDAR SYM 描述子的回环检测算法进行验证, 同时对算法在多种场景下的定位与建图效果进行验证, 本文选择公开数据集 KITTI 数据集上的 05、07、09 三个序列对算法进行测试与验证, KITTI 05、KITTI07、KITTI09 序列轨迹图与数据集相关参数如图 5-4、表 5-4 所示。




图 5-4 KITTI 数据集序列轨迹图

表 5-4 KITTI 数据集参数

实验序列	真值序列	总长 (m)	位姿数
1	05	2205.576	2761
2	07	694.697	1101
3	09	1705.051	1595

为了验证第三章基于 LIDAR SYM 描述子的回环检测算法的检测效果, 选取了均存在回环的 KITTI 数据集序列, 同时为了测试第四章提出的多传感器融合算法在各种复杂场景下的整体定位与建图精度, 选取了包含复杂城市环境的 KITTI05 序列和包含城市环形路的 KITTI07 序列以及包含郊区环境的 KITTI09 序列, 多种场景的选择提高了测试算法定位精度的客观性。

本节还分别通过 KITTI 数据集对主流的多传感器融合算法进行了误差实验

对比，本节具体的实验设计方案如 5-5 所示。




图 5-5 实验设计方案流程图

使用第三章提出的基于 LIDAR SYM 描述子的回环检测算法，在 KITTI 数据集上的建图效果如图 5-6 所示，在各序列数据集中均顺利完成回环检测，建图无重影和漂移现象，在回环较多的 05 序列中，顺利完成多个回环检测，验证了本文提出的针对关键帧点云转化为 LIDAR SYM 描述子的回环检测算法的准确性和鲁棒性。




图 5-6 点云图与数据轨迹对比图

为了验证本文提出的多传感器融合算法的定位与建图效果，将 ALOAM^[82]、

LIO-SAM^[83]两种主流算法与本文提出的多传感器融合算法 SYM-SAM 算法在 KITTI 数据集上进行对比实验。

本节实验采用 KITTI 数据集提供的真实轨迹信息 (Ground Truth)，并将其整理为 GT.txt 文件，作为轨迹的真实参考值。利用 evo 评估工具，对不同 SLAM 算法生成的轨迹进行可视化分析。ALOAM、LIO-SAM 与本文算法的在 KITTI07 序列下的轨迹对比图如图 5-6 所示。




图 5-6 07 序列下轨迹对比图

ALOAM 算法是基于 LOAM 算法的改进，通过融合 IMU 数据提升轨迹估计的精度，从图 5-6 的整体轨迹图可以看出 ALOAM 算法整体效果与真值估计较为接近，但在 Z 轴方向上出现了较大的误差，表明仅依靠激光雷达数据与 IMU 进行融合会产生较大的误差，LIO-SAM 是一种基于激光雷达与 IMU 紧耦合的多传感器融合算法，后端采用图优化框架融合 GPS 约束，使得在大场景下也能保障稳定的建图精度。

通过图 5-6 中 LIO-SAM 算法与本文的 SYM-SAM 算法的轨迹对比图可知，本文算法与 LIO-SAM 算法在 XY 方向上均保持较小的误差，但在 Z 轴方向上本文提出的 SYM-SAM 算法更加接近真值，在 Z 轴方向上也保持着较小的误差。

为进一步对比本文 SYM-SAM 算法的与主流算法的建图精度，将主流算法与本文提出的算法在城市复杂场景数据集 KITTI05 和郊区场景 KITTI09 场景下进行对比实验。轨迹对比图如图 5-7、图 5-8 所示。




图 5-7 05 序列下轨迹对比图




图 5-8 09 序列下轨迹对比图

对上述图进行结果分析,本文提出的 SYM-SAM 算法在关键区域上更加贴近于真实值,相较于 ALOAM 和 LIO-SAM 算法在 Y 轴的累积偏移误差更小,在关键区域更加贴近于轨迹真值,为了进一步验证算法的优化结果,对算法在公开数据集下的绝对轨迹误差进行评估。

在 SLAM 算法的性能评估中,以及在轨迹误差分析中, APE、Rmse、Median、Mean 和 Std 是常用的指标,用于量化算法估计的轨迹与数据集真实轨迹 (Ground Truth) 之间的误差^[84-85],其中 Rmse 是误差的均方根,能够评估估计轨迹与真实轨迹的平均偏差大小,Rmse 计算公式如 5-3 所示,能够反映出算法轨迹误差的总体分布。

$$\text{Rmse} = \sqrt{\frac{1}{n} \sum_{i=1}^n \| P_{\text{gt},i}^{-1} \cdot P_{\text{est},i} \|^2} \quad (5-3)$$

根据图 5-9 三种算法在 KITTI05 郊区数据集上绝对误差的对比图可以看出

SYM-SAM 算法相较于 ALOAM、LIO-SAM 算法具有更好的精度。




图 5-9 KITTI05 序列下绝对误差对比图

为进一步评估本文提出的多传感器融合算法在各类场景下的综合性能，采用了城市场景的 KITTI 07 数据集和郊区场景的 KITTI 09 数据集进行测试。同时，通过 evo 评估工具对各项指标进行了详细测量，实验结果如图 5-10 和图 5-11 所示，展示了绝对误差的对比分析。




图 5-10 KITTI 07 序列下绝对误差对比图




图 5-11 KITTI 09 序列下绝对误差对比图

根据图 5-10、5-11 可以看出,在城市复杂场景和郊区退化场景下,提出的 SYM-SAM 算法的各项参数均优于主流算法 ALOAM 和 LIO-SAM,这一结果充分证明了 SYM-SAM 算法在各应用场景下的优异性能,实现了更稳定的轨迹跟踪,实现更加精确的建图效果。

为了更直观地评估优化前后的绝对轨迹误差,本节记录了三种算法在每个测试序列中预测值与真实值之间的差异。通过计算包括最大差(Max)、平均差(Mean)、中位数(Median)、最小差(Min)、均方根误差(RMSE)和标准差(Std)在内的多项指标,这些数据量化了主流算法在定位精度方面的表现。误差统计结果如表 5-5、表 5-6、表 5-7 所示。

表 5-5 KITTI 数据集 05 序列建图精度

算法	Max	Mean	Median	Min	Rmse	Std
ALOAM	39.96	2.27	1.71	0.66	4.16	3.49
LIO-SAM	8.93	2.21	1.75	0.69	2.65	1.47
SYM-SAM	2.19	1.06	1.04	0.14	1.15	0.43

表 5-6 KITTI 数据集 07 序列建图精度

算法	Max	Mean	Median	Min	Rmse	Std
ALOAM	8.92	2.21	1.75	0.68	2.65	1.47
LIO-SAM	3.28	1.31	1.00	0.10	1.51	0.77
SYM-SAM	1.09	0.55	0.57	0.08	0.61	0.27

表 5-7 KITTI 数据集 09 序列建图精度

算法	Max	Mean	Median	Min	Rmse	Std
ALOAM	19.31	7.09	4.82	0.37	9.17	5.82
LIO-SAM	2.18	1.06	1.04	0.14	1.15	0.43
SYM-SAM	0.85	0.44	0.40	0.17	0.48	0.18

表 5-5、表 5-6、表 5-7 分别列出了三种算法在 KITTI 05、KITTI 07、KITTI09 数据集的误差指标上的性能对比。实验结果表明，相较于 ALOAM 和 LIO-SAM 等主流 SLAM 算法，本文提出的 SYM-SAM 优化算法在公开数据集上的表现更加优越。实验结果表明，SYM-SAM 算法在绝对轨迹误差方面实现了显著优化。在 KITTI 数据集的 05、07、09 序列中，与当前性能最优的 LIO-SAM 算法相比，SYM-SAM 算法的各项误差指标均表现更优，平均误差分别降低了 1.15、0.76 和 0.62，均方根误差分别减少了 1.50、0.90 和 0.50，标准差误差分别下降了 1.04、0.67 和 0.25。这些结果充分表明，SYM-SAM 算法在轨迹估计和地图构建的精度方面具有显著优势，且与真实场景的匹配度更高，进一步验证了其优越性。

实验结果进一步验证了 SYM-SAM 算法在多传感器融合环境下的优异性能。通过融合激光雷达、IMU、ODO 及其他传感器的数据，SYM-SAM 算法进一步降低了建图误差，有效解决了单一传感器在运动中产生的几何畸变和噪声干扰问题，提升了系统的稳定性和可靠性。不仅增强了 SLAM 系统在复杂环境中的适应能力，还为实现高精度定位与建图提供了更优的解决方案。

5.4 校园场景下的实车实验

本研究工作围绕所提出的多传感器融合 SYM-SAM 算法，开展了实车测试，并对实验结果进行了全面记录与深入分析。在校园场景中，实车采集了来自机械学院实训楼、花坛、停车场以及周围车辆等多种复杂环境下的数据集。数据采集区域如图 5-12 所示。该区域涵盖了大场景下的多样物体类型，这种环境的多变性不仅增加了算法验证的挑战，也为 SYM-SAM 算法提供了更加丰富且接近实际应用场景的测试条件。

通过在这一具有挑战性的环境中进行测试，能够评估该算法在复杂场景下的稳定性、精度和鲁棒性，从而为 SLAM 技术在现实应用中的推广与优化提供有力支持。



图 5-12 校园数据集采集区域

图 5-13 展示 SYM-SAM 算法在校园场景中的建图效果。通过点云地图可以看出，该算法在构建校园大场景地图时，对局部细节的呈现较为精准。在建筑物的边缘提取方面，该算法能够精准捕捉建筑轮廓，生成的点云地图与实际场景高度吻合。针对大场景环境，算法通过准确识别回环点，有效抑制了地图漂移现象，进一步体现了算法的高精度定位能力。在开阔区域，如道路和草坪场景中，算法表现稳定，地图中道路边界清晰，草坪分布明确，未出现重影或不连续现象，充分验证了该算法在复杂环境下的稳定性和鲁棒性。




图 5-13 校园数据集建图效果

图 5-14 为 SYM-SAM 算法在校园转角处的建图效果。从点云图中可以看出，转弯处的建图精准，道路识别准确，教学楼轮廓得到了很好的还原，减少了建图时误差和失真。




图 5-14 校园数据集建图局部细节图

图 5-15 为本文算法在校园采集大场景中左侧停车场的实景图，此场景中，有较为低矮的灌木丛、车辆以及树木。图 5-16 为停车场点云图，从停车场点云图中可以看出本文所提出的 SYM-SAM 算法中基于 SYM 描述子的回环检测算法顺利检测出回环，降低了建图误差，车辆识别准确，灌木丛轮廓也得到了很好的还原，本文算法基于多传感器融合框架，有效融合了多种传感器信息，使场景中的各类物体及道路的走向得到了很好的还原。



图 5-15 校园停车场实景图




图 5-16 校园停车场点云细节图

5.5 本章小结

本章对所提出的多传感器融合 SYM-SAM 算法进行了系统性的实验验证，并对实验结果进行了详尽的记录与分析。5.1 节着重介绍了实验所采用的移动测试平台的关键参数配置；5.2 节详细描述了实验中所使用的软件平台及其核心工具包；5.3 节通过公开数据集的仿真验证，对本文算法与现有主流多传感器融合 SLAM 算法进行了全面对比，实验结果表明，本文提出的算法在定位精度和系统鲁棒性方面均具有一定优势；5.4 节通过校园场景的实际建图应用，进一步验证了 SYM-SAM 算法在多传感器融合系统中的性能提升，充分体现了该算法在复杂实际环境中的建图精度和鲁棒性。

第 6 章 总结与展望

6.1 总结

本文的研究聚焦于通过多传感器融合优化 SLAM 框架，通过融合 IMU 数据、创建 IMU-ODO 联合预积分模型与后端图优化框架，融合多种传感器数据进一步提高定位与建图的精确性和鲁棒性，具体工作如下：

(1) 进行了基于点云体素滤波的下采样处理，解决了激光雷达采集的点云数据的冗余，以及大量噪音点和离群点造成地图畸变的问题。有效减少了冗余点云，去除了噪音点和离群点，缓解了点云密集性对地图精度的影响，为后续的点云处理提供良好的初始值。

(2) 融合了高频 IMU 数据，对运动产生的点云畸变进行补偿，消除因为移动平台运动产生的点云畸变。解决了单一传感器去畸变校正方法精度低，点云校正不佳的问题，显著提升点云数据的质量，优化后的点云数据为后续的建图与优化奠定了坚实基础。

(3) 设计了基于 LIDAR SYM 描述子的回环检测算法，将关键帧点云简化为矩阵，解决了基于距离和特征的回环检测算法计算效率低、鲁棒性差的问题，通过对关键帧点云进行转化与相似性比较，提高了回环检测的效率和准确率。该方法在复杂环境下回环检测的效率更高，误检率降低，为后续多传感器融合算法的优化提供了关键支持。

(4) 设计了一种基于因子图优化的多传感器融合策略，通过多传感器融合框架，将激光雷达里程计信息、回环检测约束及 GPS 数据进行有效融合，提升了地图的细节还原能力，增强了系统在复杂环境的适应性，解决了复杂场景下单一传感器因感知范围和数据类型局限性的问题。为自动驾驶系统在实际场景的可靠运行提供了理论与实践依据。

(5) 搭建了实车验证平台，通过公开 KITTI 数据集对本文设计的算法与主流算法进行实验对比分析，并在校园大场景中进行实车建图，验证了本文设计的多传感器融合算法在定位与建图上的优越性。相较于主流算法，本文算法建图效果更贴合真实环境，为自动驾驶领域提供了高精度的 SLAM 技术。

6.2 展望

本文主要使用多传感器融合 SLAM 技术对室外复杂场景下的精确定位与环境感知进行了深入研究。通过体素滤波下采样、IMU-ODO 联合预积分、高频 IMU 信息融合去畸变、构建新的回环检测描述子等一系列处理，提高建图的精度，通过因子图框架融合多源信息以提高系统鲁棒性。但由于时间和硬件限制原因本研究还有许多能够改进和优化的空间，具体如下所示：

（1）本文提出的回环检测算法可以进一步改进，本文提出的基于 LIDAR SYM 描述子的构建通过将点云投影到 XY 平面，通过提供每个扇形区域内的最大高度信息进行编码，这种检测算法在建筑物密集环境下，容易导致描述子相似度较大，造成误匹配，未来研究可以探索利用激光点云强度信息，提高各关键帧描述子的差异性，提高在复杂环境下回环检测的响应速度，降低误检率。

（2）本文提出的基于三维激光雷达的多传感器融合技术，能够在各种环境下提高稳定的定位与建图精度，但激光雷达数据缺少语义信息，同时在复杂环境往往对算法的需求更高，后续研究中可以探索基于视觉传感器与激光传感器相结合的激光 SLAM 系统。

参考文献

- [1] 臧维,张延法,徐磊.我国人工智能政策文本量化研究——政策现状与前沿趋势[J].科技进步与对策, 2021,38(15): 10-15.
- [2] Jiang S, Wang S, Yi Z, et al. Autonomous Navigation System of Greenhouse Mobile Robot Based on 3D Lidar and 2D Lidar SLAM[J]. Frontiers in Plant Science, 2022, 13: 218-256.
- [3] Girerd C, Kudryavtsev A V, Rougeot P, et al. SLAM-based Follow-the-Leader Deployment of Concentric Tube Robots[J]. IEEE Robotics and Automation Letters, 2020, 5(2): 1-1.
- [4] Yoshida K, Hojo M, Fujino T. Adversarial Scan Attack against Scan Matching Algorithm for Pose Estimation in LiDAR-Based SLAM[J]. IEICE Transactions on Fundamentals of Electronics, Communications and Computer Sciences, 2022, E105.A(3): 326-335.
- [5] Ismail H, Roy R, Sheu L-J, Chieng W-H, Tang L-C. Exploration-Based SLAM (e-SLAM) for the Indoor Mobile Robot Using Lidar[J]. Sensors, 2022, 22(4): 16-39.
- [6] Li L, Lin YL, Zheng NN, et al. Artificial intelligence test: a case study of intelligent vehicles[J]. Artif Intell Rev, 2018, 50(3): 441-465.
- [7] Taheri H, Zhao. SLAM; definition and evolution[J]. Engineering Applications of Artificial Intelligence, 2021, 97(1): 104032.
- [8] Lajoie P, et al. Towards Collaborative Simultaneous Localization and Mapping: a Survey of the Current Research Landscape[J]. Field Robotics, 2021, 2: 971-1000.
- [9] Hess M, Ferreyra C. Recording And Comparing Historic Garden Architecture Value Of SLAM-Based Recording For Research On Cultural Landscapes In Connection With Heritage Conservation[J]. The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences, 2021,

XLVI-M-1: 301-308.

- [10] 沈斯杰,田昕,魏国亮,袁千贺.基于 2D 激光雷达的 SLAM 算法研究综述[J]. 计算机技术与发展, 2022, 32(1): 13-18.
- [11] 左晋,张皓,远子涵,樊垚淼.移动机器人 SLAM 发展现状综述[J]. 北京印刷学院学报, 2023, 31(6): 30-32.
- [12] 黄泽霞,邵春莉.深度学习下的视觉 SLAM 综述[J]. 机器人, 2023, 45(6): 756-768.
- [13] Lai T. A Review on Visual-SLAM: Advancements from Geometric Modelling to Learning-Based Semantic Scene Understanding Using Multi-Modal Sensor Fusion[J]. Sensors, 2022, 22(19): 65-72.
- [14] Bonnabel S. Symmetries in observer design: review of some recent results and applications to EKF-based SLAM[J]. Robot Motion and Control, 2012, 422:3-15.
- [15] 张洪,于源卓,邱晓天.基于改进关键帧选择的 ORB-SLAM2 算法[J]. 北京航空航天大学学报, 2023, 49(1): 45-52.
- [16] Keitaanniemi A, Rönholm P, et al. Drift analysis and sectional post-processing of indoor simultaneous localization and mapping (SLAM)-based laser scanning data[J]. Automation in Construction, 2023, 147:104700.
- [17] Ge G, Zhang Y, Wang W, Wang Q. Medical Mobile Robot Localization in Hospital Corridor Environment Using Laser SLAM and Text Features[J]. Journal of Imaging Science and Technology, 2022, 66(4): 40412.1-40412.14.
- [18] Mu Q, Wang Y, Liang X, et al. Autonomous Localization and Mapping Method of Mobile Robot in Underground Coal Mine Based on Edge Computing[J]. Journal of Circuits, Systems and Computers, 2024, 33(01): 245-266.
- [19] Xinyue F, Kai W, Shuai C. RB-SLAM: visual SLAM based on rotated BEBLID feature point description[J]. 中国邮电高校学报:英文版, 2023, 30(3): 1-13.

- [20] Jiang Y, Wang T, et al. 3DSLAM based on NDT matching and ground constraints for ground robots in complex environments[J]. Industrial Robot, 2023, 05(2): 01-28.
- [21] 张明,章国宝,朱宏伟.融合 IMU 信息的三维激光 SLAM 方法[J]. 电子科技, 2023, 36(6): 27-33.
- [22] Lee C, Peng J, Xiong Z. Asynchronous Fusion of Visual and Wheel Odometer for SLAM Applications[C] //2020 IEEE/ASME International Conference on Advanced Intelligent Mechatronics (AIM). IEEE, 2020, 1990-1995.
- [23] Liu, et al. Bidirectional Trajectory Computation for Odometer-Aided Visual-Inertial SLAM[C] //International Conference on Robotics and Automation. IEEE-Inst Electrical Electronics Engineers, 2021 vol. 6, 1670-1677.
- [24] 刘泽宇,李大伟,张博轩,等. 一种基于 SLAM 和 GPS 定位系统定位切换的方法[P]. 北京市:CN2023 10654178.7,2023-08-29.
- [25] Wang Y, et al. EIL - SLAM: Depth enhanced edge based infrared-LiDAR SLAM[J]. Journal of Field Robotics, 2022, 39(2):117-130.
- [26] 倪安庆,李军.全球导航卫星系统惯性导航系统组合导航的算法综述[J]. 装备机械,2023,(01):4-8.
- [27] 苏越.基于卡尔曼滤波的货车状态信息估计研究综述[J].中国物流与采购,2023,(19):55-56.
- [28] Civera J, Grasa O G, Davison A J, et al. 1 - Point RANSAC for extended Kalman filtering: Application to real - time structure from motion and visual odometry [J]. Journal of field robotics, 2010, 27(5): 609-631.
- [29] 胡士强,敬忠良.粒子滤波算法综述[J].控制与决策,2005,(04):361-365+371.
- [30] Montemerlo M, Thrun S, Koller D, et al. FastSLAM: A factored solution to the simultaneous localization and mapping problem [C]. AAAI/IAAI, 2002: 593-598.
- [31] Montemerlo M, Thrun S, Koller D, et al. FastSLAM 2.0: An improved

- particle filtering algorithm for simultaneous localization and mapping that provably converges [C]. IJCAI, 2003: 1151-1156.
- [32] 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.
- [33] Lu F, Milios E. Globally consistent range scan alignment for environment mapping [J]. Autonomous robots, 1997, 4: 333-349.
- [34] Konolige K, Grisetti G, Kümmerle R, et al. Efficient sparse pose adjustment for 2D mapping [C]. IEEE/RSJ International Conference on Intelligent Robots and Systems, 2010: 22-29.
- [35] Hess W, Kohler D, Rapp H, et al. Real-time loop closure in 2D LIDAR SLAM [C]. IEEE international conference on robotics and automation (ICRA), 2016: 1271-1278.
- [36] 孙作雷. 大规模不规则环境中的移动机器人定位与地图构建 [D]; 上海交通大学, 2010.
- [37] 宋春林. 基于激光测距仪的移动机器人 SLAM 研究与实现 [D]; 哈尔滨工业大学, 2014.
- [38] Liu Z, Zhang F. Balm: Bundle adjustment for lidar mapping [J]. IEEE Robotics Automation Letters, 2021, 6(2): 3184-3191.
- [39] Xu W, Zhang F. Fast-lio: A fast, robust lidar-inertial odometry package by tightly-coupled iterated kalman filter [J]. IEEE Robotics and Automation Letters, 2021, 6(2): 3317-3324.
- [40] Xu W, Zhang F. Fast-lio: A fast, robust lidar-inertial odometry package by tightly-coupled iterated kalman filter [J]. IEEE Robotics and Automation Letters, 2021, 6(2): 3317-3324.
- [41] 王阳. 基于图优化的移动机器人 SLAM 建图算法研究 [D]; 浙江大学, 2022.
- [42] 张迅,李锦江.自动驾驶相关数据集研究综述[J].中国设备工

- 程,2021,(01):255-256.
- [43] 丁林祥,陶卫军.ROS/Gazebo 在 SLAM 算法评估中的应用[J].兵工自动化,2022,41(04):87-92.
- [44] 袁丹鹤,杜玉晓,江鑫,等.基于 ROS 的人形机器人建模与仿真[J].自动化与信息工程,2020,41(6): 6-12.
- [45] 朱建军,王明园,张博文.基于 ROS 的轮式机器人建模方法与仿真研究[J].吉林化工学院学报,2021,38(3): 61-65.
- [46] 张福斌,张炳烁,杨玉帅.基于单目/IMU/里程计融合的 SLAM 算法[J].兵工学报,2022,43(11): 2810-2818.
- [47] 何骞,常乐,吴幼丝.基于预积分的 IMU/ODO 外参估计[J].测绘通报,2021,(4): 68-73.
- [48] 祝甜一.基于 ROS 的自主式救援机器人 SLAM 和导航系统研究[D].南京:东南大学,2015.
- [49] 邹贵豪,叶金鑫,梁嘉钰.基于 ROS 的自动驾驶小车的设计[J].电子世界,2019,(9): 143-144+147.
- [50] 李皓,范玉卿,刘豪杰.基于体素栅格滤波的点云地图处理方法[J].电子制作,2021,(13): 45-48.
- [51] 郭张翔,闫天红,周国强.3D 点云数据处理方法研究进展[J].计算机科学,2024,51(S2): 206-218.
- [52] SLAM Overview: From Single Sensor to Heterogeneous Fusion[J]. Robotics & Machine Learning Daily News, 2022, (27): 43-44.
- [53] 蒲文浩,刘锡祥,陈昊,等.多传感器融合的激光雷达点云矫正与定位方法[J].激光与光电子学进展,2023,60(24): 275-282.
- [54] Panda M, Das B, Subudhi B B, et al. A comprehensive review of path planning algorithms for autonomous underwater vehicles[J]. International Journal of Automation and Computing, 2020, 17(3): 295-310.
- [55] Lee G, Moon B C, Lee S, et al. Fusion of the SLAM with Wi-Fi-Based Positioning Methods for Mobile Robot-Based Learning Data Collection,

- Localization, and Tracking in Indoor Spaces[J]. Sensors, 2020.
- [56] 张振尧, 郑建英, 徐浩, 等. 基于路侧 LiDAR 的自动背景构建与目标检测[J]. IEEE Transactions on Intelligent Transportation Systems, 2019.
- [57] 王德志. 激光雷达原理[J]. 科协论坛(下半月), 2008, (5): 40.
- [58] 周俞辰. 基于激光三角测距法的激光雷达原理综述[J]. 电子技术与软件工程, 2016, (19): 94-95.
- [59] 徐爱功, 高佳鑫, 隋心, 等. 惯性测量单元辅助的 LiDAR 动态点云剔除方法[J]. 测绘科学, 2023, 48(5): 173-182.
- [60] 白师宇, 赖际舟, 吕品, 等. 基于 IMU/ODO 预积分的多传感器即插即用因子图融合方法[J]. 中国惯性技术学报, 2020, 28(5): 624-628+637.
- [61] 刘大杰, 施一民, 过静珺. 全球定位系统(GPS)的原理与数据处理[M]. 上海: 同济大学出版社, 1996.
- [62] 曲铁军, 任顺清, 陈希军. 姿态变换矩阵性质的研究[J]. 宇航计测技术, 2004, 24(4): 6-17.
- [63] Li Q. A study of correction to the point cloud distortion based on MEMS LiDAR system[J]. Applied Sciences, 2021, 11(5): 2418-2429.
- [64] Pomerleau F, et al. A review of point cloud registration algorithms for mobile robotics[J]. Foundations & Trends in Robotics, 2013, 4(1): 92-104.
- [65] Stechschulte J, Ahmed N. Robust low-overlap 3-D point cloud registration for outlier rejection[C]// Proceedings of the 2019 IEEE International Conference on Robotics and Automation (ICRA). IEEE, 2019: 1209-1215.
- [66] Zhu J, Wang D, Mu J, et al. 3DMNDT: 3D multi-view registration method based on the normal distributions transform[J]. IEEE Transactions on Automation Science and Engineering, 2021, 21(4): 488-510.
- [67] 韩超, 陈敏, 黄宇昊. 基于全局特征描述子的激光 SLAM 回环检测方法[J]. 上海交通大学学报, 2022, 56(10): 1379-1387.
- [68] Wang Y, Sun Z, Xu C Z, et al. LiDAR Iris for loop-closure detection[C]// Proceedings of the IEEE International Conference on Intelligent Robots and

- Systems (IROS). IEEE, 2020: 105-118.
- [69] Chang L, Niu X, et al. GNSS/INS/LiDAR-SLAM integrated navigation system based on graph optimization[C]// Remote Sensing, 2019, 11(9): 1009-1016.
- [70] 袁亚湘. 非线性优化计算方法[M]. 北京: 科学出版社, 2008.
- [71] Yamashita N. Two-Stage Procrustes Rotation with Sparse Target Matrix and Least Squares Criterion with Regularization and Generalized Weighting[J]. 统计学期刊(英文), 2023, 13(2): 264-284.
- [72] Golichev I, Iosifovich I, et al. Modified gradient fastest descent method for solving linearized nonstationary Navier Stokes equations[J]. Ufa Mathematical Journal, 2013, 5(4): 58-74.
- [73] 卢俊鑫, 方志军, 陈婕妤, 等. 点线特征结合的 RGB-D 视觉里程计[J]. 光学学报, 2021, 41(4): 147-157.
- [74] Bernecker L, Idini A. Quantum Levenberg-Marquardt Algorithm for Optimization in Bundle Adjustment[J]. ArXiv, 2022, 20(5): 105-110.
- [75] Dwijotomo A, Rahman M A, Ariff M H M, et al. Cartographer SLAM Method for Optimization with an Adaptive Multi-Distance Scan Scheduler[C]// Applied Sciences, 2020.
- [76] Clayder G, Martin A. Curvature Scale Space LiDAR Odometry And Mapping (LOAM)[J]. Journal of Intelligent & Robotic Systems, 2024, 110(2).
- [77] Mur-Artal R, Montiel M M J, Tardós D J. ORB-SLAM: a Versatile and Accurate Monocular SLAM System[J]. CoRR, 2015, abs/1502.00956(5): 1147-1163.
- [78] Campos C, Elvira R, Juan J, et al. ORB-SLAM3: An Accurate Open-Source Library for Visual, Visual-Inertial and Multi-Map SLAM[J]. IEEE Transactions on Robotics, 2020, 11(9): 44-56.
- [79] Junxiang J, Xiaoji N, Jingnan L. Improved IMU Preintegration with Gravity Change and Earth Rotation for Optimization-Based GNSS/VINS[J]. Remote

- Sensing, 2020, 12(18): 3048-3048.
- [80] Graeter J, Wilczynski A, Lauer M. LIMO: Lidar-Monocular Visual Odometry[J]. arXiv, 2018, 18(7): 41-54.
- [81] 李根.基于深度学习的激光扫描 SLAM 三维点云质量评价[D].厦门大学,2018.
- [82] 余联想,郑明魁,欧文君,等.多传感器融合的移动机器人室外激光 SLAM 算法优化与系统实现[J].电子测量与仪器学报,2023,37(02):48-55.
- [83] Chao W, Guobao Z, Ming Z. Research on Improving LIO-SAM Based on IntensityScanContext[C]// Journal of Physics: Conference Series, 2021, 1827(1).
- [84] Zhu Y, Zheng C, Yuan C, Huang X, et al. CamVox: A Low-cost and Accurate Lidar-assisted Visual SLAM System[C]// Proceedings of the 2021 IEEE International Conference on Robotics and Automation (ICRA). IEEE, 2021: 156-172.
- [85] Lee H, et al. Efficient EKF-SLAM Algorithm Based on Measurement Clustering and Real Data Simulations[C]// Proceedings of the 2018 IEEE 88th Vehicular Technology Conference (VTC-Fall). IEEE, 2019, 44(5): 1-8.

攻读硕士学位期间取得学术成果

一、 发表学术论文

发表 3 类学术论文 3 篇(两篇已见刊，一篇已录用)

二、 专利

实审中发明专利 1 件，申请公布号: CN117230764A，2023.

致谢

昔日跋涉，今朝回望，感慨良多，衷心铭谢！

时光荏苒，转瞬即逝，回首过往，求索之路虽满布荆棘，却亦繁花点缀。今日落笔，心潮澎湃，唯愿借此字字句句，倾诉感恩之情。人生所遇，皆是恩泽，无论风雨或晴空，皆助我砥砺前行，拓宽视野，积累智慧。

荣光所至，深感恩养育之恩。尤感激恩师王建平教授，师者如灯塔，照亮求知之路；如春风，化雨润物无声。先生学识渊博，言传身教，以智慧启迪迷惘，以耐心雕琢棱角，使我学识日臻精进，心智愈加成熟。师恩如山，巍然不移；如水，绵长不绝。点滴教诲，铭记于心，愿以笃行致谢，不负所托。

承蒙课题组的悉心栽培，使我得以深耕学术，成长不辍。组内同道并肩，共研真知，如星辰交辉，各展光华，互勉共进，成就学术之盛景。感谢知音良朋，携手同行，共度难关，情谊如松柏常青，弥足珍贵。特别感谢张家高、唐杨、夏春婷等同门的陪伴与鼓励，亦感念李永昆、董心龙、王青、解晓民、杨礼等同窗，在学业上的鼎力相助。彼此激励，携手向前，方能行稳致远。

亦深谢父母至爱，亲朋厚谊。家之温暖，似大地承载万物，似天空包容风云。父母之恩，无以为报，唯愿以佳绩相赠，以寸心回馈。家人的陪伴与支持，是我生命中最坚实的依靠，无论前路何方，皆予我无尽动力。亦感谢张君同学在论文整理上的细致指点，如冬日暖阳，和煦而温润，陪伴我度过无数求索之夜。愿未来岁月，共赴新程，携手并肩，共赏人生风景。

最后，谨怀赤诚之心，愿吾辈以学报国，愿华夏锦绣千秋，国运昌隆，繁荣永续！

2025年3月

尚德敏学 唯实惟新

