

分类号: U463.6

学校代码: 10363

密 级: 公开

学 号: 2220110121



安徽工程大学

Anhui Polytechnic University

硕士学位论文

题 目 基于自然导航的堆垛式无人叉车
高精度定位关键技术研究

论 文 作 者 张宁禧
校 内 导 师 汪步云 教授
校 外 导 师 杨鸥 高级工程师
专业学位类别 机械
研究方向（领域） 智能机器人

论文提交日期: 2025 年 05 月 20 日

分类号: U463.6

单位代码: 10363

密 级: 公开

学号: 2220110121

基于自然导航的堆垛式无人叉车高精度定位
关键技术研究

Research on Key Technologies for High Precision Positioning of
Stacked Unmanned Forklifts Based on Natural Navigation

学 生 姓 名 : 张宁禧

校 内 导 师 : 汪步云(教授)

校 外 导 师 : 杨鸥(高级工程师)

专 业 : 机 械

研究方向(领域): 智能机器人

论文答辩日期: 2025 年 5 月 9 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：张宁禧

日期：2025年5月20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。

本学位论文属于

保密 ☐，在 _____ 年解密后适用本版权书。

不保密 ☒。

学位论文作者签名：

张宁禧

指导教师签名：

汪峰

日期：2025年5月20日

日期：2025年5月20日

基于自然导航的堆垛式无人叉车高精度定位关键技术研究

摘 要

随着自动化技术的发展,堆垛式无人叉车因其灵活操作与高效作业能力,在仓储自动化系统中占据核心地位。然而,复杂多变的环境对其高精度、高鲁棒性的定位提出了挑战。为此,本文构建了激光雷达与 IMU 紧耦合系统,并在此基础上提出了基于 IEKF 算法的多传感器数据融合方法,同时引入基于卡尔曼增益的动态调整策略以优化迭代次数,从而增强堆垛式无人叉车的定位精度;另一方面,为改善长距离运行中的定位性能,本文提出了一种基于自适应半径搜索策略的回环检测方法,并利用图优化技术对轨迹进行全局修正。本文的主要工作总结如下:

(1) 针对堆垛式无人叉车的导航控制需求,系统分析了激光雷达与 IMU 的观测模型及测量模型,设计并构建了基于激光雷达与 IMU 融合的导航与控制系统,同时搭建了控制系统的软硬件平台。在此基础上,建立堆垛式无人叉车的运动学与动力学模型,深入分析舵轮形变对定位精度的影响,并进行仿真验证。实验结果表明,舵轮形变与负载呈正相关,并对定位误差的累积具有显著影响,该研究为后续传感器融合算法的优化提供了理论支撑。

(2) 针对舵轮形变及激光雷达、IMU 融合定位中的误差累计问题,本文提出一种基于直接点云处理与 IMU 融合的自适应 IEKF 算法。首先,构建激光雷达观测与 IMU 积分模型,采用紧耦合策略融合数据,并通过三次样条插值统一时间戳,消除时钟偏差。然后,基

于直接点云处理进行全点云几何配准，避免特征匹配误差。进一步引入基于卡尔曼增益的动态调整策略，自适应优化 IEKF 算法的迭代次数，有效抑制舵轮形变与融合误差累积，提高系统实时性与计算效率。仿真实验表明，该方法在多个数据集中均显著提升点云帧的平均处理时间与定位精度，相较 LOAM 和 LIOM 算法降低累积误差并增强鲁棒性，但长距离轨迹估计仍与 LIO-GPS 算法存在差距。

(3) 针对堆垛式无人叉车在长时间运行过程中累积的定位误差问题，提出了一种基于自适应半径搜索策略的回环检测与定位优化方法，设计了自适应半径搜索策略，引入密度计算模型与局部几何特征模型，通过量化点云密度和提取法向量、曲率等几何信息，增强特征匹配的约束能力。基于此，构建姿态图并采用图优化方法对轨迹误差进行修正，从而有效抑制定位漂移，显著提升全局定位精度与系统稳定性。实验结果表明，该方法在复杂环境中能够有效降低误差积累，提高回环检测的可靠性。

(4) 针对堆垛式无人叉车高精度定位实验与结果分析展开研究，搭建了远程控制实验平台，并设计了指定路径实验与自主导航重复定位实验。实验结果表明，本文所提方法能够有效抑制定位漂移，并显著降低长时间运行过程中误差积累的影响；在指定路径实验中，引入基于自适应半径搜索策略的回环检测后，定位误差均值由 38.431 mm 降至 20.493 mm，提升精度达 46.675%；在自主导航重复定位实验中，引入基于自适应半径搜索策略的回环检测后，定位偏差降低 67.589%，并采用置信度分析进一步证明了该方法在长期运行中的稳定性和精

度优势，进一步验证了该方法在复杂环境下的稳定性与高精度表现。

关键词：堆垛式无人叉车，高精度定位，多传感器融合，自适应 IEKF，回环检测，自适应半径搜索策略

Research on Key Technologies for High Precision Positioning of Stacked Unmanned Forklifts Based on Natural Navigation

ABSTRACT

With the advancement of automation technology, stacker unmanned forklifts have become a core component of warehouse automation systems due to their flexible operation and high efficiency. However, the complex and dynamic environment poses challenges to achieving high-precision and robust localization. To address this, this paper constructs a tightly coupled LiDAR-IMU system and proposes a multi-sensor data fusion method based on the Iterated Extended Kalman Filter (IEKF) algorithm. Additionally, a dynamic adjustment strategy based on Kalman gain is introduced to optimize the number of iterations, thereby enhancing the localization accuracy of stacker unmanned forklifts. Furthermore, to improve localization performance over long-distance operations, this paper proposes a loop closure detection method based on an adaptive radius search strategy and employs graph optimization techniques for global trajectory correction. The main contributions of this study are summarized as follows:

(1) To meet the navigation control requirements of stacker autonomous forklifts, this study systematically analyzes the observation

and measurement models of LiDAR and IMU, designing and constructing a LiDAR-IMU fusion-based navigation system. A software-hardware platform for the control system is also developed. On this basis, the kinematic and dynamic models of the stacker autonomous forklift are established, and the impact of caster wheel deformation on localization accuracy is thoroughly analyzed through simulations. Experimental results indicate that caster wheel deformation is positively correlated with load and significantly contributes to cumulative localization errors, providing theoretical support for subsequent sensor fusion algorithm optimization.

(2) To address the cumulative errors caused by caster wheel deformation and LiDAR-IMU fusion localization, this study proposes an adaptive iterated extended Kalman filter (IEKF) algorithm based on direct point cloud processing and IMU fusion. First, a LiDAR observation model and an IMU integration model are constructed, and a tightly coupled strategy is adopted for data fusion, with cubic spline interpolation applied to synchronize timestamps and eliminate clock bias. Next, full-point cloud geometric registration is conducted to avoid feature matching errors. Additionally, a dynamic adjustment strategy based on Kalman gain is introduced to adaptively optimize the number of IEKF iterations, effectively mitigating errors induced by caster wheel deformation and fusion inaccuracies while improving system real-time

performance and computational efficiency. Simulation experiments demonstrate that the proposed method significantly enhances average point cloud processing time and localization accuracy across multiple datasets, reducing cumulative errors and improving robustness compared to LOAM and LIOM, though long-range trajectory estimation still lags behind LIO-GPS.

(3) To suppress localization drift and cumulative errors over extended operation periods, this study proposes a loop closure detection and localization optimization method based on an adaptive radius search strategy. A density calculation model and a local geometric feature model are introduced, quantifying point cloud density and extracting geometric features such as normal vectors and curvature to improve feature matching constraints. Based on this, a pose graph is constructed, and a graph optimization method is employed to refine trajectory errors, effectively mitigating localization drift and significantly improving global localization accuracy and system stability. Experimental results demonstrate that this method effectively reduces cumulative errors and enhances the reliability of loop closure detection in complex environments.

(4) Finally, a series of high-precision localization experiments and result analyses are conducted, including the development of a remote-control experimental platform and the design of designated path

experiments and autonomous navigation repeat localization experiments. Experimental results indicate that the proposed method effectively suppresses localization drift and significantly reduces cumulative errors over long-term operations. In the designated path experiment, the average localization error decreased from 38.431mm to 20.493mm after incorporating the optimized loop closure detection, achieving a 46.675% improvement in accuracy. In the autonomous navigation repeat localization experiment, the localization deviation was reduced by 67.589%. Confidence analysis further confirms the stability and accuracy advantages of the proposed method over extended operation periods, verifying its robustness and high-precision performance in complex environments.

KEY WORDS: Stacking unmanned forklift, high-precision localization, multi-sensor fusion, adaptive IEKF, loop closure detection, adaptive radius search method

目录

摘要	V
ABSTRACT	VIII
目录	XII
插图清单	XV
插表清单	XVIII
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	4
1.2.1 堆垛式无人叉车研究现状	5
1.2.2 多维信息融合定位研究现状	9
1.2.3 回环检测研究现状	11
1.3 主要研究内容与章节安排	12
1.4 本章小结	15
第 2 章 堆垛式无人叉车系统建模与设计	16
2.1 引言	16
2.2 定位系统模型	16
2.2.1 二维激光雷达观测模型	16
2.2.2 三维激光雷达观测模型	18
2.2.3 IMU 测量模型	20
2.2.4 IMU 惯性解算	21
2.3 堆垛式无人叉车控制系统设计	23
2.3.1 控制系统总体结构	23
2.3.2 控制系统硬件设计	25
2.3.3 开发环境搭建	28
2.4 堆垛式无人叉车导航系统设计	30
2.4.1 导航系统总体架构	30
2.4.2 基于 ROS 的开发环境搭建	31

2.5 堆垛式无人叉车模型分析	33
2.5.1 堆垛式无人叉车运动学建模	33
2.5.2 堆垛式无人叉车运动学仿真分析	35
2.6 堆垛式无人叉车误差机理分析	39
2.6.1 堆垛式无人叉车垂向动力学建模	39
2.6.2 堆垛式无人叉车舵轮形变分析	41
2.6.3 堆垛式无人叉车动力学仿真模型搭建	42
2.7 本章小结	44
第 3 章 基于直接点云处理与 IMU 融合自适应 IEKF 算法	46
3.1 引言	46
3.2 基于多维信息融合的问题描述及分析	47
3.2.1 扩展卡尔曼滤波中的非线性误差问题	47
3.3 激光雷达与 IMU 紧耦合系统构建	49
3.3.1 紧耦合系统分析	49
3.3.2 数据预处理	50
3.3.3 激光雷达与 IMU 的时钟源统一	52
3.3.4 点云配准	54
3.3.5 优化与状态估计	54
3.4 基于 IEKF 算法的多维信息融合	55
3.4.1 IEKF 算法研究	55
3.4.2 基于 IEKF 融合激光雷达与 IMU	56
3.5 基于 IEKF 多维信息融合的自适应迭代方法	57
3.5.1 卡尔曼增益的作用与数学模型	57
3.5.2 动态调整策略对比分析	58
3.5.3 基于卡尔曼增益的动态调整策略	60
3.6 实验验证及结果分析	63
3.6.1 点云帧平均耗时对比	64
3.6.2 定位精度实验结果及分析	64
3.7 本章小结	68

第 4 章 基于自适应半径搜索策略的回环检测与定位优化	69
4.1 引言	69
4.2 回环检测与定位优化问题分析	70
4.3 基于自适应半径搜索策略的回环检测方法	70
4.3.1 回环检测与因子图优化算法框架	71
4.3.2 基于密度计算模型与几何特征的自适应半径搜索策略	72
4.4 定位优化与漂移修正	76
4.4.1 姿态图构建	77
4.4.2 图优化方法	77
4.5 实验结果及分析	78
4.5.1 定位精度实验结果及分析	78
4.6 本章小结	81
第 5 章 堆垛式无人叉车高精度定位实验与结果分析	82
5.1 实验方案设计与实验基础	82
5.1.1 实验方案设计	82
5.1.2 实验场地与远程控制实验平台搭建	82
5.2 堆垛式无人叉车优化算法高精度定位实验与实验结果分析	85
5.2.1 堆垛式无人叉车指定路径定位实验	85
5.2.2 堆垛式无人叉车自主导航重复定位实验	86
5.3 本章小结	90
第 6 章 总结与展望	91
6.1 论文总结	91
6.2 研究展望	93
参考文献	94
攻读硕士专业学位期间学术成果	101

插图清单

图 1-1 堆垛式无人叉车在不同场景的应用	1
图 1-2 堆垛式无人叉车导航方式	3
图 1-3 美国第一台堆垛式无人叉车	5
图 1-4 世界上第一台叉车	5
图 1-5 Balyo 的前移式叉车堆垛式无人叉车	6
图 1-6 Rocla 公司的堆垛式无人叉车	6
图 1-7 林德堆垛式无人叉车	7
图 1-8 Vecna Robotics 公司堆垛式无人叉车	7
图 1-9 AutoGuide 公司堆垛式无人叉车	7
图 1-10 Seegrid 公司堆垛式无人叉车	7
图 1-11 中国第一辆叉车	8
图 1-12 中国第一辆堆垛式无人叉车	8
图 1-13 西华大学智能堆垛式无人叉车	8
图 1-14 合肥工业大学的堆垛式无人车	8
图 1-15 徐工集团的堆垛式无人叉车	9
图 1-16 安徽合力的堆垛式无人叉车	9
图 1-17 Cartographer 算法建图效果	10
图 1-18 Karto 算法建图效果	10
图 1-19 各章节安排	14
图 2-1 激光雷达坐标变换	17
图 2-2 三维激光雷达三角测距原理图	18
图 2-3 激光雷达 TOF 原理图	19
图 2-4 三维激光雷达观测模型	19
图 2-5 ECEF 与 ENU 坐标系示意	20
图 2-6 堆垛式无人叉车物理结构解析	23
图 2-7 控制系统各功能模块结构	25
图 2-8 堆垛式无人叉车实体结构	27

图 2-9 单舵轮控制流程图.....	29
图 2-10 货叉流程控制图.....	29
图 2-11 堆垛式无人叉车总体系统框架图.....	30
图 2-12 ROS 结构分析.....	31
图 2-13 软件框架搭建.....	32
图 2-14 任务执行流程图.....	33
图 2-15 堆垛式无人叉车运动学模型.....	34
图 2-16 堆垛式无人叉车 t 到 $t+1$ 时刻运动示意.....	34
图 2-17 直线轨迹对比图.....	36
图 2-18 直线轨迹平面投影图.....	36
图 2-19 直线轨迹 x 坐标对比图.....	36
图 2-20 直线轨迹 y 坐标对比图.....	37
图 2-21 直线轨迹 z 坐标对比图.....	37
图 2-22 曲线轨迹对比图.....	37
图 2-23 曲线轨迹平面投影图.....	38
图 2-24 曲线轨迹 x 坐标对比图.....	38
图 2-25 曲线轨迹 y 坐标对比图.....	38
图 2-26 曲线轨迹 z 坐标对比图.....	39
图 2-27 垂向动力学模型示意图.....	40
图 2-28 舵轮形变示意图.....	42
图 2-29 动力学模型 Simulink 仿真计算示意图.....	43
图 2-30 舵轮垂向位移.....	43
图 2-31 舵轮垂向变形.....	44
图 2-32 舵轮有效半径.....	44
图 3-1 扩展卡尔曼滤波流程图.....	47
图 3-2 激光雷达与 IMU 紧耦合流程图.....	50
图 3-3 数据预处理过程.....	50
图 3-4 激光雷达与 IMU 时间戳.....	52
图 3-5 三次样条插值结果.....	53

图 3-6 误差分布图.....	61
图 3-7 算法流程图.....	62
图 3-8 迭代过程流程图.....	63
图 3-9 Campus 轨迹对比图.....	66
图 3-10 Park 轨迹对比图.....	66
图 4-1 后端优化算法框架.....	71
图 4-2 回环检测流程图.....	72
图 4-3 策略流程介绍.....	73
图 4-4 图优化内容详解.....	77
图 4-5 全局位姿优化.....	78
图 4-6 Campus 轨迹对比图（引入回环后）.....	79
图 4-7 Park 轨迹对比图（引入回环后）.....	79
图 5-1 实验方案设计.....	82
图 5-2 软件组成与交互示意图.....	83
图 5-3 实验中心俯视图.....	84
图 5-4 实验中心环境及路径.....	84
图 5-5 堆垛式无人叉车定位信息示意图.....	85
图 5-6 x 坐标对比图.....	87
图 5-7 y 坐标对比图.....	87
图 5-8 定位误差 δ 对比图.....	87
图 5-9 重复定位实验（50 次）分布图.....	89

插表清单

表 1-1 堆垛式无人叉车导航方法分类	4
表 2-1 堆垛式无人叉车机械结构主要参数	24
表 2-2 各模块硬件参数指标表	26
表 2-3 运动模型参数表	34
表 2-4 动力学建模参数图	40
表 2-5 舵轮垂向变形仿真参数表	43
表 2-6 舵轮变形表	44
表 3-1 IEKF 融合参数表	55
表 3-2 点云帧平均耗时对比	64
表 3-3 绝对轨迹误差 RMSE 分析表 (ATE)	67
表 4-1 基于密度计算模型与几何特征的自适应半径搜索策略伪代码	76
表 4-2 绝对位姿估计误差 RMSE 分析表 (ATE)	80
表 5-1 动态定位精度表	86
表 5-2 定位误差测试结果对比	88

第 1 章 绪论

1.1 研究背景与意义

近年来,随着全球工业化进程的加速和技术的不断进步,智能制造已经成为全球制造业发展的重要趋势。特别是在中国,智能制造作为提高生产效率、降低人工成本、优化资源配置的重要手段,正在成为国家制造业转型升级的核心战略之一。自 2013 年德国提出“工业 4.0”发展战略以来,世界范围内的制造业开始逐步转向智能化、自动化、高效化,并推动机器人、人工智能、物联网等技术在各行业的广泛应用。这一发展趋势深刻影响了中国制造业的发展方向,中国也提出了《中国制造 2025》战略,致力于推动制造业的智能化、数字化和绿色化^[1]。

在《中国制造 2025》的框架下,堆垛式无人叉车作为智能物流系统的重要组成部分,凭借其自主导航与智能化作业的特点,在各类自动化仓储、生产线物料搬运等领域的应用逐渐增多。堆垛式无人叉车通过自动化技术代替传统的人工叉车,提高了物流效率,降低了作业成本^[2]。为了适应现代物流系统对高效、精准、智能的需求,如何提升无人叉车的定位精度和自主导航能力,已成为智能制造领域的重要研究课题^[3],图 1-1 为堆垛式无人叉车在不同场景的应用。



(a)智能仓储的堆垛式无人叉车



(b)超窄巷道的堆垛式无人叉车



(c)室外作业的堆垛式无人叉车



(d)自主导航的堆垛式无人叉车

图 1-1 堆垛式无人叉车在不同场景的应用

通过构建完善的控制系统,堆垛式无人叉车能够沿预设的安全路径自主运行,

并将物料精准运输至指定位置^[4]。在导航控制单元的支持下，叉车不仅能够检测并规避行驶路径上的障碍物，还具备智能决策能力，以确保运输过程的高效性和安全性。此外，堆垛式无人叉车可与机械臂、货叉等工业设备协同作业，实现多种自动化系统的集成^[5]。作为现代制造业中不可或缺的材料搬运设备，该类叉车在负载能力、运动灵活性以及适应复杂工况方面不断优化，已成为柔性自动化物流系统的重要组成部分，并广泛应用于生产制造、流水线作业及仓储管理^[6]。与此同时，随着工业 4.0 和智能制造技术的推进，其智能化与自动化水平持续提高，为企业提供了更加高效且经济的物流解决方案^[7]。

时至今日，国内外对堆垛式无人叉车的研究主要聚焦于运动控制方法、导航控制方法、调度系统研发及路径规划优化等方面，并已取得诸多研究成果。为了提升导航效率，需采用先进的定位方法，例如多传感器融合技术，以确保系统具备较高的定位精度^[8]。在实际运行过程中，精准定位是保障无人叉车安全作业的关键因素，直接影响任务执行的稳定性和可靠性^[7]。由于外部环境的不确定性以及传感器测量误差的存在，叉车运行过程中难以避免受到扰动，因此，需要采用多传感器组合导航技术，并通过后端优化策略进一步提升系统的稳定性与鲁棒性，实现堆垛式无人叉车的高精度定位。精准的定位不仅是确保无人叉车高效作业的基础，同时对于提升整体运行性能和适应复杂环境具有重要的现实价值^[3]。

堆垛式无人叉车的导航系统通常采用视觉传感器、激光雷达、惯性测量单元 IMU（Inertial Measurement Unit, IMU）、GNSS、磁导航传感器、轮式里程计等设备^[9]。结合先进的算法和传感器技术，堆垛式无人叉车能够应对复杂的环境变化，减少定位误差，提高整体系统的鲁棒性。多传感器信息融合技术的应用，使得叉车能够在不同的工作条件下保持高效稳定的工作表现^[10]。在人工智能领域，同步定位与建图 SLAM（Simultaneous Localization And Mapping, SLAM）是实现导航和定位的关键技术^[11]。目前，堆垛式无人叉车常见的导航方式包括磁导航、激光导航、色带导航、视觉导航、惯性导航以及基于多传感器信息融合的导航方案^[12]。这些技术的不断进步为堆垛式无人叉车的智能化和自动化提供了强有力的支持^[11]，图 1-2 为堆垛式无人叉车导航方式简述图。



图 1-2 堆垛式无人叉车导航方式

在多种组合导航的选择中，工业环境常以磁导航为主要导航方式，磁导航的价格成本较低，而且在作业环境进行叉车路径调整便捷。然而，这类方法对地面铺设条件存在一定要求，同时磁条和色带易损坏，需要定期维护和更换^[13-14]。视觉导航则对环境依赖性较强，尤其在复杂的工厂环境中，如灰尘覆盖或光照变化（如夜间作业），影响定位精度。视觉导航使用摄像头获取彩色图像，但对光照条件敏感，在作业环境低光或者过曝下，无法获得清晰图像，导致特征点提取失败^[15]。GNSS（全球导航卫星系统）是一种常用于室外环境的定位技术，能够提供较大范围的全球位置信息。然而，由于 GNSS 信号容易受到遮挡（如建筑物或隧道）以及多路径效应的影响，其在室内或复杂工业环境中的应用受到限制^[3]。惯性导航虽可提供短时间内的连续定位信息，但存在累积误差问题，随着作业时间的增加，误差不断累积，导致定位精度下降^[16]。相比之下，激光 SLAM 由于具备较强的抗干扰能力和较高的稳定性，在室内环境，特别是工业应用场景中，被更广泛采用^[17]。激光导航的定位精度主要取决于激光雷达的性能，但高精度激光雷达成本较高，而且对嵌入式系统要求较高^[18]。综合来看，为了提高堆垛式无人叉车的定位性能，通常需要结合多种导航方式，保障导航系统在多种环境下的稳定性，表 1-1 为堆垛式无人叉车导航方式分类。

堆垛式无人叉车在作业环境中完全取决于自身的导航精度与控制系统的性能。在复杂的工厂环境中，若缺乏精准的定位技术，可能会引发安全隐患。因此，

高精度定位技术的应用对于确保堆垛式无人叉车的安全与稳定运行至关重要。为了解决上述问题，研究人员逐步将研究重点转向多传感器融合技术的应用^[19]。通过融合多种传感器的数据，不仅能够弥补单一传感器在复杂环境中易受干扰的缺陷，还能提升系统的稳定性和适应能力^[20]。这种融合策略不仅增强了导航精度，还使叉车在多变的作业环境下具备更可靠的运行能力，从而显著提升其实际应用中的安全性与工作效率。

表 1-1 堆垛式无人叉车导航方法分类

导航方式	所用设备	优点	缺点
激光导航	激光雷达 (2D/3D)	高精度，实时性高，适应复杂环境	成本高，计算量大
视觉导航	深度摄像头、 立体摄像头	低成本，环境信息丰富	受光照影响大，计算复杂，易产生累计误差
磁导航	磁条、磁传感器	稳定可靠，成本低廉	路径固定，易受磁场干扰，需要维护
惯性导航	IMU	实时性强，不受外界干扰	累计误差大，长期稳定性差
GNSS	GPS 接收器	定位精度高，适用于大范围导航	室内不可用，易受天气影响

堆垛式无人叉车在导航系统的高精度定位问题是学术界，以及产业领域重点研究的方向。回顾其发展历程，不同国家的研究人员在该领域取得了诸多重要成果，并推动了关键技术的突破^[3]。然而，尽管已有一定的进展，堆垛式无人叉车的高精度定位仍面临许多挑战，相关研究仍需持续深化和拓展，以应对复杂环境和多变工作条件下的定位需求^[20]。因此，进一步探索和优化定位技术，提升系统的稳定性和精度，依然是当前研究的关键方向^[21]。

1.2 国内外研究现状

经过长期研究，堆垛式无人叉车在传感器融合、控制系统优化以及调度系统设计等方面取得了显著进展，不仅促进了相关系统的研发，也拓宽了其在工业领域的应用范围，其中，导航定位、运动控制、调度系统等关键技术始终是国内外

研究的核心议题^[20]。近年来，高校、科研机构及企业围绕这些核心问题展开深入研究，并取得了一系列突破性成果。本文将综述堆垛式无人叉车的研究进展，分析当前技术的发展现状，并探讨其面临的挑战。

1.2.1 堆垛式无人叉车研究现状

堆垛式无人叉车的国外发展可追溯至 20 世纪 50 年代，当时第一台牵引式堆垛式无人叉车被制造并投入应用，以提高生产效率和自动化水平。随后，20 世纪 60 年代激光技术的诞生推动了其在军事勘探、民用工业等多个领域的深入应用，进一步提升了环境感知能力^[22]。近年来，研究表明多传感器信息融合已成为提升感知与定位能力的有效手段，能够显著增强系统的鲁棒性和环境适应性^[23]。对于堆垛式无人叉车而言，多维信息融合与后端优化是确保高精度定位的核心环节，其精度直接影响叉车在复杂环境下的导航性能^[24-25]。然而，合理选择合适的传感器仍然是一项复杂的任务，需要综合考虑精度、成本、环境适应性等多方面因素^[26]。

在叉车的发展历史上，全球首台叉车由 CLARK 公司研发，并以“Tructier”命名，于 1928 年投入使用，标志着叉车技术的正式起步^[27]。1954 年，英国率先研制出采用电磁导引方式的堆垛式无人叉车，该导航方式提高了路径规划的灵活性，使其在物流和仓储等场景得到广泛应用，并成为当时主流的导航方式之一^[28]。1984 年，柔性装配系统（FAS）的建立进一步加快了堆垛式无人叉车在生产线中的推广，为智能制造和自动化物流的发展奠定了坚实的基础，推动了堆垛式无人叉车技术向更高精度、更高智能化方向演进^[4]。




图 1-3 美国第一台堆垛式无人叉车



图 1-4 世界上第一台叉车

1974 年，瑞典首次在工业生产领域成功应用堆垛式无人叉车技术，并研发

了一款用于车身组装的自动化设备，标志着该技术在制造行业的初步实践^[20]。近年来，随着自动化技术的持续发展，多家企业相继推出高精度堆垛式无人叉车，以满足精密作业需求。例如，Balyo 公司研发的前移式叉车，在理想环境下可实现毫米级定位精度，其导航与定位系统基于 SLAM 算法构建地图，在运行过程中持续扫描周围环境，提取关键特征并进行匹配，从而实现高精度自主定位，提高了车辆在动态环境中的适应性^[29]。

与此同时，Rocla 公司推出了一款高精度堆垛式无人叉车，其定位误差可达 $\pm 3\text{mm}$ 。该设备采用激光导航方式，并在顶部安装了激光雷达，可进行 360° 环境扫描，并与预存地图进行匹配，以实时校正位姿并优化行驶轨迹^[29]。激光导航技术的引入，使得堆垛式无人叉车在大规模物流仓储、柔性制造系统等应用场景中的表现更加稳定可靠^[30]。此外，现代堆垛式无人叉车正朝着更高精度、更强智能化的方向发展，通过融合多传感器信息与先进控制算法，实现更加精准的环境感知和路径规划^[30]。这些先进技术的应用进一步提升了堆垛式无人叉车在工业生产中的智能化水平，并推动了其在自动化仓储与物流行业的广泛应用，为未来智能制造的发展奠定了坚实的基础^[20]。



图 1-5 Balyo 的前移式叉车堆垛式无人叉车



图 1-6 Rocla 公司的堆垛式无人叉车

多传感器融合技术已成为提升堆垛式无人叉车定位精度的重要研究方向。由于单一传感器在精度、环境适应性等方面的局限性，众多研究者提出了多传感器信息融合的方法^[22]。该技术通过集成不同类型的传感器数据，并采用多种融合策略，包括松耦合与紧耦合模式，对位姿进行优化估计，以提高系统的稳定性和定位精度^[21]。目前，多信息融合技术已在堆垛式无人叉车领域得到广泛应用，并显著提升了其导航与作业能力，同时降低了系统对单一传感器的依赖，提高了恶劣环境下的适应性^[30]。



图 1-7 林德堆垛式无人叉车



图 1-8 Vecna Robotics 公司堆垛式无人叉车

AutoGuide 公司专注于高负载堆垛式无人叉车的设计、研发与制造，其产品具备更高的灵活性，能够适应多种复杂作业环境。通过集成先进的传感器与智能控制系统，该设备不仅支持全天候自动化运行，还能在不同工作场景下自适应调整。

Seegrid 公司推出了一款采用视觉导航技术的堆垛式无人叉车，该设备配备了其自主研发的摄像头，并通过结合复杂算法与机器学习技术，实现高精度的导航计算^[12]。这种创新的导航方法使得无人叉车在动态环境中能够更精准地进行路径规划与定位，从而提升了系统的灵活性与可靠性。



图 1-9 AutoGuide 公司堆垛式无人叉车



图 1-10 Seegrid 公司堆垛式无人叉车

相比于国外，我国在自动化运输工具领域的研究起步相对较晚，但经过数十年的持续探索与技术积累，已取得显著成就。自 20 世纪 50 年代起，我国叉车产业逐步发展，并在 70 年代成功研制出首台堆垛式无人叉车，标志着我国在该领域迈出了关键性的一步。至 1991 年，该技术实现实际应用，为自动化物流装备的推广奠定了基础。进入 21 世纪，随着国内叉车行业的快速崛起，相关技术不断迭代升级，并在国际市场上逐渐崭露头角，吸引了全球行业的广泛关注^[27]。在这一过程中，技术创新持续推进，企业竞争力不断增强，助力我国在全球自动化

运输行业中占据重要地位。



图 1-11 中国第一辆叉车




图 1-12 中国第一辆堆垛式无人叉车

西华大学的丁声雷、王强等^[32]研究了堆垛式无人叉车的传感器数据预处理方法。针对不同频率周期的数据，他们采用了互补融合技术，并进行了滤波处理，以提高数据的质量和准确性。在此基础上，结合堆垛式无人叉车的非完整约束模型，设计了一种改进的变趋近律滑模控制方法，从而有效减小了控制抖动，提高了定位精度^[33]。李恒恒、彭慕蓉等^[34]则提出了一种新的雷达点云数据提取方法，能够将提取出的特征信息与环境地图进行匹配，同时结合惯性导航技术，从而实现了更加可靠的定位。这些创新方法显著提高了堆垛式无人叉车的定位精度和系统的稳定性，为其在复杂环境中的应用提供了更有力的技术支持^[35]。



图 1-13 西华大学智能堆垛式无人叉车



图 1-14 合肥工业大学的堆垛式无人车

国内领先的堆垛式无人叉车制造企业，如杭叉集团和木牛流马，已经逐步接近国际先进水平。徐工集团推出的堆垛式无人叉车，采用高精度定位系统和智能控制技术，能够根据不同作业环境进行导航与调度，广泛应用于自动化仓储和物流领域。此外，徐工集团叉车的高效电池管理系统支持长时间连续作业，大幅提升了工作效率和设备的持续运行能力。

安徽合力的堆垛式无人叉车则采用了激光导航与传感器融合技术，具备极高

的定位精度和强大的环境适应性。该叉车在狭窄通道中表现尤为出色，能够灵活应对各种复杂作业。其无级调速和自动定位高度功能，使得停位精度得到有效保证，确保了作业过程的安全性高效性。凭借这些技术创新，安徽合力的堆垛式无人叉车已成为现代自动化仓储和物流管理系统中不可或缺的重要装备。



图 1-15 徐工集团的堆垛式无人叉车



图 1-16 安徽合力的堆垛式无人叉车

目前市场上叉车种类繁多，其中堆垛式无人叉车因其在运输行业及室内工厂自动化物流中的突出优势，具有重要的应用价值。现阶段，主流的多传感器信息融合技术依托多种传感器组合获取环境信息，并通过数据融合处理，实现高精度定位^[36]。该技术的广泛应用显著增强了堆垛式无人叉车在复杂作业环境中的适应能力，有效提升了工业自动化水平与作业效率，为智能制造和智慧物流的发展提供了重要支撑^[37]。

1.2.2 多维信息融合定位研究现状

近年来，激光导航技术取得了长足进展，作为一种具备高精度和高可靠性的定位手段，在堆垛式无人叉车领域得到了广泛应用^[38]。该技术依托激光传感器实时感知周围环境，并结合同时定位与建图（Simultaneous Localization and Mapping, SLAM）算法，使堆垛式无人叉车能够自主完成定位与路径规划^[36]。目前，主流的激光 SLAM 算法包括：基于粒子滤波的 Gmapping 算法^[39]、利用高斯牛顿方法进行优化的 Hector 算法^[40]、采用图优化策略的 Karto 算法^[41]，以及 Cartographer 算法^[42]等。然而，仅依赖激光雷达进行导航仍存在一定局限性，该方法对环境地图的完整性依赖较大，并且对外界环境的稳定性要求较高，尤其是针对堆垛式无人叉车，相关的组合导航技术研究仍较为有限^[41-44]。因此，在复杂应用场景下如何进一步提升导航系统的鲁棒性与适应性，已成为当前研究领域亟待解决的重要

问题^[46]。




图 1-17 Cartographer 算法建图效果




图 1-18 Karto 算法建图效果

随着智能工厂的快速发展,堆垛式无人叉车对高精度定位与自主导航的需求日益增长,其中,多传感器融合技术已成为实现高精度定位的重要手段^[45]。传感器融合作为一项跨学科的信息处理技术,最早可追溯至 20 世纪 80 年代,其核心目标是整合多种传感器获取的环境信息,构建统一的环境感知模型,并在此基础上进行数据分析与处理^[46]。目前,常见的传感器融合方法包括粒子滤波、贝叶斯滤波、神经网络、模糊逻辑以及卡尔曼滤波等,广泛应用于机器人与智能车辆的定位与导航系统,通常采用激光雷达与轮式里程计融合来获取定位信息^[47]。

近年来,国内外研究人员围绕堆垛式无人叉车的传感器融合技术展开了深入研究^[48]。在非线性系统的处理方面,Kailath 等^[49]提出的扩展卡尔曼滤波(EKF)算法已在工程领域得到广泛应用。Bersani 等^[50]通过融合激光雷达与毫米波雷达信息,并结合曲线坐标系建模,实现了障碍物识别、目标跟踪以及车辆运动估计。然而,该方法未涉及车辆动力学建模,也未与其他融合方法进行对比分析。首尔大学的 Park 等^[51]提出了一种基于旋转声纳与差分编码器融合的定位方法,该方法利用已知地图与实时传感器数据进行匹配,从而实现动态环境下的车辆定位。然而,该研究未对复杂环境下的适应性与稳定性进行深入探讨。Hyunhak 等^[52]人针对磁导引堆垛式无人叉车,提出了一种基于编码器输出实时校准的方法,并结合 EKF 算法提升了定位精度,但该方法仅在理想实验条件下验证,缺乏在实际复杂场景中的应用测试。S. Gao 等^[53]提出随机加权融合方法,降低异构传感器测量误差;但未考虑动态环境下的权重自适应调整,可能依赖先验噪声模型假设。Guo H 等^[54]通过扩展局部结构信息增强里程计抗噪性;但对运动畸变校正依赖较强,高速场景易累积误差。Xu W^[55]实现激光-惯性紧耦合里程计;但点云稀疏时

（如远距离）特征提取稳定性不足。Júnior G P C 等^[56]提出 EKF-LOAM 算法，通过自适应融合激光 SLAM、轮式里程计与惯性数据，显著提升定位鲁棒性与建图精度，但依赖轮式里程计的高精度输出，在轮毂打滑或地面不平整时易产生误差累积，且多传感器标定误差可能影响融合效果。Shi P^[57]改进激光-惯性紧耦合 SLAM 数值稳定性，但对比验证困难。

随着任务复杂度的增加，现代堆垛式无人叉车通常集成多个传感器，并根据传感器的安装位置及工作原理进行功能分配，以实现精准导航^[20]。多传感器信息融合已成为该领域研究的核心方向之一，为解决复杂环境下的导航控制问题提供了有效的技术支撑。

1.2.3 回环检测研究现状

回环检测（Loop Closure Detection）作为高精度定位系统的关键技术之一，主要用于识别当前帧与历史帧之间的匹配关系，以此修正累计误差，优化全局轨迹精度并增强系统一致性。近年来，国内外研究人员围绕该领域展开了深入研究，并提出了多种基于激光雷达点云的回环检测方法。

在国外，局部描述符方法主要依赖特征点的提取与匹配，以提高回环检测的准确性。例如，S. Salti 等^[58]提出了 SHOT（Signature of Histograms of Orientations）描述符，该方法利用关键点的法线信息构建直方图，以此表征局部几何特征。随后，Prakhya 等^[59]在 SHOT 的基础上提出 B-SHOT（Binary SHOT）描述符，该方法在计算特征点邻域信息时加入了角度特征，增强了特征表达能力。此外，Guo 等^[60]设计了 ISHOT（Intensity SHOT）方法，该方法结合激光雷达的反射强度信息，提高了回环检测在不同环境条件下的鲁棒性。尽管局部描述符在捕捉几何细节方面具有一定优势，但在重复结构较多的环境中，基于直方图的特征提取方式可能导致匹配错误，并且难以全面刻画场景整体特征。

相比之下，全局描述符方法更加关注点云的整体几何结构，并且计算效率较高，因此在回环检测中得到了广泛应用^[61]。例如，Rusu 等^[61]提出 FPFH（Fast Point Feature Histograms）方法，该方法通过计算点云的法线信息生成特征直方图，以刻画局部几何信息，但在高维特征匹配时计算复杂度较高，难以满足实时性的需求。为了提高计算效率，Wohlking 等^[62]提出 ESF（Ensemble of Shape Functions）

描述符,该方法通过分析点云的表面距离、角度及面积分布构建特征向量,提高了计算速度。He 等^[63]提出 M2DP (Multiview 2D Projection) 方法,该方法利用点云在不同投影平面的投影结果进行特征压缩,并结合奇异值分解 (SVD) 方法提取描述符,提高了计算效率。此外, Kim 等^[64]提出 Scan Context (SC) 方法,该方法将激光雷达点云投影至鸟瞰视角,并提取最大高度信息,以构造全局描述符,从而实现高效的回环检测。在此基础上, Wang 等^[65]对 SC 方法进行了优化,提出 ISC (Intensity Scan Context), 该方法利用激光雷达的强度信息替代高度特征,提高了系统在不同环境下的适应性。虽然全局描述符方法在计算速度和匹配鲁棒性方面表现较好,但在动态环境中仍可能受到噪声与遮挡的影响,进而影响回环检测的准确性^[66]。

国内研究者在回环检测领域也取得了重要进展,尤其是在基于投影构建全局描述符的方法上,提出了多种创新性算法。Wang 等^[67]提出 LIDAR Iris 方法,该方法利用点云的高度信息构建特征编码,并采用 Hamming 距离进行高效匹配,从而提升了回环检测的实时性。此外, Li 等^[68]提出了一种基于语义信息的回环检测方法,通过引入语义分割技术优化特征匹配策略,提高了在复杂环境下的检测精度。丁盼云^[69]提出了一种基于动态物体去除和地面点去除的回环检测,通过计算特征描述符之间的相似度从而检测回环。廖礼洲^[70]提出了一种轻量化的约束构建方法,提高了计算效率。近年来,一些研究团队尝试将深度学习方法引入回环检测任务,以提升特征提取与匹配的准确性。

总体而言,国外研究者在特征提取、匹配策略和计算效率方面提出了诸多改进,而国内研究者在基于投影的全局描述符和深度学习方法上取得了显著进展。然而,面对复杂动态环境,回环检测技术仍然面临诸多挑战,包括环境适应性、鲁棒性提升及计算效率优化等方面。

1.3 主要研究内容与章节安排

本文以堆垛式无人叉车为研究对象,针对堆垛式无人叉车的组合导航定位系统中所存在的问题进行了研究,提出了相应的解决方案,并设计了具体的实验来进行验证。共分为 6 章,各章具体的研究内容如下:

第 1 章 介绍了堆垛式无人叉车激光导航与信息融合研究背景与意义,课题

来源,并分析堆垛式无人叉车高精度定位的研究现状,探讨了堆垛式无人叉车高精度定位现阶段的研究存在的一些不足,确定后续章节安排。

第2章 堆垛式无人叉车系统建模与设计。系统的分析了激光雷达的观测模型与IMU的测量模型,推导惯性解算方法,并构建堆垛式无人叉车的运动学模型,为多传感器数据融合提供基础,并搭建了堆垛式无人叉车的导航系统与控制系统。其次,本章进一步开展了堆垛式无人叉车的运动学仿真分析。通过直线与曲线路径下的运动过程,对比分析坐标值的误差特性。随即,探讨了堆垛式无人叉车的误差机理,构建了垂向动力学模型,分析叉车在垂直方向上的动态响应特性;通过舵轮形变分析,探讨了舵轮结构形变对运动精度的影响。上述研究为后续章节的融合定位方法提供了理论依据,并奠定了系统优化的基础。

第3章 基于直接点云处理与IMU融合自适应IEKF算法。基于扩展卡尔曼滤波(EKF)的误差机理分析,针对其非线性误差问题,提出一种改进的激光雷达与IMU紧耦合融合方法。构建了激光雷达与IMU的紧耦合系统,并采用三次样条插值对两者的时间戳进行统一处理,以消除时钟偏差的影响,引入直接点云处理,避免特征匹配误差。随后,利用迭代扩展卡尔曼滤波(IEKF)实现两类传感器信息的融合,并进一步设计基于卡尔曼增益的动态调整策略,以提升滤波精度和系统鲁棒性。

第4章 基于自适应半径搜索策略的回环检测与定位优化。针对回环检测与定位优化问题展开研究,提出一种基于自适应半径搜索策略的回环检测方法。首先,分析回环检测的关键问题,并设计基于自适应半径搜索的特征匹配与回环判定机制,并深入讨论了密度计算模型与局部几何特征模型,通过密度估计和几何特征提取,能够在回环检测中更精确的匹配特征点。随后,构建姿态图,并采用图优化方法对轨迹误差进行修正,从而有效抑制堆垛式无人叉车长时间运行过程中累积的定位漂移,提高系统的全局定位精度与稳定性。

第5章 堆垛式无人叉车高精度定位实验与结果分析。基于堆垛式无人叉车的机械结构及实际生产任务需求,设计实验方案,分别开展融合定位算法与回环检测的指定路径实验以及自主导航重复定位实验。最终,通过实验数据验证所提出融合定位算法与回环检测方法的有效性,为系统的工程应用提供支撑。

第6章 总结及展望。对所进行研究的内容和取得的成果进行总结,思考尚

未解决的问题和当前研究的不足之处，并提供一些未来研究方向的参考，以便后续研究更深入地探讨堆垛式无人叉车高精度定位问题。




图 1-19 各章节安排

各章节的主要内容及其相互关联如图 1-19 所示。第一章主要介绍了堆垛式无人叉车高精度定位的研究意义，介绍了多传感器融合、后端优化算法的研究现状。第二章构建激光雷达与 IMU 的测量模型，并建立堆垛式无人叉车的运动学模型，为后续章节信息融合奠定基础，随即分析了堆垛式无人叉车的误差机理分析，建立了动力学模型，为后续研究奠定理论基础。第三章提出基于直接点云处理的激光雷达与 IMU 紧耦合融合方法，采用自适应 IEKF 算法对多传感器信息进行融合，并优化 IEKF 的迭代次数，以提升估计精度与收敛性。第四章针对长距离运行过程中累积误差导致的定位漂移问题，提出基于自适应半径搜索策略的回环检测方法，并结合图优化对定位结果进行优化。第五章设计并实施自主导航重复定位实验与指定路径实验，以验证所提出融合算法与回环检测方法的有效性，为系统实际应用提供实验验证。

1.4 本章小结

本章阐述了研究的背景及意义，介绍了堆垛式无人叉车及其多维信息融合定位与回环检测的国内外研究现状。介绍了当前堆垛式无人叉车常用的组合导航算法，以及国内外堆垛式无人叉车关于激光导航以及与其他传感器融合的研究现状。总结了各章节的主要研究内容与章节之间的关系。

第 2 章 堆垛式无人叉车系统建模与设计

2.1 引言

本章主要围绕堆垛式无人叉车的模型搭建与系统设计展开研究,为后续高精度定位与多传感器融合奠定理论基础。首先,构建激光雷达观测模型、IMU 测量模型及惯性解算方法,系统分析其测量原理、误差特性及数据融合机制,并在此基础上建立堆垛式无人叉车的导航与控制系统。其次,针对堆垛式无人叉车的运动特性,构建运动学模型,详细分析其运动约束条件。在此基础上,开展运动学仿真分析,以验证模型的准确性及适用性。此外,本章进一步探讨堆垛式无人叉车的误差机理,建立动力学模型,分析舵轮形变对定位精度的影响,并搭建动力学仿真平台,以量化舵轮形变对叉车整体定位精度的影响程度。通过本章的研究,旨在构建适用于堆垛式无人叉车的精确数学模型,并为后续传感器融合及优化算法的研究提供理论支撑。

2.2 定位系统模型

激光雷达通过发射激光脉冲并测量其往返时间,实现对环境的高精度三维重建,在复杂环境条件下依然能够提供精确的距离信息。惯性测量单元(Inertial Measurement Unit, IMU)由加速度计与陀螺仪组成,可高频率获取载体的姿态与运动状态。然而,单一传感器存在固有局限性,例如激光雷达在动态场景中易受遮挡影响,而 IMU 则因漂移误差导致长时间累积误差。因此,为提升定位与导航的精度和稳定性,需引入多传感器融合技术,对不同传感器的数据进行综合处理,以充分发挥各自优势,弥补单一传感器的不足,从而实现更加鲁棒的环境感知与精确定位。

2.2.1 二维激光雷达观测模型

激光雷达的工作原理基于激光测距技术,其核心机制依赖于飞行时间测量。激光雷达系统通过发射器释放短脉冲激光束,这些脉冲以光速传播,并在遇到物体表面后发生反射。接收器捕获返回的激光信号,并记录从发射到接收所经历的

时间。结合光速信息，系统即可计算激光脉冲的传播距离，从而实现对环境的精准测绘。

在激光导航过程中，首先需将采集到的测距数据转换至激光雷达的直角坐标系，以便进行后续计算和处理。设 S 表示激光雷达中某个特定的激光束，扫描到的目标点在极坐标系中的位置可表示为 $S(\rho, \phi)$ ，其中 k 代表该点在扫描序列中的编号。通过坐标变换，可将极坐标下的点云数据转换至直角坐标系。

$$\begin{cases} x = \rho \cos \phi \\ y = \rho \sin \phi \end{cases} \quad (2-1)$$

变量 x_L^k 和 y_L^k 分别表示激光雷达数据在笛卡尔坐标系中的横坐标和纵坐标。由于激光雷达安装在堆垛式无人叉车上，其坐标系与叉车本体坐标系之间存在固定的转换关系。因此，需要对采集到的激光雷达坐标数据进行坐标变换，使其映射至堆垛式无人叉车的本体坐标系，以便在统一坐标框架下进行融合计算和导航控制。如图 2-1 所示，详细展示了坐标系之间的转换关系。




图 2-1 激光雷达坐标变换

在实际部署的应用场景中，若当前时刻激光雷达的位姿坐标表示为 $P_t = [x_t \ y_t \ \phi_t]^T$ ，通常默认当前激光雷达与堆垛式无人叉车的坐标系无角度变换关系。因此，可以直接求解激光雷达的观测数据在世界坐标系下的坐标：

$$\begin{bmatrix} x_k \\ y_k \end{bmatrix} = \begin{bmatrix} x_t \\ y_t \end{bmatrix} + \begin{bmatrix} \cos(\phi_k + \phi_t) \\ \sin(\phi_k + \phi_t) \end{bmatrix} \rho_k \quad (2-2)$$

在式 2-2 中， $[x_k \ y_k]^T$ 表示激光雷达数据在世界坐标系中的坐标信息，可以推导出激光雷达的观测模型如下：

$$\begin{cases} \rho_k = \sqrt{(y_k - y_t)^2 + (x_k - x_t)^2} \\ \phi_k = \left[\arctan \left(\frac{y_{t+1} - y_t}{x_{t+1} - x_t} \right) \right] - \phi_k \end{cases} \quad (2-3)$$

2.2.2 三维激光雷达观测模型

三维激光雷达可以采用激光发射的方式进行测距。激光测距雷达主要技术原理是 TOF 测距和三角测距原理，即通过激光雷达发射激光，接触障碍物后，经扫描装置成像，生成三角形形状的图像，完成测距^[71]。如图 2-2 所示，标线 x 是入射光点到摄像头 O 的距离，俯仰角定义为 β ， f 是图像传感器的焦距。

根据几何关系，图像传感器对反射光的感应点记为 a ，以 O 为出发点作一条与入射光束平行的虚拟直线，并设该直线与图像传感器的交点为 b ，则在图像传感器上， a 与 b 之间的间距可记作 x ，结合上述几何计算方法，可进一步推导出被测物体的实际空间坐标。




图 2-2 三维激光雷达三角测距原理图

由图 2-2 两个大小相同的三角形中相似的关系可推出 F 值。然后我们可以通过激光的俯仰角 β 推算出距离激光雷达的障碍物距离 d 值，公式为：

$$\frac{X}{x} = \frac{F}{f} \quad (2-4)$$

$$d = \frac{F}{\sin \beta} = \frac{Xf}{x \sin \beta} \quad (2-5)$$

由于三角测距精度不高，一般只用于有限室内测量距离，基于 TOF 原理的

测距更精准，可用于室内大范围的测量距离，如图 2-3 所示为 TOF 原理示意图。




图 2-3 激光雷达 TOF 原理图

激光雷达发出的激光一旦跟踪到回波，当其被障碍物反射回来，可通过激光的发出-接收到的时间之差及光速，计算得出其至激光雷达的距离 d 。具体算法如下：其中， C 为光速， t 为激光束发出至接收到的时间间隔。

$$d = \frac{Ct}{2} \quad (2-6)$$

通常来说，三维激光雷达一般采用距离-方位角-俯仰角的模型进行建模，如图 2-4 所示，可以通过观察模型中找出激光雷达的观测点的各种信息，如观测点的位置、姿态、反射强度等。




图 2-4 三维激光雷达观测模型

如在图 2-4 中设定激光雷达的坐标为原点 O ，观测点 P 为 OP ， OP 表示从观测点到激光雷达的距离，可以通过 TOF 来获得。选定方位角为 δ ，俯仰角为 α 。

通过激光雷达观测模型 RAE，将激光雷达三维上通过距离、方位角和仰俯角的转换算出观测点 P 在激光雷达坐标系中的三维坐标 $P(x, y, z)$ 。其计算方式如式所示：

$$\overrightarrow{OP} = \begin{bmatrix} x \\ y \\ z \end{bmatrix} = d \begin{bmatrix} \sin \delta \cos \alpha \\ \cos \delta \cos \alpha \\ \sin \alpha \end{bmatrix} \quad (2-7)$$

也就是说，已知目标点激光雷达坐标系下的坐标，便可求得距离、方位角、俯仰角等参量。反投影计算如表所示。

$$\begin{bmatrix} d \\ \delta \\ \alpha \end{bmatrix} = \begin{bmatrix} \sqrt{x^2 + y^2 + z^2} \\ \arctan(x / y) \\ \arcsin(z / \sqrt{x^2 + y^2 + z^2}) \end{bmatrix} \quad (2-8)$$

2.2.3 IMU 测量模型

IMU 通常情况下分为陀螺仪和加速度计，用于对载体进行描述的两个载体中，一个是以测量载体相对惯性系统的姿态变化作为载体描述的内容，另一个是以测量载体对惯性系统的相对位置变化作为载体描述的内容，均是对坐标框架为 IMU 坐标帧得到的数据^[72]。不过，考虑到堆垛式无人叉车采用的是低精度微型机械电子陀螺仪，因此在静止环境时无法感知到地球自转的运动。因此，为了避免受到地球自转的影响，在数据处理算法中需要剔除地球自转的影响，并将地球坐标框架视作惯性参考帧，且认为地球处于静止状态。另外，ENU 坐标框架定义为以地球表面某点的东南西北四个方向作为其 XYZ 三个轴向。如将地球坐标框架当作惯性参考帧来看，可以将陀螺仪、加速度计的数据建模，其中对于地心地固坐标框架(ECEF)和东北天坐标框架(ENU)之间关系如图 2-5 所示。




图 2-5 ECEF 与 ENU 坐标系示意

由此可得，陀螺仪的测量模型为：

$$\tilde{\omega}_{wb}^b(t) = \omega_{wb}^b(t) + b_{\omega}(t) + n_{\omega}(t) \quad (2-9)$$

式中： $\tilde{\omega}_{wb}^b(t)$ 表示测得的载体系相对于惯性系（此处假设惯性系为世界坐标系）的角速度，并在载体系下进行表达，此处载体系即 IMU 坐标系^[73]； $\omega_{wb}^b(t)$ 这表示经过精确计算和校正处理，从而消除了传感器在测量过程中可能产生的误差，得到的角速度的真实数值； $b_{\omega}(t)$ 表示陀螺仪的零偏随时间的变化； $n_{\omega}(t)$ 这表示了陀螺仪的白噪声。

加速度计的测量模型可通过以下方式表示：

$$\tilde{a}_{wb}^b(t) = R_w^b(a_w^w - g^w) + b_a(t) + n_a(t) \quad (2-10)$$

式中： $\tilde{a}_{wb}^b(t)$ 表示测量得到的载体相对于惯性坐标系的加速度在载体坐标系中的值； $R_w^b = R_b^{wt}$ 是从世界坐标系到载体坐标系的旋转矩阵； a_w^w 为世界坐标系下的真实加速度值； $b_a(t)$ 为加速度计随时间变化的零偏； $g^w = [0 \ 0 \ -9.81]^T$ 表示重力加速度； $n_a(t)$ 则代表加速度计的白噪声。

2.2.4 IMU 惯性解算

IMU 的测量模型提供了角速度 ω_{wb}^b 和线加速度 a_{wb}^b 这两个关键观测量，这些数据为系统后续的计算提供了必要的基础，使得系统能够进行一系列的推算，如姿态、速度和位置的估计。解算的主要目标是基于 IMU 获得的角速度和线加速度，并结合 $k-1$ 时刻的导航信息，推导出当前时刻 k 的导航数据，包括位置 p_k 、速度 v_k 和姿态 R_{wb_k} ，使用四元数 q_{wb_k} 表示。这些姿态信息是通过各个方向上的差分方程计算而来的，再转换成离散时刻的近似值。由于 IMU 不受外在噪声干扰，因此其得到的定位结果能够为稳定、连续的定位提供数值。然而受加速度计和陀螺仪的原始偏差影响，定位误差在短时间内会不断叠加。下面将系统阐述基于 IMU 的姿态解算策略。

(1) 基于旋转矩阵的姿态更新

由旋转矩阵的微分方程可得：

$$\dot{R}_{wb} = R_{wb} \left[\omega_{wb}^b \times \right] \quad (2-11)$$

$$\omega_{wb}^b \times = \begin{pmatrix} 0 & -\omega_z & \omega_y \\ \omega_z & 0 & -\omega_x \\ a_{31} & a_{32} & 0 \end{pmatrix} \quad (2-12)$$

式中： ω_{wb}^b 表示在载体坐标系中观察到的角速度，指的是在排除零偏影响后，陀螺仪所提供的角速度读数， $\omega_{wb}^b \times$ 对应角速度的反对称矩阵， R_{wb} 它表示从载体坐标系到世界坐标系的旋转转换矩阵， ω_{wb}^b 陀螺仪的零偏可暂不纳入考量，在实际应用时可通过扣除零偏值直接修正角速度。

基于上述微分方程，可从 $k-1$ 时刻的旋转矩阵递推 k 时刻的旋转矩阵：

$$R_{wb_k} = R_{wb_{k-1}} e^{\int_{t_{k-1}}^{t_k} [\omega_{wb}^b]_{\times} d\tau} \quad (2-13)$$

该式中的指数项积分结果等效于 $k-1$ 至 k 时刻的相对旋转矢量 $\phi_{b_k}^{b_{k-1}}$ 构成的反对称矩阵 $\phi_{b_k}^{b_{k-1}} \times$ ；利用反对称矩阵的指数性质和罗德里格斯公式，式（2-13）可简化为：

$$R_{wb_k} = R_{wb_{k-1}} e^{\int_{t_{k-1}}^{t_k} [\omega_{wb}^b]_{\times} d\tau} = R_{wb_{k-1}} e^{\phi_{b_k}^{b_{k-1}}} = R_{wb_{k-1}} R_{b_{k-1}b_k} \quad (2-14)$$

$$R_{b_{k-1}b_k} = I + \frac{\sin|\phi_{b_k}^{b_{k-1}}|}{|\phi_{b_k}^{b_{k-1}}|} (\phi_{b_k}^{b_{k-1}} \times) + \frac{1 - \cos|\phi_{b_k}^{b_{k-1}}|}{|\phi_{b_k}^{b_{k-1}}|^2} (\phi_{b_k}^{b_{k-1}} \times)^2 \quad (2-15)$$

式中： $\phi_{b_k}^{b_{k-1}}$ 表示 b_k 到 b_{k-1} 坐标系间的等效旋转矢量。

(2) 基于四元数的姿态更新

依据四元数微分方程：

$$\dot{q}_{wb} = q_{wb} \otimes \frac{1}{2} \begin{bmatrix} 0 \\ \omega_{wb}^b \end{bmatrix} \quad (2-16)$$

式中： $\otimes$ 表示四元数乘法运算符， q_{wb} 为描述载体坐标系至世界坐标系旋转变换的四元数。

将四元数乘法转换为矩阵运算形式：

$$q_{wb_k} = q_{wb_{k-1}} \otimes q_{b_{k-1}b_k} = q_{wb_{k-1}} \otimes \begin{bmatrix} \cos \frac{|\phi_{b_k}^{b_{k-1}}|}{2} \\ \phi_{b_k}^{b_{k-1}} \sin \frac{|\phi_{b_k}^{b_{k-1}}|}{2} \end{bmatrix} \quad (2-17)$$

式中： $\phi_{b_k}^{b_{k-1}}$ 对应于 b_{k+1} 到 b_k 的等效旋转矢量。

(3) 等效旋转矢量的计算

无论是旋转矩阵法还是四元数法,均需通过等效旋转矢量的微分方程完成参数更新。将旋转矩阵用等效矢量形式表达后,可推导出旋转矢量的微分方程:

$$\dot{\phi} = \omega_{wb}^b + \frac{1}{2} \phi \times \omega_{wb}^b + \frac{1}{\phi^2} \left(1 - \frac{\phi}{2} \cot \frac{|\phi|}{2} \right) (\phi \times)^2 \omega_{wb}^b \quad (2-18)$$

采用泰勒展开对三角函数进行近似,并基于中值积分法离散化处理,最终得到 b_{k-1} 至 b_k 时刻的等效旋转矢量 $\phi_{b_k}^{b_{k-1}}$:

$$\phi_{b_k}^{b_{k-1}} = \frac{\omega_{wb_{k-1}}^{b_{k-1}} + \omega_{wb_k}^{b_k}}{2} (t_k - t_{k-1}) \quad (2-19)$$

2.3 堆垛式无人叉车控制系统设计

2.3.1 控制系统总体结构

在堆垛式无人叉车的设计中,舵轮安装在车辆中心位置,既负责转向,又承担驱动功能,而车体后方配备的两个从动轮则主要用于支撑货叉载荷,以维持车辆的平衡。车体的平稳运行由舵轮确保,其构成包括行走轮、转向电机、转向电机减速器、行走电机以及矩形弹簧等部件。图 2-6 为堆垛式无人叉车物理结构解析,图中 1 为车轮,2 为承重板,3 为减震器,4 为簧载质量,5 为转向电机,6 为小转向齿轮,7 为大转向齿轮,8 为驱动电机,9 为货叉。



图 2-6 堆垛式无人叉车物理结构解析

为了提升精准定位与导航能力,不仅对堆垛式无人叉车的本体结构进行了优

化改造，还搭建了完整的导航平台，使其具备自主导航、智能搬运及路径规划等功能。经过这些优化升级，堆垛式无人叉车不仅能更好地适应复杂的作业环境，还可提升工作效率，满足多样化的应用需求，从而在智能物流和自动化仓储中发挥重要作用。堆垛式无人叉车的关键机械参数列于表 2-1。

表 2-1 堆垛式无人叉车机械结构主要参数

性能指标	参数	单位
轴距(2L)	L1	m
轮距(2H)	B	m
自重	1500	kg
额定载重	3000	kg
行驶速度	0.3~1.0	m/s
电源	48V 锂电池	——
行走电机功率	1500	kW
转向电机功率	750	kW

堆垛式无人叉车由控制模块、定位模块、安全模块、电源模块及人机交互模块等部分构成。其中，控制模块作为系统的核心，负责系统的协调与管理，确保堆垛式无人叉车的高效、可靠运行，该模块由主控制器和上位机组成，其主要职责是调度和指挥其他模块的协同工作。定位模块用于实时确定堆垛式无人叉车在作业环境中的位姿，并提供准确的位置信息，以支持导航与路径规划。安全模块用于保障堆垛式无人叉车在运行过程中的安全，通过安装避障雷达，实时检测潜在风险，并采取相应措施，防止与障碍物发生碰撞。电源模块不仅提供堆垛式无人叉车的运行动力，还需通过电路板进行升压或降压处理，以确保各部件正常工作，并提升系统运行效率。人机交互模块用于实际工作人员与堆垛式无人叉车之间的系统操作，能够高效地监控和控制其运行状态。控制系统各功能模块的结构示意图如图 2-7 所示。





图 2-7 控制系统各功能模块结构

2.3.2 控制系统硬件设计

针对堆垛式无人叉车的作业需求及工作场地特点，选取了激光雷达、IMU和激光避障雷达等关键传感器，确保堆垛式无人叉车运动状态的精准感知与有效控制。基于工厂内实际作业需求，对堆垛式无人叉车的控制系统进行硬件设计，以提升其在复杂环境中的适应性及任务执行能力。通过合理的硬件选型，堆垛式无人叉车能够实现更高精度的定位与路径规划，从而提高作业效率和运行安全性。该硬件改造不仅拓展了堆垛式无人叉车在工业场景中的应用范围，同时也为后续算法优化提供了硬件支撑。表 2-2 为各模块主要核心硬件参数指标。

表 2-2 各模块硬件参数指标表

名称	硬件设备	参数指标	设备图
控制模块	STM32 控制板	供电电压 DC 12-24V 通信协议 RS485 线性精度+0.05%FS 分辨率 17 位 量程 4000mm 电流 40mA	
	EI-52 工控机	线径规格 0.8mm 或 1.5mm 供电电压 DC 12-19V 通信协议 TCP/IP, UDP, RS485 功率 90w 运行内存 8G 磁盘空间 256G 接口资源 2 个网口, 6 个 USB 口, 2COM 口	
定位模块	激光雷达	线数 16 线 供电电压 DC 9-32V 通信协议 TCP/IP 激光波长 905nm 最大测距 150m 角分辨率 0.1° 扫描角度 360° 帧率 5Hz/10Hz/20Hz	
	IMU	供电电压 DC5-26V 轴数九轴 输出频率 400HZ 功耗 210mW	
安全模块	激光避障雷达	供电电压 DC 18-32V 通信协议 TCP/IP, UDP/IP 扫描半径 0.05m-5m 扫描角度 270° 分辨率 1mm 角分辨率 0.5° 工作频率 20HZ	
电源模块	锂电池	输出电压 48v 通信协议 RS485, CAN	
交互模块	LCD 触摸屏	-----	
	遥控器		



2.3.3 开发环境搭建

在确定堆垛式无人叉车的总体硬件架构后,下一步需明确各模块之间的通信方式,以确保系统的高效协调与可靠运行。本文选取 TCP/IP 协议与 UDP 协议作为通信方式,以满足不同模块的通信需求及系统稳定性要求。其中,选择 TCP/IP 协议的主要原因在于其可靠的数据传输能力,使得不同操作系统、网络类型或设备之间能够建立稳定的通信连接。相较而言,UDP 协议传输效率更高、时延更低,适用于实时性要求较高且数据量较小的场景。然而,堆垛式无人叉车在应用过程中对数据完整性与系统稳定性有较高要求,因此通信方式需结合具体应用场景合理选取。

在堆垛式无人叉车系统中,上位机通过任务调度将任务分发至各个执行单元,以实现整体任务的协调和执行。特别是在与激光雷达之间的通信中,稳定的 TCP/IP 连接对于实时获取和处理激光雷达数据至关重要。此外,堆垛式无人叉车的控制器采用 TCP/IP 协议与上位机建立通信连接。通过无线接入点(AP)实现连接,并经过合理的安装与配置,确保其处于同一网络段内,从而保证通信的稳定性。该方案不仅简化了系统的部署与管理,同时提升了系统的灵活性和可扩展性,便于后续优化与扩展。同时,使用了 CAN 协议来实现电池和电机之间的稳定通信。CAN 协议具备高度的可靠性和抗干扰能力,适合于车辆内部控制和传感器数据的快速传输,有效支持堆垛式无人叉车在复杂环境中的精准运动和控制。

堆垛式无人叉车为单舵轮驱动,通过单舵轮驱动设计和精确的控制策略,堆垛式无人叉车在灵活性、可靠性和控制简便性方面表现优异。综合应用多种传感器和通信协议,确保了系统的稳定运行和高效作业。如图 2-9 为堆垛式无人叉车的单舵轮控制流程图。




图 2-9 单舵轮控制流程图

堆垛式无人叉车的货叉配备了电动升降系统，采用 CAN 通信方式进行数据传输和控制。通过伺服电机和螺旋升降机构实现货叉高度的精确调节，确保货物能够安全稳定地搬运到指定位置。货叉控制系统的设计和实施不仅提高了搬运的效率，还增强了系统的可靠性和稳定性。如图 2-10 所示为货叉控制流程图。




图 2-10 货叉流程控制图

2.4 堆垛式无人叉车导航系统设计

堆垛式无人叉车的研究重点在于其导航方式，不同的当行方式所需要的硬件选型和软件系统是各不相同的。一个定位精度高、性能稳定的导航方式，是堆垛式无人叉车进行高效作业的必然要求。结合上节所设计的控制系统，本章节从定位导航精度着手考虑，并结合工程实际需求，从主流导航方式中，选中了激光导航作为本文的研究重点。

2.4.1 导航系统总体架构

为了实现堆垛式无人叉车的高效、精准和安全运行，选择合适的导航系统至关重要。结合堆垛式无人叉车作业环境，目前市面上主流的导航方式有磁导航、二维码导航、视觉导航、激光导航等，本文选择激光导航作为组合导航方式，三维激光雷达凭借其高精度和稳定性，成为堆垛式无人叉车导航的理想选择。

结合堆垛式无人叉车作业环境需求，本文采用激光雷达结合 IMU 的信息融合导航方式，以实现堆垛式无人叉车的精确定位与导航。IMU 通过检测堆垛式无人叉车的角速度，提供实时的姿态和状态信息；激光雷达则通过扫描周围环境，实时获取障碍物信息并提供高精度的位置信息。如图 2-11 所示，展示了堆垛式无人叉车的总体系统框架图。



图 2-11 堆垛式无人叉车总体系统框架图




图 2-13 软件框架搭建

根据堆垛式无人叉车的功能需求，软件系统需要实现数据处理与传输、无线通信、驱动控制及超声波避障等关键任务。具体的任务逻辑设计如下：首先，系统进行初始化操作，完成各硬件模块的初始化，为后续任务的执行提供基础。随后，激光雷达数据处理与传输模块负责处理激光雷达获取的环境数据，提取特征点并进行重定位，处理结果会被发送到车载上位机，同时 IMU 的信息也会传送到车控端。接下来，驱动模块通过控制电机来实现堆垛式无人叉车的行驶。无线

通信部分通过车载端的无线 AP 与 PC 进行连接，确保数据传输的顺畅进行。最后，避障模块在激光避障雷达检测到障碍物时，及时发送避障信息并控制电机进行停车。堆垛式无人叉车的任务执行流程如图 2-14 所示。




图 2-14 任务执行流程图

2.5 堆垛式无人叉车模型分析

2.5.1 堆垛式无人叉车运动学建模

本节利用刚体平面运动瞬心法进行分析，解算定位中心内堆垛式无人叉车的舵轮转速，根据堆垛式无人叉车的实际物理结构，分别建立载体坐标系和世界坐标系，从而求取相对于当前前一刻位置角度变化的当前瞬间。

图 2-15 展示了堆垛式无人叉车的运动学模型框架,图 2-16 则通过 t 至 $t+1$ 时刻的运动示意图阐明其动态演化的过程。将世界坐标系原点设为 O , 假设堆垛式无人叉车从 O_L 点起步, 行驶至 O'_L 处, 在叉车的运动过程中, 当前位置状态仅与前一时刻的状态相关, 具体参数对应表 2-3 所列的符号定义。




图 2-15 堆垛式无人叉车运动学模型




图 2-16 堆垛式无人叉车 t 到 $t+1$ 时刻运动示意

表 2-3 运动模型参数表

符号	名称	符号	名称
A	舵轮回转中心	P _i	t 时刻无人叉车的位置
B	从动轮滚动中心	ϕ_i	t 时刻无人叉车的角度
C	从动轮滚动中心	r	瞬时回转半径
ϕ	转向角	ω	瞬时角速度
p	前后轮轴线交点	v_i	i 时刻瞬时线速度
l	轴距	d	两从动轮 1/2 轮距
ϕ	车身在世界系角度	O	从动轮轴线几何中心

由于改进的堆垛式无人叉车采用单舵轮驱动设计，需将舵轮的角速度与线速度映射至回转中心以适配货叉的定位需求，通过对舵轮运动进行分解，可推导其速度关系表达式：

$$\begin{cases} v_x = v \cos \phi \\ v_y = v \sin \phi \\ r = l / \tan \phi \end{cases} \quad (2-20)$$

结合堆垛式无人叉车结构参数，进一步将舵轮运动至定位中心可得：

$$\begin{cases} v_d = v_y \\ \omega = lv_x \end{cases} \quad (2-21)$$

定义 t 时刻堆垛式无人叉车的位姿为 $P_t = (x_t, y_t, \phi_t)$ ， $t+1$ 时刻位姿为 $P_{t+1} = (x_{t+1}, y_{t+1}, \phi_{t+1})$ ，采样时间为 Δt ，则位姿更新关系可表述为：

$$\begin{bmatrix} x_{t+1} \\ y_{t+1} \\ \phi_{t+1} \end{bmatrix} = \begin{bmatrix} x_t \\ y_t \\ \phi_t \end{bmatrix} + \begin{bmatrix} \Delta t \cos \phi_t & 0 \\ \Delta t \sin \phi_t & 0 \\ 0 & \Delta t \end{bmatrix} \begin{bmatrix} v_d \\ \omega \end{bmatrix} \quad (2-22)$$

式中： ϕ_{t+1} 为 $t+1$ 时刻的偏航角； x_{t+1} 与 y_{t+1} 为对应位置坐标； ϕ_t 为 t 时刻的航向角。

2.5.2 堆垛式无人叉车运动学仿真分析

为了全面评估堆垛式无人叉车在不同路径条件下的运动表现及其轨迹跟踪精度，本节基于 MATLAB 平台开展运动学仿真分析，重点研究直线路径与曲线路径下叉车的运动特性。该分析旨在模拟实际应用场景中可能遇到的定位误差与控制精度问题，从而为优化导航控制策略提供理论依据。

本实验依托堆垛式无人叉车的运动学模型，结合理论轨迹与实际轨迹的对比，定量评估其在不同工况下的运动性能。具体而言，实验设计分为两种路径形式：直线路径和曲线路径。其中，直线路径实验设定叉车沿 0-10 m 的直线轨迹运行，以调度站点模式执行任务，运动速度设定为 0.5 m/s，且货叉高度始终保持在 1 m 不变。通过分析堆垛式无人叉车在此路径上的位姿变化，可以验证其在直线行驶精度。

另一方面，曲线路径实验进一步考察堆垛式无人叉车在非线性路径上的运动

控制能力,通过对比理论轨迹与实际轨迹,分析运动学模型在复杂路径条件下的适用性,并探讨可能影响定位精度的因素,如轮胎滑移、传感器误差对控制精度的影响。




图 2-17 直线轨迹对比图




图 2-18 直线轨迹平面投影图






图 2-19 直线轨迹 x 坐标对比图

图 2-20 直线轨迹 y 坐标对比图图 2-21 直线轨迹 z 坐标对比图

根据图 2-17、图 2-18、图 2-19、图 2-20 以及图 2-21 可知，在直线轨迹行驶过程中， x 坐标最大位置误差为 0.08m， y 坐标反映了堆垛式无人叉车在直线运动中的横向偏移， y 坐标最大横向误差为 0.05m，由于货叉高度不变， z 坐标最大高度误差为 0.03m。




图 2-22 曲线轨迹对比图




图 2-23 曲线轨迹平面投影图




图 2-24 曲线轨迹 x 坐标对比图





图 2-25 曲线轨迹 y 坐标对比图

图 2-26 曲线轨迹 z 坐标对比图

根据图 2-22、图 2-23、图 2-24、图 2-25 以及图 2-26 可知，在拐弯区域 x 坐标最大误差为 0.12 m， y 坐标在拐弯过程中的最大横向误差为 0.15 m，表明堆垛式无人叉车在曲线运动中的跟踪精度下降， z 坐标最大高度误差为 0.04 m。

2.6 堆垛式无人叉车误差机理分析

2.6.1 堆垛式无人叉车垂向动力学建模

在堆垛式无人叉车行驶过程中，地面不规则激励会对车轮系统产生影响，导致轮胎变形及垂向振动。为了进行深入研究，本节基于堆垛式无人叉车的垂向动力学特性，建立相应的数学模型。当舵轮系统受到路面激励时，其动态响应主要表现为垂向位移和变形。为简化分析过程，可将其视作等效弹簧-阻尼系统，并运用动力学方法探讨车轮与地面之间的相互作用。通过对不同路况下的振动特性进行建模分析，可以评估堆垛式无人叉车的动态稳定性，并优化其行驶性能。此外，堆垛式无人叉车的整体结构对地面激励具有显著的动态响应，这种响应将直接影响其运动平稳性。因此，需要构建一个包含刚体运动及轮胎-地面接触特性的动力学模型，以便更全面地理解堆垛式无人叉车在复杂路面环境中的运动行为。

为了进一步分析低速行驶工况下舵轮的等效悬架受力情况，本研究建立了堆垛式无人叉车的等效悬架垂向动力学模型，其结构如图 2-27 所示。该模型可用于研究不同悬架参数对车辆振动特性的影响，为叉车的结构优化与性能提升提供理论支持。




图 2-27 垂向动力学模型示意图

表 2-4 动力学建模参数图

符号	名称	符号	名称
L_1	前轮到质心 X 轴方向距离	z_{si}	车身位移
L_2	后轮到质心 X 轴方向距离	z_{ri}	地面的起伏量
m_s	整车质量	k_{si}	各轮等效悬架弹性刚度
m_{ui}	各车轮质量	k_{ti}	各轮等效弹性刚度
F_i	各轮悬架受到的力	f_i	各轮等效悬架阻尼系数
z	车身垂向位移	θ	车身俯仰角
z_{ui}	车轮垂向位移	O	瞬心坐标系原点

通过图 3-1 可知，以微分方程描述车身与车轮的垂向运动：

$$m_s \ddot{z} = F_1 + F_2 + F_3 \quad (2-23)$$

$$\begin{cases} m_{u1}\ddot{z}_{u1} = k_{t1}(z_{r1} - z_{u1}) - F_1 \\ m_{u2}\ddot{z}_{u2} = k_{t2}(z_{r2} - z_{u2}) - F_2 \\ m_{u3}\ddot{z}_{u3} = k_{t3}(z_{r3} - z_{u3}) - F_3 \end{cases} \quad (2-24)$$

各轮悬架受力表达式为：

$$\begin{cases} F_1 = k_{s1}(z_{s1} - z_{u1}) + f_1(\dot{z}_{s1} - \dot{z}_{u1}) \\ F_2 = k_{s2}(z_{s2} - z_{u2}) + f_2(\dot{z}_{s2} - \dot{z}_{u2}) \\ F_3 = k_{s3}(z_{s3} - z_{u3}) + f_3(\dot{z}_{s3} - \dot{z}_{u3}) \end{cases} \quad (2-25)$$

此外，堆垛式无人叉车在运动时车身会产生一定程度的俯仰，其角度称为俯仰角 θ ，对 z_{si} 分析可得：

$$\begin{cases} z_{s1} = z + L_1\theta \\ z_{s2} = z - L_2\theta \\ z_{s3} = z - L_2\theta \end{cases} \quad (2-26)$$

车身俯仰运动微分方程为：

$$I_y\ddot{\theta} = F_1L_1 - (F_2 + F_3)L_2 \quad (2-27)$$

路面垂向激励通过滤波白噪声法生成为：

$$\dot{z}_{ri} = -2\pi f_0 z_0 + 2\pi\omega(t)\sqrt{G_0(n_0)}v \quad (2-28)$$

式中： f_0 为下截止频率； $\omega(t)$ 为均值为零的高斯白噪声信号； G_0 为路面不平整系数； v 为堆垛式无人叉车行驶速度； η_0 为参考空间频率。

2.6.2 堆垛式无人叉车舵轮形变分析

在堆垛式无人叉车运行过程中，舵轮等效半径的动态变化是影响定位精度的关键因素。由于车身载荷与地面激励的共同作用，舵轮材料发生弹性形变，导致其实际外形偏离理想几何轮廓。这种形变将引发测量值与真实值之间的偏差，且偏差量随运行时间逐步累积，最终降低导航系统的定位精度。为量化误差，需通过几何关系求解舵轮在动态工况下的实际有效半径 r_e ，其形变示意如图 2-28 所示。




图 2-28 舵轮形变示意图

如图 2-28 所示，舵轮中心垂线与接触印迹间的夹角记为 ρ ，舵轮与地面接触区域纵向长度的半值记为 l_d ， r_d 和 r_w 分别对应静态与未变形状态下的舵轮半径，舵轮角速度记为 ω ，垂向形变量记为 Δs 。根据几何关系可推导以下方程：

$$\begin{cases} r_d = r_w \cos \rho \\ l_d = r_w \sin \rho \end{cases} \quad (2-29)$$

进一步结合线速度与角速度的关系：

$$\begin{cases} v = r_e \omega = \frac{l_d}{t} \\ \omega = \frac{\rho}{t} \end{cases} \quad (2-30)$$

式中： t 为时间变量。

静态半径 r_d 与未变形半径 r_w 的关联式为：

$$r_d = r_w - \Delta s \quad (2-31)$$

最终得出实际有效半径 r_e 为：

$$r_e = \frac{r_w \sin \rho}{\varphi} = \frac{r_w \sin \left[\arccos \left(1 - \frac{\Delta s}{r_w} \right) \right]}{\arccos \left(1 - \frac{\Delta s}{r_w} \right)} \quad (2-32)$$

2.6.3 堆垛式无人叉车动力学仿真模型搭建

基于 MATLAB/Simulink 平台，构建堆垛式无人叉车运动学仿真模型，如图 2-19 所示，研究不同负载条件下舵轮的形变特性。仿真参数严格遵循 ISO/DIS8608

标准，具体数值详见表 2-5。通过仿真输出舵轮垂向位移、垂向形变量、及有效半径变化，如图 2-30、图 2-31、图 2-32 所示。

表 2-5 舵轮垂向变形仿真参数表

符号	名称	数值	符号	名称	数值
f_1/f_4	舵轮等效悬架阻尼系数	26 kN·s/m	f_2/f_3	从动轮悬架阻尼系数	100 kN·s/m
k_{t1}/k_{t4}	舵轮等效刚度系数	1000 N/m	k_{t2}/k_{t3}	从动轮等效刚度系数	900 N/m
k_{s1}/k_{s4}	舵轮悬架刚度系数	200 N/m	k_{s2}/k_{s3}	从动轮悬架刚度系数	2800 N/m
m_{u1}/m_{u4}	舵轮质量	30 kg	m_{u2}/m_{u3}	从动轮质量	6 kg
r_w	舵轮半径	0.13 m	m_s	整车质量	1500 kg
L_1	前轮到质心 X 方向距离	1 m	L_2	后轮到质心 X 方向距离	1 m
f_0	下截止频率	0.01	G_0	路面不平整系数	256
η_0	参考空间频率	0.1			




图 2-29 动力学模型 Simulink 仿真计算示意图




图 2-30 舵轮垂向位移




图 2-31 舵轮垂向变形




图 2-32 舵轮有效半径

仿真结果如表 2-6 所示。

表 2-6 舵轮变形表

负载情况	最大变形	最大位移
空载	11.961mm	12.935mm
负载1000kg	19.893mm	16.754mm
负载2000kg	27.934mm	24.016mm

仿真结果如表 2-6 表明，空载时舵轮最大垂向形变为 11.961 mm，位移达 12.935 mm；负载 1000 kg 时形变量增至 19.893 mm，位移为 16.754 mm；负载 2000 kg 时进一步升至 27.934 mm 与 24.016 mm。图 2-30 至图 2-32 所示，形变量与位移呈先增后减趋势，此现象源于舵轮材料的弹性恢复特性，且形变程度与负载呈显著正相关。空载至 2000 kg 负载时，形变量与位移分别增加 15.973 mm 与 11.081 mm。

2.7 本章小结

本章为后续章节中定位系统的传感器融合方法奠定理论基础。首先，通过建立激光雷达与 IMU 的观测模型，详细阐述各传感器的数学模型及其工作原理，为传感器数据融合提供关键理论支撑。其中，激光雷达观测模型描述了激光雷达

获取环境信息，而 IMU 惯性解算模型则基于加速度计和陀螺仪数据推算车辆的运动状态及姿态。其次，本章构建了堆垛式无人叉车的控制系统，设计了系统总体架构，完成了核心硬件选型，并搭建了开发环境，以确保系统的可靠性和可扩展性。在此基础上，进一步搭建了堆垛式无人叉车的导航系统，详细介绍了导航系统的总体架构及其实现方案，为后续的定位提供支持。此外，本章深入分析了堆垛式无人叉车的运动学特性。通过建立堆垛式无人叉车的动力学与运动学模型，系统研究了叉车在不同运行工况下的受力与运动特性，并推导了相应的运动控制约束条件。最后，针对堆垛式无人叉车的舵轮驱动特性，本章进一步探讨了舵轮形变对定位精度的影响，并结合动力学建模分析其对导航系统稳定性的潜在影响。上述研究内容为后续章节中传感器融合及优化方法的设计提供了理论依据和实践支撑。

第3章 基于直接点云处理与IMU融合自适应IEKF算法

3.1 引言

在第二章中,本文对舵轮形变导致的误差机理进行了深入分析,激光雷达通过高精度点云匹配可实时获取车辆位姿信息,而IMU通过惯性解算提供短时高频率的运动状态数据。二者融合后,可构建误差观测模型,动态修正舵轮形变引起的偏差。需要指出的是,定位精度的误差来源不仅限于舵轮形变,也存在于信息融合中。尽管激光雷达和IMU都能为定位提供必要的信息,但各自存在的局限性使得单独使用时难以达到理想的定位精度。激光雷达能够生成密集的环境点云信息,然而其采样频率相对较低,无法提供足够高频的动态响应,导致在快速运动和快速变化的环境中存在较大的滞后和定位误差。此外,IMU虽然可以提供高频率的姿态、速度和加速度信息,但由于其内部传感器存在噪声、偏置以及长期积累的误差,其单独使用时会在时间上逐渐偏离真实值,造成系统定位精度的严重下降。因此,如何将这两种传感器优势互补,充分发挥各自的优点,并克服其局限性,成为提升定位精度的关键。

目前,经典的扩展卡尔曼滤波(Extend Kalman Filter, EKF)已被广泛应用于激光雷达和IMU的融合定位中。然而,EKF方法在处理非线性系统时,可能会因为滤波增益不稳定和数值收敛问题而导致估计精度降低,尤其是在激光雷达和IMU之间存在强烈非线性关系的情况下。为了克服这些问题,本章选用迭代扩展卡尔曼滤波(Iterated Extended Kalman Filter, IEKF)。与EKF相比,IEKF通过增量更新卡尔曼增益,能够在每次迭代时更好地处理系统的非线性,从而有效地提高定位的精度和稳定性。

然而在实际应用中,IMU和激光雷达传感器数据的同步、精确的点云处理以及状态估计的实时性问题,仍然是影响系统性能的主要原因。传统的点云处理方法多依赖于特征提取和匹配技术,这些方法在计算上通常较为复杂且存在匹配误差。与此不同,直接点云处理方法通过直接利用点云数据进行优化,避免了特征提取和匹配过程中的误差,从而提高了点云处理的精度和效率。

为了解决上述问题,本章提出了一种基于直接点云处理的激光雷达与IMU紧耦合融合自适应迭代次数调整的IEKF算法。该方法在紧耦合的基础上,采用

直接点云处理技术优化激光雷达数据的处理过程，结合 IMU 的高频运动信息进行状态估计。通过引入自适应迭代次数调整机制，根据状态估计的精度和误差动态调整迭代次数，能够有效提升定位系统的实时性和精度。

本章将详细介绍该方法的基本原理、核心算法以及实现步骤，首先分析激光雷达与 IMU 的工作原理与数据特性，接着介绍紧耦合融合的方法，并阐述直接点云处理在提高定位精度方面的优势。最后，结合 IEKF 算法和自适应迭代次数调整机制，提出了一种全新的激光雷达与 IMU 融合定位方案，提升了系统的状态估计精度和鲁棒性。

3.2 基于多维信息融合的问题描述及分析

3.2.1 扩展卡尔曼滤波中的非线性误差问题

EKF 是处理非线性系统状态估计的广泛使用方法。它通过对非线性状态转移方程和观测方程进行局部线性化，以适应卡尔曼滤波框架，图 3-1 为扩展卡尔曼滤波的流程图。然而，EKF 在应用中存在一些固有的非线性误差问题，尤其是由于线性化近似引起的误差。本节将详细探讨 EKF 中的非线性误差及其来源。




图 3-1 扩展卡尔曼滤波流程图

(1) 非线性系统模型

考虑一个具有非线性特性的动态系统，其状态方程和观测方程可表示为：

1.状态转移方程：

$$x_{k+1} = f(x_k, u_k) + w_k \quad (3-1)$$

式中： x_k 是时刻 k 的状态向量； u_k 是控制输入； $f(x_k, u_k)$ 是非线性状态转移函数； w_k 是过程噪声，通常假设为零均值高斯噪声，协方差矩阵为 Q_k 。

2.观测方程：

$$z_k = h(x_k) + v_k \quad (3-2)$$

式中： z_k 是时刻 k 的测量值； $h(x_k)$ 是非线性观测模型； v_k 是测量噪声，通常假设为零均值高斯噪声，协方差矩阵为 R_k 。

3.线性化过程

由于 $f(x_k, u_k)$ 和 $h(x_k)$ 的非线性特性，EKF 通过一阶泰勒展开对这些方程进行线性化。线性化后，系统模型如下：

状态转移方程的线性化为：

$$f(x_k, u_k) \approx f(\tilde{x}_k, u_k) + F_k(x_k - \tilde{x}_k) \quad (3-3)$$

F_k 是对状态转移方程的雅可比矩阵：

$$F_k = \frac{\partial f(x_k, u_k)}{\partial x_k} \quad (3-4)$$

观测方程的线性化为：

$$h(x_k) \approx h(\tilde{x}_k) + H_k(x_k - \tilde{x}_k) \quad (3-5)$$

H_k 是观测方程的雅可比矩阵：

$$H_k = \frac{\partial h(x_k)}{\partial x_k} \quad (3-6)$$

(2) EKF 中的误差来源

EKF 中的非线性误差主要来源于线性化误差、积累误差和状态不一致性。首先，EKF 在对非线性系统进行线性化时，仅采用一阶泰勒展开，未考虑高阶

非线性项,因此在处理强非线性系统时,线性化模型与真实系统之间的偏差较大,导致估计精度下降。其次,EKF的状态预测依赖于IMU的加速度和角速度积分操作,这些传感器噪声会随时间积累,尤其是在测量更新频率较低的情况下,累积的误差会显著影响状态估计的准确性。此外,EKF假设状态更新在欧几里得空间进行,但实际的旋转和位姿等状态变量属于李群,这种几何结构的不一致性会进一步引发误差,影响滤波器的精度和稳定性。

3.3 激光雷达与IMU紧耦合系统构建

激光雷达与IMU的紧耦合融合,旨在将两种传感器的优势结合起来,从而提高系统的定位精度与稳定性。激光雷达提供高精度的环境观测,但其更新频率较低;IMU提供高频率的运动数据,但其容易受到噪声与漂移的影响。因此,利用IMU的运动估计和激光雷达的点云数据进行融合,有助于克服各自的局限。基于直接点云处理的紧耦合方法的主要思想是,不依赖于特征提取,而是直接在IMU提供的运动估计下进行点云数据的配准与优化,从而实现高精度的定位与建图。与传统的基于特征的方法相比,直接点云处理能够更好地处理复杂环境中的非线性误差,并且减少了计算开销。

3.3.1 紧耦合系统分析

紧耦合方法的核心思想是将IMU的运动状态估计与激光雷达的观测信息结合,利用两者的数据相互补充。相比于传统的松耦合方法,紧耦合方法在状态估计过程中将IMU和激光雷达的观测数据同时引入滤波算法中,这样能够更好地处理两者的时间同步和观测间的相关性。

在紧耦合系统中,IMU的状态估计提供了一个粗略的定位和运动估计,而激光雷达提供了高精度的环境观测信息。在传统的扩展卡尔曼滤波框架中,系统的状态方程和观测方程被联合起来,形成一个非线性估计问题。通过将IMU的运动学模型和激光雷达的观测模型结合,能够实现最优的状态估计。图3-2为激光雷达与IMU紧耦合流程图。




图 3-2 激光雷达与 IMU 紧耦合流程图

状态方程基于 IMU 提供的运动学模型，表示为：

$$x_{k+1} = x_k + \Delta t \cdot f(x_k, a_k, \omega_k) + \omega_k \quad (3-7)$$

式中： ω_k 为过程噪声。

激光雷达的观测方程与 IMU 的状态估计相关，可以表示为：

$$z_k = h(x_k) + v_k \quad (3-8)$$

式中： $h(x_k)$ 是由 IMU 状态计算得到的激光雷达观测值； v_k 是观测噪声。

3.3.2 数据预处理

在激光雷达与 IMU 紧耦合系统中，传感器数据的质量直接影响到状态估计的精度和系统的鲁棒性。激光雷达和 IMU 作为两种不同类型的传感器，其原始数据通常包含噪声、零偏误差、尺度因子误差以及时间不同步等问题。因此，传感器数据预处理是紧耦合系统中不可或缺的环节。通过对激光雷达点云和 IMU 数据进行预处理，可以有效消除数据中的噪声和误差，为后续的点云配准、状态估计和数据融合提供高质量的输入。图 3-3 为数据预处理过程。




图 3-3 数据预处理过程

激光雷达点云数据通常包含噪声和无效点（如地面点、远处点等），这些噪声和无效点会影响后续处理的精度。因此，点云预处理是紧耦合系统的首要任务。激光雷达点云预处理首先是去噪，使用统计滤波去除离群点，统计滤波通过计算每个点的邻域统计特性（均值、方差）来识别噪声点，公式如下：

$$\text{Noise}_i = \begin{cases} 1, & \text{if } \|p_i - \overline{p_i}\| > \tau \\ 0, & \text{otherwise} \end{cases} \quad (3-9)$$

式中： p_i 为第 i 个点； $\overline{p_i}$ 为其邻域点的均值； τ 为噪声阈值。

随即进行地面点去除，使用平面拟合方法去除地面点；最后是降采样，使用体素网格滤波对点云进行降采样，以减少数据量并提高处理效率，体素网格滤波的数学表达式为：

$$p_{\text{voxel}} = \frac{1}{N} \sum_{i=1}^N p_i \quad (3-10)$$

式中： p_{voxel} 为提速网格内的代表点； N 为网格内的点数。

IMU 数据通常包含零偏误差、尺度因子误差和随机噪声，这些误差会随着时间的推移而累积，严重影响状态估计的精度。因此，IMU 数据预处理是紧耦合系统中至关重要的一环。IMU 数据预处理首先是零偏补偿，IMU 的加速度计和陀螺仪在静态条件下会输出非零值，这种现象称为零偏误差。零偏误差会随着时间的推移而累积，导致状态估计的漂移。零偏误差模型分为加速度计的零偏误差模型和陀螺仪的零偏误差模型，加速度计的零偏误差模型为：

$$a_{\text{meas}} = a_{\text{true}} + b_a + n_a \quad (3-11)$$

式中： a_{meas} 为测量值； a_{true} 为真实值； b_a 为零偏误差； n_a 为随机噪声。

陀螺仪的零偏误差模型为：

$$\omega_{\text{meas}} = \omega_{\text{true}} + b_g + n_g \quad (3-12)$$

式中： ω_{meas} 为测量值； ω_{true} 为真实值； b_g 为零偏误差； n_g 为随机噪声。

零偏补偿方法为静态零偏补偿，在静态条件下，通过长时间的平均值估计零偏误差：

$$\begin{cases} b_a = \frac{1}{N} \sum_{i=1}^N a_{\text{meas},i} \\ b_g = \frac{1}{N} \sum_{i=1}^N \omega_{\text{meas},i} \end{cases} \quad (3-13)$$

式中： N 为静态条件下的采样点数。

3.3.3 激光雷达与 IMU 的时钟源统一

在多传感器融合系统中，不同传感器的数据采集频率和时钟源往往不一致，尤其是 IMU 和激光雷达，由于采样频率差异显著：IMU 频率较高，激光雷达频率较低，导致两者的时间戳不同步，激光雷与 IMU 时间戳如图 3-4 所示。这种不一致性会引入时间延迟误差，影响后续状态估计和融合算法的准确性。因此，为解决多传感器的时钟源统一的问题，本文利用三次样条插值方法在时间轴上对 IMU 和激光雷达数据进行对齐，实现时钟源的统一，可以有效提高数据同步的精度和多传感器融合的效果。




图 3-4 激光雷达与 IMU 时间戳

接下来进行三次样条插值模型构建与约束条件，获取 $n+1$ 个 IMU 的数据点 $(t_0, x_0), (t_1, x_1), \dots, (t_n, x_n)$ ，以及一组激光雷达的采样时间点 t_{LIDAR} ，目标是在该时间点上估计 IMU 状态值。三次样条插值方法在相邻的 IMU 数据点之间 $[t_i, t_{i+1}]$ 构造一个三次多项式 $S_i(x)$ ：

$$S_i(x) = a_i + b_i(x - t_i) + c_i(x - t_i)^2 + d_i(x - t_i)^3 \quad (3-14)$$

完成三次样条插值模型构建后，为确保插值曲线的连续性和光滑性，三次样条插值函数需满足插值条件、一阶导数连续性、二阶导数连续性、边界条件，具

体如下：

插值条件为样条函数需在各节点处满足观测值，即：

$$S_i(t_i) = x_i \quad (3-15)$$

$$S_i(t_{i+1}) = x_{i+1} \quad (3-16)$$

保证样条函数在各连接点处的一阶导数连续，即：

$$S'_i(t_{i+1}) = S'_{i+1}(t_{i+1}) \quad (3-17)$$

保证样条函数在各连接点处的二阶导数连续，即：

$$S''_i(t_{i+1}) = S''_{i+1}(t_{i+1}) \quad (3-18)$$

边界条件通常采用自然边界条件，假设样条函数在边界点的二阶函数为零：

$$S''_0(t_0) = 0 \quad (3-19)$$

$$S''_{n-1}(t_n) = 0 \quad (3-20)$$

基于上述插值流程，将 IMU 数据在激光雷达的采样时间点上进行插值，从而生成与激光雷达时间戳一致的 IMU 状态值，需将 IMU 数据点设为三次样条的节点，构建三次样条插值函数 $S(t)$ ；对于每个激光雷达的时间戳 t_{LIDAR} ，通过插值函数 $S(t_{LIDAR})$ 计算对应的 IMU 状态值；将插值后的 IMU 数据与激光雷达数据同步，形成统一的时间轴，为多传感器融合算法提供输入，图 3-5 为插值结果。




图 3-5 三次样条插值结果

三次样条插值方法在时钟源统一方面展现出显著优势。首先，该方法能够保证 IMU 数据的平滑性和连续性，且在激光雷达时间点上提供精确的状态估计，显著降低了数据同步过程中的插值误差。其次，三次样条插值对于高频 IMU 数

据的实时同步需求具有较好的适应性，有助于提升系统的实时性和鲁棒性，特别是在对时间同步精度要求较高的场景下，表现尤为出色。

3.3.4 点云配准

点云配准是将当前时刻激光雷达采集到的点云与上一时刻的点云进行对齐，进而估算相对位姿。传统的配准方法通常基于特征提取和匹配，而直接点云处理方法通过所有点的几何信息进行配准，避免了特征匹配过程中的误差。

在 IMU 提供的运动估计下，点云配准的目标是找到最优的位姿变换矩阵 T （包括旋转和平移），使得当前点云和上一时刻点云之间的几何误差最小：

$$T = \arg \min \sum_{i=1}^n \|T \cdot p_i - p_{i-1}\|^2 \quad (3-21)$$

式中： p_i 是当前时刻的点云数据； p_{i-1} 是上一时刻的点云数据； T 是待估计的位姿变换矩阵。

3.3.5 优化与状态估计

点云配准后，通过优化算法对 IMU 的运动预测和激光雷达的点云数据进行联合优化，从而得到最优的位姿估计。该过程主要通过最小化 IMU 运动预测与激光雷达点云之间的误差来进行。

假设 z_{LIDAR} 是激光雷达的观测数据， z_{IMU} 是 IMU 的观测数据， x_k 是 IMU 的状态估计，优化目标函数可以表示为：

$$E = \sum_{i=1}^n \|z_{LIDAR,i} - h(x_k)\|^2 + \lambda \|z_{IMU} - g(x_k)\|^2 \quad (3-22)$$

式中： $h(x_k)$ 表示 IMU 状态下的激光雷达预测函数； $g(x_k)$ 表示 IMU 的运动模型； λ 是平衡激光雷达观测与 IMU 估计的权重系数。

通过最小化该误差函数，能够同时更新 IMU 的运动状态和激光雷达的位姿估计，从而实现高精度的状态估计。

3.4 基于 IEKF 算法的多维信息融合

3.4.1 IEKF 算法研究

IEKF 算法是在基于 EKF 算法的基础上所提出的一种改进算法。基于 EKF 在对非线性函数进行一阶泰勒级数展开后得到一个近似线性化模型的过程中，易产生非线性误差的问题。IEKF 在测量更新阶段上将上一步修正后的输出作为下一次迭代修正误差的输入值，通过多次迭代来修正和减小误差。

表 3-1 IEKF 融合参数表

符号	名称	符号	名称
x_k	当前 k 时刻状态	x_{k-1}	$k-1$ 时刻状态
u_k	输入量	z_k	观测状态
w_{k-1}	状态过程噪声	V_k	观测噪声
c	状态过程噪声常系数	g	观测噪声常系数
H	线性化的观测函数	F	观测函数的状态函数

由此可得，非线性系统的状态估计和观测模型表示为：

$$x_k = f(x_{k-1}, u_k) + w_{k-1} \quad (3-23)$$

$$z_k = h(x_k) + V_k \quad (3-24)$$

式中： f 为系统状态转移函数； h 为观测函数； u_k 为控制输入； x_k 表示堆垛式无人叉车的当前状态； x_{k-1} 表示堆垛式无人叉车上一刻状态； $V_k \sim N(0, Q(k))$ 表示观测噪声； $w_k \sim N(0, R(k))$ 表示状态过程噪声，且均符合零均值高斯白噪声。

由于 f 和 h 为非线性函数，采用泰勒公式展开进行线性化处理，整理可得系统的状态方程为：

$$x_k \approx \frac{\partial f(x_{k-1}, u_k)}{\partial x_{k-1}} x_{k-1} + w_{k-1} = Fx_{k-1} + cw_{k-1} \quad (3-25)$$

同时，系统的观测方程为：

$$z_k \approx \frac{\partial h(x_k)}{\partial x_k} h(x_k) + V_k = Hx_k + gV_k \quad (3-26)$$

3.4.2 基于 IEKF 融合激光雷达与 IMU

EKF 算法在应用中存在一些固有的非线性误差问题，因此，本文采用 IEKF 算法，拟增强定位精度，在进行 IEKF 算法融合激光雷达与 IMU 时，首先需要进行状态向量 X_0 和协方差矩阵 P_0 的初始化。其次，在对堆垛式无人叉车进行状态估测时，根据状态转移矩阵，利用第 k 时刻的状态量推测出第 $k+1$ 时刻的状态：

$$X^{\sim}(k+1) = f[k, X^{\sim}(k)] \quad (3-27)$$

由此可得，状态预测协方差方程为：

$$P(k+1) = F(k)P(k)F(k)^T + Q(k) \quad (3-28)$$

F 为 f 的雅可比矩阵，计算测量雅可比矩阵为：

$$F(k) = \frac{\partial f[X(k)]}{\partial X(k)} \quad (3-29)$$

根据定义中的非线性观测矩阵 $h(x_k)$ ，结合堆垛式无人叉车的状态估计 $X^{\sim}(k+1)$ 和位置 $X_i = (x_i, y_i)$ ，可得当前时刻的量测预测值为：

$$Z^{\sim}(k+1) = h[X^{\sim}(k+1)] \quad (3-30)$$

当传感器新的量测 $Z(k+1)$ 到来之后，对新息和滤波器增益进行计算，并进行状态修正。新息方程为：

$$\tau(k+1) = Z(k+1) - Z^{\sim}(k+1) \quad (3-31)$$

式中： H 为 h 的雅可比矩阵，对应的新息协方差方程为：

$$S(k+1) = H(k+1)P(k+1)H(k+1)^T + R(k) \quad (3-32)$$

则 H 为：

$$H(k+1) = \frac{\partial h[X(k+1)]}{\partial X(k+1)} \quad (3-33)$$

此时，滤波器的增益矩阵方程为：

$$W(k+1) = P(k+1)H(k+1)^T S(k+1)^{-1} \quad (3-34)$$

对应的堆垛式无人叉车状态更新为：

$$X_+(k+1) = X^-(k+1) + W(k+1)\tau(k+1) \quad (3-35)$$

状态协方差更新方程为：

$$P_+(k+1) = P(k+1) - W(k+1)S(k+1)W(k+1)^T \quad (3-36)$$

$$X^-(k+1) = X_+(k+1) \quad (3-37)$$

$$P(k+1) = P_+(k+1) \quad (3-38)$$

将上式代入状态修正进行计算，所得结果重新按迭代更新进行赋值。在不影响计算效率的前提下，根据实际情况设置迭代次数。循环迭代之后，最终得到较为精确的堆垛式无人叉车位姿估计 $X(k) = [x(k), y(k), \varphi(k)]^T$ 。

3.5 基于 IEKF 多维信息融合的自适应迭代方法

在激光雷达与 IMU 紧耦合系统中，状态估计的精度和鲁棒性直接依赖于滤波算法的性能。传统的 IEKF 通过固定卡尔曼增益来平衡预测值与观测值的权重，然而，在复杂动态环境中，传感器数据的噪声特性、环境动态性以及系统非线性等因素可能导致固定卡尔曼增益方法的性能下降。为此，本节提出一种基于卡尔曼增益的动态调整策略，通过实时评估系统状态并动态调整卡尔曼增益，以提升状态估计的精度和系统的鲁棒性。本节将对比基于估计误差（协方差）的动态调整、基于残差的动态调整以及卡尔曼增益的动态调整方法，并最终采用基于卡尔曼增益的动态调整策略。

3.5.1 卡尔曼增益的作用与数学模型

卡尔曼增益是 IEKF 中用于更新状态估计的关键参数，起作用主要体现在权重分配和误差协方差更新。在权重分配方面，卡尔曼增益决定了状态预测与观测值在状态更新中的相对权重。当观测值更可靠时，卡尔曼增益较小，状态估计更倾向于预测值；在误差协方差更新方面，卡尔曼增益用于更新状态估计的误差协方差矩阵，从而反映状态估计的不确定性。卡尔曼增益的计算公式为：

$$K_k = P_{k|k-1} H_k (H_k P_{k|k-1} H_k^T + R_k)^{-1} \quad (3-39)$$

式中： $P_{k|k-1}$ 为预测误差协方差矩阵； H_k 为观测矩阵； R_k 为观测噪声协方差矩阵。

3.5.2 动态调整策略对比分析

IEKF 是一种适用于非线性系统的状态估计方法，通过增量更新和非线性函数线性化的方式实现高精度的状态估计。在前一节中，激光雷达与 IMU 的多传感器融合为 IEKF 提供了丰富的观测数据，然而，在实际应用中，IMU 与激光雷达等传感器数据的融合往往需要优化 IEKF 的收敛性和计算效率。为此，本节提出一种自适应迭代次数调整方法，通过动态调整迭代次数来提高算法的精度和实时性，避免过多的计算浪费，并加速滤波器的收敛过程。此外，在紧耦合系统中，观测值（激光雷达点云）和预测值（IMU 运动估计）的可靠性可能随时间变化，为了适应这种动态变化，本节对比了基于误差（协方差）的动态调整、基于残差的动态调整以及基于卡尔曼增益的动态调整方法，并最终采用基于卡尔曼增益的动态调整策略，以进一步提升状态估计的精度和系统的鲁棒性。

(1) 基于估计误差（协方差）的动态调整

在 IEKF 中，协方差矩阵是状态估计不确定性的量化表征，其不仅反映了当前状态估计的置信度，还为迭代次数的动态调整提供了关键依据。具体而言，协方差矩阵的幅值与其迹（ trace ）或最大对角元素可作为衡量估计误差的重要指标：当协方差矩阵的迹较大时，表明系统状态估计的不确定性较高，此时需增加迭代次数以提升估计精度；当协方差矩阵的迹较小时，则意味着估计结果已趋于稳定或接近真实值，此时减少迭代次数可显著节省计算资源。

IEKF 通过迭代线性化非线性函数，逐步更新状态估计 $\hat{x}$ 和协方差矩阵 P 。在每次迭代中，卡尔曼增益 K_k 的计算与状态更新过程会直接影响协方差矩阵的演化。具体而言，协方差矩阵的迹 $\text{tr}(P)$ 或最大对角元素可表征状态估计的整体不确定性。其动态特性可归纳为：在高不确定性场景下，当 $\text{tr}(P) > \tau_{\max}$ （ $\tau_{\max}$ 为预设阈值）时，表明系统存在较大的估计误差或环境扰动，需增加迭代次数以加速收敛；在低不确定性场景下，当 $\text{tr}(P) < \tau_{\min}$ （ $\tau_{\min}$ 为预设阈值）时，表明估计已接近稳态，减少迭代次数可避免冗余计算。

该策略实现如下：首先，设置最大迭代次数 $N_{\max}$ 、最小迭代次数 $N_{\min}$ ，以及协方差迹的上下限阈值 $\tau_{\max}$ 和 $\tau_{\min}$ 。其次，在每次滤波周期开始时，计算协方差矩阵的迹 $\text{tr}(P)$ ，并根据迹值调整当前迭代次数 N_{iter} ：当 $\text{tr}(P) > \tau_{\max}$ 时，设置 $N_{\text{iter}} = N_{\max}$ ；当 $\text{tr}(P) < \tau_{\min}$ 时，设置 $N_{\text{iter}} = N_{\min}$ ；在其他情况下，通过线性插值确定迭代次数。最后，执行 N_{iter} 次迭代，每次迭代更新状态估计 $\hat{x}$ 和协方差矩阵 P ，并在相邻两次迭代的状态估计变化量 $\|\Delta \hat{x}\|$ 小于收敛阈值 ς 时提前终止迭代。

(2) 基于残差的动态调整

在 IEKF 算法中，残差向量定义为测量值与状态预测值之间的差异，其数学表达式为：

$$r_k = z_k - H_k \hat{x}_{k|k-1} \quad (3-40)$$

式中： z_k 为当前时刻的实际测量值； H_k 为测量矩阵； $\hat{x}_{k|k-1}$ 为当前滤波器的状态预测值。残差向量 r_k 反映了状态估计与真实测量之间的偏差，是评估滤波器性能的重要指标。

基于残差的动态调整策略通过评估残差的大小，动态调整 IEKF 的迭代次数。具体而言，若残差范数 $\|r_k\|$ 超过设定的上限阈值 $\tau_{\max}$ ，表明当前估计存在较大的不确定性，需增加迭代次数以进一步优化估计；若残差范数低于下限阈值 $\tau_{\min}$ ，则表明当前估计已收敛，可减少迭代次数以提高计算效率。残差范数的计算如下：

$$\|r_k\| = \sqrt{r_k^T r_k} \quad (3-41)$$

该策略的实现过程如下：首先，初始化滤波器的状态估计 $\hat{x}_{0|0}$ 和协方差矩阵 $P_{0|0}$ ，并设置最大迭代次数 $N_{\max}$ 、最小迭代次数 $N_{\min}$ 以及残差的上下限阈值 $\tau_{\max}$ 和 $\tau_{\min}$ 。其次，在每次迭代中，计算卡尔曼增益 K_k 并更新状态估计 $\hat{x}_{k|k}$ 和协方差矩阵 $P_{k|k}$ 。每次迭代后，计算残差向量 r_k 及其范数 $\|r_k\|$ ，并根据以下规则调整迭代次数：若 $\|r_k\| > \tau_{\max}$ ，增加迭代次数以优化估计；若 $\|r_k\| < \tau_{\min}$ ，减少迭代次数以提高计算效率。

(3) 基于卡尔曼增益的动态调整策略

基于卡尔曼增益的动态调整方法的核心思想是通过监测卡尔曼增益 K_k 的大小和变化趋势，自适应地调整 IEKF 的迭代次数。卡尔曼增益反映了系统对测量信息的依赖程度，其数学表达式为：

$$K_k = P_{k|k-1} H_k^T (H_k P_{k|k-1} H_k^T + R_k)^{-1} \quad (3-42)$$

式中： $P_{k|k-1}$ 为预测误差协方差矩阵； H_k 为观测矩阵； R_k 为观测噪声协方差矩阵。

当卡尔曼增益较大时，表明系统对测量信息的依赖较强，通常意味着当前估计的不确定性较大，此时应增加迭代次数以优化状态估计；当卡尔曼增益较小时，表明系统对预测值的依赖较强，当前估计已趋于稳定，可减少迭代次数以提高计算效率。

该策略的实现过程如下：首先，初始化滤波器的状态估计 $\hat{x}_{0|0}$ 和协方差矩阵 $P_{0|0}$ ，并设置最大迭代次数 $N_{\max}$ 、最小迭代次数 $N_{\min}$ 以及卡尔曼增益的上下限阈值 $\kappa_{\max}$ 和 $\kappa_{\min}$ 。其次，在每次迭代中，计算卡尔曼增益 K_k 并更新状态估计 $\hat{x}_{k|k}$ 和协方差矩阵 $P_{k|k}$ 。每次迭代后，根据卡尔曼增益的范数 $\|K_k\|$ 动态调整迭代次数：若 $\|K_k\| > \kappa_{\max}$ ，增加迭代次数以优化估计；若 $\|K_k\| < \kappa_{\min}$ ，减少迭代次数以提高计算效率。

综上所述，本节选择基于卡尔曼增益的动态调整策略，主要原因如下：首先，该策略综合了估计误差和残差信息，能够更全面地反映系统状态的动态变化，在复杂动态环境中表现出更高的适应性和稳定性；其次，通过动态调整卡尔曼增益，能够更合理地分配预测值和观测值的权重，从而提高状态估计的精度；此外，该策略在高噪声环境下表现出较强的鲁棒性，能够有效减少不可靠观测值对状态估计的影响；最后，基于卡尔曼增益的调整策略能够适应系统状态的快速变化，适用于动态环境中的状态估计。因此，基于卡尔曼增益的动态调整策略在精度、鲁棒性和适应性方面均具有显著优势，为多传感器融合系统提供了高效且可靠的状态估计解决方案。

3.5.3 基于卡尔曼增益的动态调整策略

基于上节分析，本节采用基于卡尔曼增益的动态调整策略，首先，计算残差

协方差矩阵，根据当前时刻的预测误差协方差矩阵 $P_{k|k-1}$ 和观测噪声协方差矩阵 R_k ，计算残差协方差矩阵 S_k ：

$$S_k = H_k P_{k|k-1} H_k^T + R_k \quad (3-43)$$

随即计算动态调整因子，根据残差协方差矩阵 S_k 和观测噪声协方差矩阵 R_k ，计算动态调整因子 α_k ：

$$\alpha_k = \frac{\text{tr}(S_k)}{\text{tr}(R_k)} \quad (3-44)$$

最后更新状态估计和误差协方差矩阵，使用调整后的卡尔曼增益，更新状态估计和误差协方差矩阵：

$$\begin{cases} \hat{x}_{k|k} = \hat{x}_{k|k-1} + K_k (z_k - H_k \hat{x}_{k|k-1}) \\ P_{k|k} = (I - K_k H_k) P_{k|k-1} \end{cases} \quad (3-45)$$

为了直观展示状态估计的不确定性变化，本节引入协方差椭圆图作为可视化工具。协方差椭圆图通过绘制误差协方差矩阵的特征向量和特征值，反映状态估计在二维平面上的不确定性分布。通过对比不同迭代次数下的协方差椭圆图，可以直观观察到状态估计不确定性的变化趋势。当卡尔曼增益较大时，椭圆面积较大，表明估计不确定性较高；当卡尔曼增益较小时，椭圆面积收缩，表明估计趋于稳定。误差分布如图 3-6 所示。




图 3-6 误差分布图

系统流程包括：获取激光雷达观测模型与 IMU 积分模型，融合 IEKF 算法，引入自适应迭代次数调整机制，提高定位准确性。具体算法流程如图 3-7 示，迭

代过程如 3-8 所示。

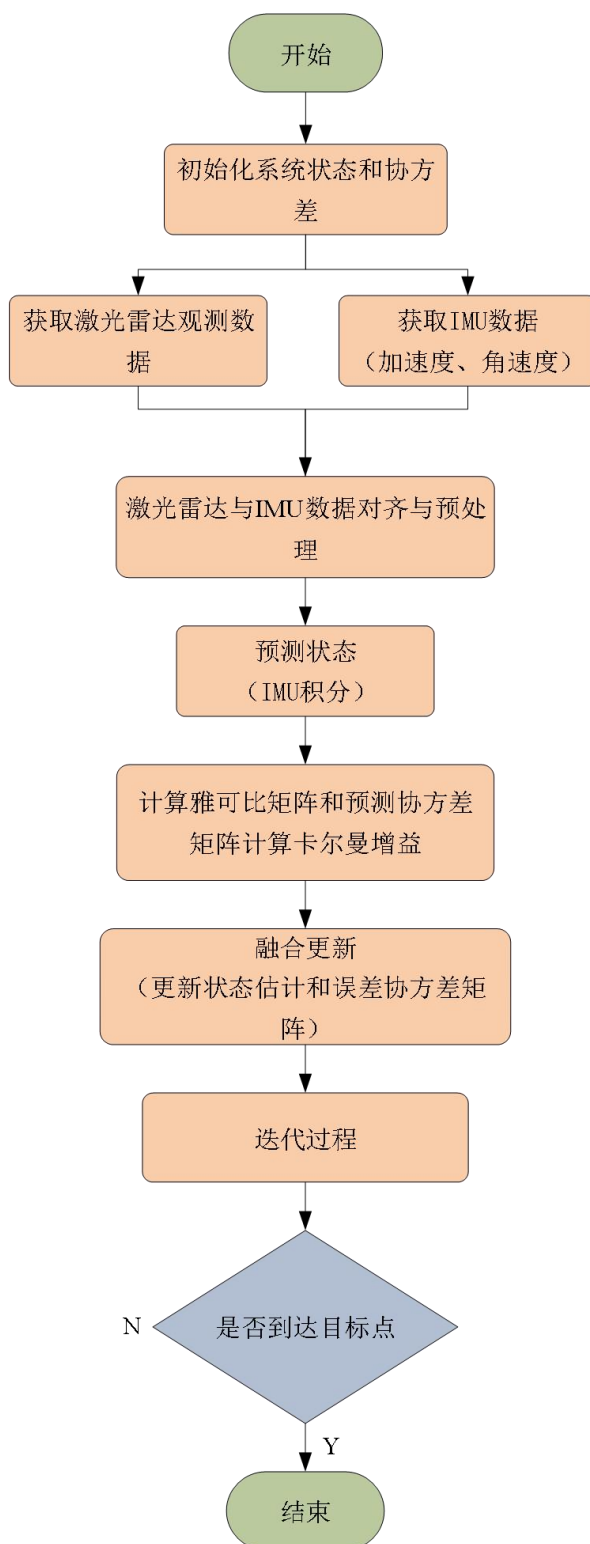


图 3-7 算法流程图




图 3-8 迭代过程流程图

3.6 实验验证及结果分析

本节基于直接点云处理的激光雷达与 IMU 的紧耦合系统，融合了自适应迭代次数调整的 IEKF 算法，对比了四种算法：LOAM(Lidar Odometry and Mapping)、LIOM(Lidar-Inertial Odometry and Mapping)、LIO-GPS(Lidar-Inertial Odometry with GPS) 及自适应 IEKF 融合算法在点云帧处理效率与定位精度上的性能。实验在工控机上进行，硬件配置为 Intel i7-11800H CPU、16 GB 内存，数据集采用 KITTI 数据集中的激光雷达与 IMU 数据，点云帧率为 10 Hz。

3.6.1 点云帧平均耗时对比

数据预处理阶段，对 KITTI 数据集中的激光雷达点云和 IMU 数据进行了时间同步和坐标对齐，以确保输入数据的一致性。工控机的操作系统为 Linux Ubuntu20.04；ROS 机器人操作系统版本为 Noetic。实验过程为：在笔记本电脑上用本章算法与 LOAM、LIOM、LIO-GPS 算法分别对上述数据集进行实验，对比点云帧平均耗时。实验结果如下表：

表 3-2 点云帧平均耗时对比

算法名称	平均耗时（帧/秒）	标准差（秒）
LOAM	0.12	0.02
LIOM	0.08	0.01
LIO-GPS	0.15	0.03
自适应IEKF	0.06	0.01

表 3-2 展示了四种算法的点云帧平均耗时及其标准差。从表中可以看出，本章算法表现最优，其平均耗时仅为 0.06 秒/帧，标准差为 0.01 秒，表明其在计算效率和稳定性上均具有显著优势。LIOM 算法的平均耗时为 0.08 秒/帧，略高于 IEKF 算法，但其标准差为 0.01 秒，表明其处理时间波动较小，适合实时性要求较高的应用场景。LOAM 算法的平均耗时为 0.12 秒/帧，标准差为 0.02 秒，由于其未融合 IMU 数据，计算负担较大，导致处理效率较低。LIO-GPS 算法的平均耗时为 0.15 秒/帧，标准差为 0.03 秒，由于其引入了 GPS 数据以提升全局定位精度，导致计算复杂度显著增加，处理效率最低。

3.6.2 定位精度实验结果及分析

在本章研究中，为了全面评估并验证所提出的基于直接点云处理与 IMU 融合自适应 IEKF 算法的有效性与鲁棒性，选取了 Campus 和 Park 两个典型的开源数据集作为实验基础。该数据集因其涵盖了多种复杂场景，在自主导航与高精度定位领域的研究中得到了广泛应用，并受到高度评价。Campus 数据集主要包含开阔区域，适用于评估算法在大尺度、无明显特征环境中的适应性，而 Park 数据集则模拟了树木密集、道路狭窄等复杂环境，为验证算法在特征密集区域的稳定性提供了良好的测试条件。

在实验过程中,本研究采用了基于卡尔曼增益的动态调整策略,以优化 IEKF 滤波过程的收敛性和精度。在该策略中,设定最大迭代次数为 25 次,最小迭代次数为 3 次,并设定卡尔曼增益的上限阈值为 0.9,下限阈值为 0.01,确保滤波过程在不同工况下均能够实现稳定且高效的状态估计。此外,为了进一步验证本章方法的优越性,实验选取了当前主流的 LOAM、LIOM、LIO-GPS 等定位精度较好的算法作为对比基准,并与本章提出的自适应 IEKF 融合算法进行定量分析与误差评估。实验主要基于绝对位姿估计误差 (Absolute Trajectory Error, ATE) 进行性能对比,并采用均方根误差 (Root Mean Square Error, RMSE)、最大误差、最小误差及平均误差等指标对不同方法的定位精度进行细致量化分析,从而全面评估所提出方法在不同环境条件下的定位稳定性与精度提升效果。

本实验按照以下步骤进行:首先,在笔记本计算机上分别运行 LOAM、LIOM、LIO-GPS 以及本章提出的自适应 IEKF 融合算法,对 Campus 与 Park 数据集进行回放处理,并生成对应的轨迹数据。所有实验所得的轨迹数据均以 TXT 格式进行存储,以确保后续数据分析的标准化与可复现性。随后,在 Matlab 环境中对实验数据进行处理与分析,包括轨迹误差计算、关键指标统计以及误差分布可视化等步骤,以全面评估不同算法在高精度定位任务中的表现。最后,为了直观展示各算法在不同场景下的轨迹估计结果,本实验对生成的轨迹数据进行可视化处理,并将 LOAM、LIOM、LIO-GPS 及本章提出算法的轨迹绘制在同一张图中进行对比分析,如图 3-7 与图 3-8 所示。

本分采用绝对轨迹误差作为全局误差评估指标,能够直观反映估计轨迹在整个运动过程中的全局偏差。ATE 主要用于评估位姿估计算法的绝对精度,适用于分析长时间运行中的累积误差。假设系统在 n 个时间步上获得了真实轨迹 $P = \{p_1, p_2, \dots, p_n\}$ 和估计轨迹 $\hat{P} = \{\hat{p}_1, \hat{p}_2, \dots, \hat{p}_n\}$, 其中每个位姿 p_i , $\hat{p}_i$ 表示在第 i 个时刻的三维位置。ATE 通过计算所有时间步上估计位姿与真实位姿之间的欧式距离来量化误差,其定义如下:

$$e_i = \|p_i - T\hat{p}_i\| \quad (3-46)$$

式中: T 是用于对齐真实轨迹和估计轨迹的最优刚体变换矩阵,以消除坐标系误差对评估结果的影响。

为进一步量化误差,本文采用均方根误差 (Root Mean Square Error, RMSE)

作为 ATE 的核心评估指标，其计算公式为：

$$\text{RMSE(ATE)} = \sqrt{\frac{1}{n} \sum_{i=1}^n e_i^2} \quad (3-47)$$

RMSE 是衡量定位精度的重要指标之一，其数值大小直接反映了算法在全局轨迹估计中的准确性。一般而言，RMSE 值越小，说明算法在估计位姿时的累积误差越低，轨迹的精度越高，从而表明该算法在长时间运行和大范围运动场景下具有更优的全局一致性和定位稳定性。因此，在本研究中，通过对比不同算法的 RMSE 值，可以直观评估各方法在高精度定位任务中的表现，并进一步验证所提出算法的有效性和优势。




图 3-9 Campus 轨迹对比图




图 3-10 Park 轨迹对比图

表 3-3 绝对轨迹误差 RMSE 分析表 (ATE)

场景	算法	最大值 (mm)	平均值 (mm)	最小值 (mm)	均方根误差 (mm)
Campus	LOAM	5862.7	1762.4	962.1	1924.3
	LIOM	Fail			
	LIO-GPS	178.44	54.96	30.97	68.7
	自适应 IEKF	254.41	75.52	15.64	94.4
Park	LOAM	3126.1	1347.6	608.7	1217.4
	LIOM	939.4	263.5	121.2	546.1
	LIO-GPS	284.8	131.3	23.65	151.3
	自适应 IEKF	483.5	208.6	58.24	263.6

根据图 3-9、图 3-10 与表 3-3 的实验结果，可以得出以下结论：在 Campus 数据集中，LOAM 算法的均方根误差为 1924.3 mm，表明其在长距离轨迹定位中存在显著的累积误差；LIOM 算法由于在长距离轨迹中发生了严重的漂移现象，导致其定位精度较差；LIO-GPS 算法表现最佳，均方根误差仅为 68.7 mm，显著优于其他算法；本章提出的算法均方根误差为 94.4 mm，虽然略高于 LIO-GPS 算法，但仍明显优于 LOAM 和 LIOM 算法。在 Park 数据集中，LOAM 算法的均方根误差为 1217.4 mm，LIOM 算法的均方根误差为 546.1 mm，LIO-GPS 算法的均方根误差为 151.3 mm，而本章算法的均方根误差为 263.6 mm。综合以上结果可以看出，由于当绝对轨迹误差越小时，算法定位精度越高，从最大值、最小值和 RMSE 的结果得出，本章算法在定位轨迹误差方面显著优于 LOAM 和 LIOM 算法，但与 LIO-GPS 算法相比仍存在一定差距。

本章算法在定位精度上不及 LIO-GPS 算法，主要是由于 LIO-GPS 算法引入了 GPS 数据作为全局约束，有效抑制了长距离轨迹中的漂移现象，而本章算法未引入外部全局定位信息，仅依赖激光雷达与 IMU 的紧耦合实现局部定位。尽管如此，本章算法在综合定位估计误差方面表现出了较高的鲁棒性与稳定性，尤其是在动态环境中的适应性较强。然而，在高精度定位需求场景下，本文算法仍需进一步优化以提升其性能。

3.7 本章小结

本章围绕激光雷达与 IMU 的紧耦合融合定位问题，提出了一种基于直接点云处理与 IMU 融合自适应 IEKF 算法。该方法在紧耦合框架下对激光雷达数据处理流程进行了优化，并融合 IMU 的高频运动信息以提高状态估计的准确性。同时，采用三次样条插值对时间戳进行统一处理，消除不同传感器时钟偏差对数据同步性的影响。此外，本章引入自适应迭代次数调整机制，使 IEKF 在迭代过程中能够根据状态估计误差动态调整迭代次数，从而有效抑制因舵轮形变导致的误差累积。该策略不仅提升了系统的实时性和计算效率，还在保证定位精度的同时增强了系统的鲁棒性，使其能够更稳定地适应复杂环境下的高精度定位需求。

为验证本章算法的有效性，本文在多个数据集上进行了实验，并与现有主流算法进行了对比分析。实验结果表明，所提出的算法在定位精度方面显著优于 LOAM 和 LIOM 算法，有效抑制了长时间运行过程中累积误差的影响，提高了系统的定位稳定性。然而，由于未引入外部全局定位信息，相较于融合 GPS 信息的 LIO-GPS 算法，本章方法在长距离轨迹估计场景下仍存在一定精度差距，主要体现在累积误差难以完全消除。尽管如此，本章算法在动态环境下展现出较强的适应性，并在综合定位精度与系统鲁棒性方面达到了较优的平衡，为进一步优化高精度定位奠定了基础。基于本章研究内容，下一步的工作将重点围绕后端优化展开，以进一步提升系统的长期稳定性和定位精度。

第4章 基于自适应半径搜索策略的回环检测与定位优化

4.1 引言

在第三章中研究了基于直接点云处理与 IMU 紧耦合的自适应 IEKF 算法，尽管该方法有效解决了短期内的定位精度问题，在长时间运行和大范围运动过程中，仍然面临着定位误差的积累和漂移问题。特别是在堆垛式无人叉车进行长距离行驶、运动速度较高或遇到环境结构相似的情况时，定位误差可能会逐渐扩大，导致系统的精度严重下降。

为了进一步提升定位系统的精度，并有效解决长时间运行中的定位漂移问题，回环检测 (Loop Closure Detection, LCD) 可以通过识别历史路径中的重复位置来修正累积的误差，从而提高系统的定位精度。回环检测方法能够有效解决由于漂移积累引起的定位误差，尤其是在长时间、高速度运动的情况下。

然而，现有的回环检测方法通常依赖于静态的搜索半径或特定的特征匹配技术，这在某些复杂环境中可能会导致误匹配或漏检，进而影响回环检测的效果。因此，本章提出了一种基于自适应半径搜索策略的回环检测方法，分析了回环检测中面临的关键问题，包括点云匹配精度、环境变化的适应性等，并设计了基于自适应半径搜索的特征匹配与回环判定机制。在该机制中，采用动态调整的搜索半径，使得特征匹配能够根据环境点云的密度进行自适应优化。密度计算模型通过估算局部点云的密度，动态调整搜索半径，确保在稠密或稀疏区域都能实现精准的特征匹配。

在特征匹配的基础上，进一步引入了局部几何特征模型，利用点云法向量、曲率及主成分分析 (PCA) 提取的几何特征进行特征点的描述。通过对局部几何特征的融合与加权，增强了回环检测的鲁棒性和匹配精度，尤其在复杂环境下，有效提升了回环检测的稳定性。

此外，本章还构建了姿态图，并采用图优化方法对轨迹误差进行修正。通过优化轨迹中的节点位置，抑制了长时间运行中累积的定位漂移，进一步提高了全局定位精度和系统的稳定性。

4.2 回环检测与定位优化问题分析

第三章所提算法在长时间运行中,随着误差逐步积累,定位精度依然会受到较大影响。这一问题主要体现在定位漂移问题、长距离运动中的误差累积、固定半径搜索的局限性、环境的动态变化,具体分析如下:

(1) 定位漂移问题

传感器噪声、动态变化的环境以及传感器自身的误差,定位系统难以避免地产生漂移,特别是在视觉或激光雷达信息不足的区域,定位误差会不断积累,导致系统最终偏离真实路径。

(2) 长距离运动中的误差累积

当堆垛式无人叉车行驶的距离较长时,即使 IMU 和激光雷达的数据融合策略能够在短期内维持较高精度,随着运动距离的增加,误差的累积效应逐渐显现,特别是在没有明显回环的情况下。此时,仅用 IEKF 融合多传感器的方法无法有效地抑制漂移,导致定位精度下降。

(3) 固定半径搜索的局限性

在现有的回环检测方法中,通常使用固定半径搜索来寻找历史轨迹中的匹配点。然而,固定半径的设置可能导致在复杂环境中出现误匹配,尤其是在环境密集或分布稀疏的区域。此外,固定半径在高速运动下可能导致遗漏回环检测,或者在低速运动时造成无谓的计算开销。

(4) 环境的动态变化

环境的动态变化也是回环检测的误差来源。特别是当堆垛式无人叉车行驶到一个之前经过的区域时,环境发生了较大的变化(如物体的移动或障碍物的增减),传统的回环检测方法难以有效地匹配历史轨迹和当前点云,导致回环检测失败。

4.3 基于自适应半径搜索策略的回环检测方法

为了有效提高回环检测的精度和鲁棒性,本研究提出了一种自适应半径搜索策略,旨在动态调整搜索半径以适应不同的环境和运动状态,从而提升回环检测的表现。与传统的固定半径搜索方法不同,自适应半径搜索方法能够根据当前的环境特征以及堆垛式无人叉车运动状态动态地调整搜索范围,避免因环境复杂度

和传感器特征分布的不同导致回环检测误差的发生。

4.3.1 回环检测与因子图优化算法框架

在多传感器融合系统中，回环检测和因子图优化的结合能够有效消除长时间运行中的累积误差，显著提升定位精度、全局一致性和系统的鲁棒性。后端优化是多传感器融合系统中至关重要的步骤，其主要作用是对前端信息进行全局优化，以消除长期运行中的累积误差，降低位姿漂移，提高定位精度和系统的鲁棒性。在本系统中，后端优化过程包括回环检测、因子图构建及优化等多个环节，并通过优化求解实现全局轨迹的精细调整。后端优化算法框架如图 4-1 所示。




图 4-1 后端优化算法框架

回环检测是提高堆垛式无人叉车定位精度和稳定性的关键技术，其核心目标是识别堆垛式无人叉车在环境中已访问过的位置，并为定位优化提供有效的约束。通过精确的回环检测，能够显著减少定位误差的积累，提升全局定位的准确性与稳定性，确保叉车在长时间运行过程中的高效性与可靠性。回环检测的过程通常包括三个主要步骤：特征提取、特征匹配和回环判定。在特征提取阶段，通过激光雷达和 IMU 传感器获取环境特征信息，进而提取出有用的特征，确保特征点的稳定性与高区分度。特征匹配阶段则通过对比当前观测数据与历史特征，采用几何或点云匹配方法进行识别，以确保匹配过程的高效与准确。最后，回环判定根据特征匹配结果，结合位置误差、角度差异等几何约束，判断是否为回环，进一步提高定位系统的可靠性。图 4-2 展示了回环检测的详细流程。




图 4-2 回环检测流程图

为进一步优化回环检测的效果，因子图优化方法被广泛应用于 SLAM 系统中。因子图通过图结构建模堆垛式无人叉车状态与观测之间的约束关系，节点表示堆垛式无人叉车的位姿、速度等状态，因子表示状态之间的约束。通过最小化误差函数，因子图优化能够有效校正堆垛式无人叉车状态，消除长时间运行中的累积误差。图优化的核心在于通过对因子图中的约束进行全局优化，得到最优的堆垛式无人叉车轨迹，提升定位精度。

回环检测与因子图优化的结合，不仅能够提升定位精度，还能在动态、复杂环境下保持系统的鲁棒性。回环检测提供了必要的位姿约束，而因子图优化则通过全局优化来有效地校正整个轨迹。特别是在堆垛式无人叉车等自动化设备中，这一技术能够显著提高导航控制系统的稳定性和精度，保证长时间、大范围的自主定位任务能够准确执行。

4.3.2 基于密度计算模型与几何特征的自适应半径搜索策略

为了克服固定半径搜索的局限性，本研究提出了一种自适应半径搜索策略，

通过动态调整搜索半径来适应不同的环境和运动状态。具体研究包括自适应半径搜索策略通过计算特征点密度与局部几何特征模型确定半径值，如图 4-3 所示。




图 4-3 策略流程介绍

(1) 密度计算模型

密度计算是局部特征提取与自适应半径搜索策略中的基础。点云数据的密度反映了局部区域内点的稠密程度，对于自适应搜索半径的调整至关重要。准确的密度估计能够有效改善特征匹配的精度，尤其在点云稀疏或密集度差异较大的环境中。

在此模型中，给定待检测点 p_i ，其邻域内的点集 p_n 可以通过球形区域或 K 近邻算法来定义。点云的密度通过以下公式计算：

$$\rho(p_i, r_i) = \frac{n(p_i, r_i)}{V(r_i)} \quad (4-1)$$

式中： $\rho(p_i, r_i)$ 是点 p_i 在领域 $N(p_i, r_i)$ 内的密度； $n(p_i, r_i)$ 是领域内的点的数量； $V(r_i)$ 是领域的体积。

若领域为球形，则体积计算为：

$$V(r_i) = \frac{4}{3} \pi r_i^3 \quad (4-2)$$

密度计算模型还可以通过 K 近邻密度（KNN）来替代球型邻域。在此情况下，KNN 密度可以表示为：

$$\rho(p_i) = \frac{k}{V_k} \quad (4-3)$$

式中： k 是点 p_i 的 K 个最近邻点数量； V_k 是包含这 k 个点的局部面积。通过密度动态调整搜索半径 r_i ，可以提高特征匹配的精度。

(2) 局部几何特征模型

局部几何特征模型用于描述点云的局部几何形态，并提取具有描述性和区分性的特征点，进而提升回环检测和定位优化的效果。局部几何特征主要分为法向量计算、曲率计算、局部几何特征融合。

在回环检测中，法向量能够有效表征局部点云的表面方向，为特征匹配和回环判定提供有力支持。在本研究中，法向量采用主成分分析（PCA）方法进行计算。PCA 通过对点云邻域的协方差矩阵进行特征值分解，能够提取出最能表征局部几何形态的法向量。首先选择邻域点集，对于点云中的任意一点 p_i ，选择其邻域点集 $P_n = \{p_1, p_2, \dots, p_k\}$ ，其中 $p_j = (x_j, y_j, z_j)$ 为点 p_j 的坐标，邻域点通常为点 p_i 周围的若干个最近邻点；其次计算邻域质心，公式如下：

$$\bar{p} = \frac{1}{n} \sum_{j=1}^n p_j = \left(\frac{1}{n} \sum_{j=1}^n x_j, \frac{1}{n} \sum_{j=1}^n y_j, \frac{1}{n} \sum_{j=1}^n z_j \right) \quad (4-4)$$

式中： $p_j = (x_j, y_j, z_j)$ 为第 j 个邻域点的坐标。

随即计算协方差矩阵，基于邻域点集与质心之间的偏差，计算协方差矩阵 C ，公式为：

$$C = \frac{1}{n} \sum_{j=1}^n (p_j - \bar{p})(p_j - \bar{p})^T \quad (4-5)$$

协方差矩阵反映了点云在局部区域的几何变异性，下一步为特征值分解，对协方差矩阵 C 进行特征值分解，得到特征值 $\lambda_1, \lambda_2, \lambda_3$ 和对应的特征向量 v_1, v_2, v_3 ，即：

$$Cv_k = \lambda_k v_k \quad (4-6)$$

式中： $k = 1, 2, 3$ ，特征值按照从大到小的顺序排列 $\lambda_1 \geq \lambda_2 \geq \lambda_3$ ；最后进行法向量提取，法向量 n 与特征值最小的特征向量 v_3 对应，法向量 n 表示局部表面的法线方向，能够有效描述点云数据的局部几何特征，即：

$$n = v_3 \quad (4-7)$$

曲率是描述局部几何形态弯曲程度的关键特征，能够有效区分不同环境区域的几何特性。在回环检测过程中，曲率能够提供补充的几何信息，帮助区分不同的环境区域。曲率通常通过对局部点云进行二次曲面拟合来进行计算。曲率的计算基于点云的局部拟合，通过最小二乘法对邻域点进行二次曲面拟合，可以得到

曲率的估计值。首先，选择邻域点集，对于目标点 p_i ，选择其邻域的点集 $P_n = \{p_1, p_2, \dots, p_k\}$ ；其次，进行二次曲面拟合，假设局部点云可以近似为一个二次曲面，使用最小二乘法对点云进行拟合，得到曲面的表达式：

$$z = f(x, y) \quad (4-8)$$

最后计算主曲率，通过曲面的二阶导数计算主曲率 κ_1 和 κ_2 ，公式如下：

$$\kappa_1 = \frac{\partial^2 z}{\partial x^2} \quad (4-9)$$

$$\kappa_2 = \frac{\partial^2 z}{\partial y^2} \quad (4-10)$$

曲率 κ 可以通过主曲率的平均值来表示：

$$\kappa = \frac{\kappa_1 + \kappa_2}{2} \quad (4-11)$$

该曲率值反映了局部几何形状的弯曲程度。

在回环检测中，通过法向量和曲率等局部几何特征的匹配，可以有效判断是否存在回环。通过将当前帧的几何特征与历史帧的几何特征进行匹配，能够准确判断环境是否发生变化，从而识别回环。法向量匹配通过计算两法向量之间的夹角来度量相似度，法向量的匹配度可以表示为：

$$\text{Match}(n_1, n_2) = \frac{n_1 \cdot n_2}{|n_1| |n_2|} \quad (4-12)$$

曲率的匹配通过计算两点的曲率差异来衡量相似度。匹配度可以表示为：

$$\text{Match}(\kappa_1, \kappa_2) = 1 - \left| \frac{\kappa_1 - \kappa_2}{\kappa_1 + \kappa_2} \right| \quad (4-13)$$

当两点的曲率差异较小时，表示两点的局部几何形态较为相似，匹配度较高。

局部几何特征，如法向量和曲率，在回环检测中具有重要应用价值。通过法向量和曲率的匹配，能够有效判断当前帧与历史帧是否相似，从而实现回环的检测。特别是在复杂环境中，这些几何特征能够提供额外的几何信息，提高回环检测的鲁棒性和精度。此外，局部几何特征在定位优化中也有重要作用。通过这些特征引入图优化框架，可以有效修正由于累积误差导致的定位漂移，从而提高全局定位精度和稳定性。基于密度计算模型与几何特征的自适应半径搜索策略伪

代码如表 4-1 所示。

表 4-1 基于密度计算模型与几何特征的自适应半径搜索策略伪代码

基于密度计算模型与几何特征的自适应半径搜索伪代码步骤

输入：当前帧点云 P ，历史帧特征库 H ，初始搜索半径 R_0

参数初始化：设置邻域类型、 k 值、密度阈值

For each 点 $p_i \in P$ do

计算密度：

若邻域类型为球形，按式 (4-1) 计算 $\rho_i = \frac{N}{V}$ ，其中 $V = \frac{4}{3}\pi R^3$

若邻域类型为 KNN，按式 (4-3) 计算 $\rho_i = \frac{K}{A}$

调整搜索半径： $R = R_0 \cdot \frac{\rho_{th}}{\rho_i}$

提取局部几何特征：

按式 (4-4) 计算邻域质心 $\bar{p}$ ，按式 (4-5) 计算协方差矩阵 C

对 C 进行 PCA 分解，取最小特征值对应向量作为法向量 n_i

按式 (4-8) 与式 (4-11) 拟合二次曲面，计算曲率 κ_i

特征匹配：

For each 历史特征 $h_j \in H$ do

计算法向量夹角 $\theta_{ij} = \arccos(n_i \cdot n_j)$ (式 4-12)

计算曲率差异 (式 4-13)

若 $\theta_{ij} < \theta_{th}$ 且 $\Delta\kappa < \kappa_{th}$ ，标记为候选匹配对，更新回环检测结果

End for

End for

输出：回环候选帧集合及匹配置信度

4.4 定位优化与漂移修正

回环检测后的定位优化主要通过图优化来实现，图优化是通过构建一个优化

问题来修正堆垛式无人叉车的轨迹误差。具体地，图优化通过最小化位姿图中的约束误差来进行定位优化。优化内容如图 4-4 所示。




图 4-4 图优化内容详解

4.4.1 姿态图构建

假设在时间 t_i 时刻，堆垛式无人叉车的位姿为 T_i ，则堆垛式无人叉车在连续时刻之间的位姿关系可以通过约束表达。对于每一对相邻帧 (i, j) ，它们之间的约束可以通过相对位姿变化来描述：

$$T_j = T_i \cdot T_{ij} \quad (4-14)$$

式中： T_{ij} 为相对位姿转换，如果检测到回环，在回环帧 (k, l) 之间加入的约束为：

$$T_l = T_k \cdot T_{kl} \quad (4-15)$$

这些约束会添加到位姿图中，形成图优化的约束边。

4.4.2 图优化方法

图优化是通过在位姿图中添加节点和边来表示堆垛式无人叉车的轨迹，每个节点表示一个时刻的位姿，每条边表示节点之间的约束关系。在回环检测中，回环节点被视为图中的一个新的节点，并通过相应的边连接到其他相关节点，形成闭环约束。

优化目标是 minimized 位姿图中的约束误差，优化过程的目标函数可表示为：

$$\varepsilon(X) = \sum_{i=1}^N \|X_i - X_i^{true}\|^2 + \sum_{j=1}^M \|X_i - X_j\|^2 \quad (4-16)$$

式中： X_i 代表节点 i 的估计位姿； X_i^{true} 代表节点 i 的真实位姿； N 代表优化问题中位姿节点的总数； M 代表约束边的数量。通过最小化该目标函数，能够更

新位姿图中各节点的位置，从而修正堆垛式无人叉车的轨迹误差。

如图 4-5 为通过回环检测进行全局位姿优化的情况，主要描述了从原始位姿估计到优化后位姿的变化情况。从图中可以看出，左侧表示优化前的位姿图，右侧表示优化后的位姿图。图中各个 Pos 节点（Pos0、Pos1、Pos2、Pos3）代表堆垛式无人叉车在不同时刻的位姿，而 X0、X1、X2 等节点表示观测到的外部特征点。虚线箭头表示传感器测量到的观测信息，标注的 (u_i, v_i) 代表观测误差。

在优化前（左图），由于累计误差的影响，Pos 节点的排列存在一定的偏差，且观测信息未能很好地对齐。在优化后（右图），通过全局位姿优化调整了各个位姿节点的位置，使其更加一致地符合观测约束，减少了累计误差对定位精度的影响，从而提高了整体定位的准确性和一致性。图 4-5 直观地说明了全局位姿优化对于提升定位精度的重要性，优化后的位姿更加符合真实轨迹，有助于提高堆垛式无人叉车在复杂环境中的自主导航能力。




图 4-5 全局位姿优化

4.5 实验结果及分析

4.5.1 定位精度实验结果及分析

本章实验的主要目的是验证基于自适应半径搜索策略的回环检测与定位优化方法在长时间运行和大范围运动中的有效性。为了全面评估该方法的性能，本实验选择了两个典型的环境场景进行验证，依旧选用开阔区域的 Campus 环境和复杂狭窄区域的 Park 环境。本实验选择了多个已有的算法作为对比对象，包括

LOAM、LIOM、LIO-GPS、自适应 IEKF 以及本章提出的回环检测方法。通过这些算法的实验结果进行详细比较，可以全面了解它们在长时间运行、大范围运动下的定位精度表现。

实验数据的分析采用了多种量化指标，包括均方根误差、最大值、最小值和平均值。这些指标可以全面反映不同算法在定位精度上的差异，帮助更直观地展示各种算法的优势与不足。此外，为了更直观地展现不同算法的定位结果，本实验还进行了位姿的可视化对比，并通过图 4-6、图 4-7 对比展示了各算法的位姿估计结果。这些可视化结果可以清晰地反映出算法在复杂环境中的定位稳定性和准确性。




图 4-6 Campus 轨迹对比图（引入回环后）




图 4-7 Park 轨迹对比图（引入回环后）

表 4-2 绝对位姿估计误差 RMSE 分析表 (ATE)

场景	算法	最大值 (mm)	平均值 (mm)	最小值 (mm)	均方根误差 (mm)
Campus	LOAM	5862.7	1762.4	962.1	1924.3
	LIOM			Fail	
	LIO-GPS	178.44	54.96	30.97	68.7
	自适应 IEKF	254.41	75.52	15.64	94.4
	自适应 IEKF+				
	回环检测	142.67	61.53	20.56	65.6
Park	LOAM	3126.1	1347.6	608.7	1217.4
	LIOM	939.4	263.5	121.2	546.1
	LIO-GPS	284.8	131.3	23.65	151.3
	自适应 IEKF	483.5	208.6	58.24	263.6
	自适应 IEKF+				
	回环检测	291.1	127.3	15.94	149.8

由表 4-2 可得，本文提出的基于自适应半径搜索策略的回环检测方法在 Campus 和 Park 两个典型实验场景中均展现出了良好的定位优化效果。实验结果表明，在 Campus 数据集中，该方法的均方根误差降低至 65.6 mm，较未引入回环检测策略的自适应 IEKF 方法（RMSE = 94.4 mm）减少了 30.5%，显著提升了定位精度并有效降低了累积误差。在 Park 数据集中，本方法的 RMSE 由 263.6 mm 降低至 149.8 mm，降幅达到 43.17%，进一步验证了其在复杂环境下的稳定性和鲁棒性。

与此同时，与 LIO-GPS 方法（Campus 数据集 RMSE = 68.7 mm，Park 数据集 RMSE = 151.3 mm）相比，本文方法在 RMSE 方面表现相近，表明所提出的基于自适应半径搜索策略的回环检测与定位优化策略能够有效提升系统的全局一致性和精度，在长时间行驶和大范围运动中保持稳定的定位性能。这一结果表明，基于自适应半径搜索策略的回环检测方法能够有效抑制传统 IEKF 方法在长距离运行中的误差累积与漂移问题，并在保证计算效率的前提下，实现更高精度的自主导航定位。

4.6 本章小结

本章针对堆垛式无人叉车在长时间运行与大范围运动过程中定位误差累积和漂移的问题，提出了一种基于自适应半径搜索策略的回环检测与定位优化方法。该方法通过动态调整搜索半径，通过引入密度计算模型，根据局部点云密度自适应调整搜索半径，以确保在稠密或稀疏区域均能实现精准匹配。此外，采用局部几何特征模型，结合点云法向量、曲率及主成分分析（PCA）提取的几何特征进行特征点描述，通过特征融合与加权进一步增强了回环检测的稳定性和精度。在回环检测的基础上，本章构建了基于姿态图的全局轨迹优化模型，并采用图优化方法对轨迹误差进行修正。通过优化轨迹中的关键帧位姿，有效抑制了长时间运行过程中累积的定位漂移，从而提升了系统的全局定位精度与稳定性。

综合来看，本章所提出的方法通过结合自适应半径搜索、密度计算模型与局部几何特征模型，有效提升了堆垛式无人叉车在复杂环境中的定位精度，并显著抑制了长时间运行导致的漂移问题。

第 5 章 堆垛式无人叉车高精度定位实验与结果分析

5.1 实验方案设计与实验基础

5.1.1 实验方案设计

为了验证上述理论的合理性，需要通过实验对其进行评估。实验采用指定路径的测试方法，以验证所提方法的可行性。其中，直线路径实验用于分析系统的定位精度，而进一步的定位精度实验则用于全面评估系统在不同工况下的定位性能与稳定性。

图 5-1 展示了实验方案的设计，包括不同路径条件下的测试流程及数据采集方法。通过这些实验，能够量化所提出算法的定位误差，并评估其在堆垛式无人叉车高精度定位中的适用性，从而为系统优化与工程应用提供依据。




图 5-1 实验方案设计

5.1.2 实验场地与远程控制实验平台搭建

(1) 软件配置

在本系统架构中，笔记本电脑被配置为主机，在堆垛式无人叉车上，作为从机的 EI-52 工业计算机接入局域网，是通过无线 AP 实现的。实现与主机的实时数据交互与远程控制。

该网络架构使主机能够高效管理从机的计算任务，包括传感器数据的获取、融合计算、路径规划以及运动控制等功能。同时，EI-52 作为从机，主要负责激光雷达、IMU 等传感器的数据采集与初步处理，并将处理后的信息通过无线网络传输至主机进行进一步计算与优化。此外，主机可通过局域网向从机发送控制指令，实现对堆垛式无人叉车的远程操控与导航调整。

图 5-2 直观展示了该系统的软件连接与各功能模块的交互关系。该架构不仅提高了系统的数据处理能力和计算效率，同时确保了信息传输的稳定性与实时性，为堆垛式无人叉车在复杂环境下的自主作业提供了坚实的技术支撑。

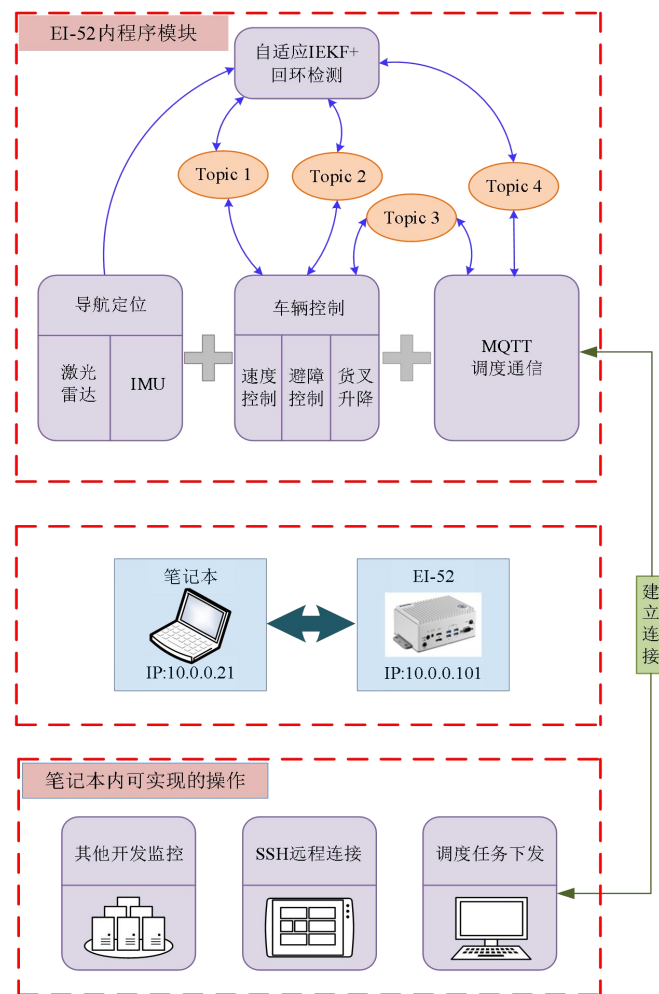


图 5-2 软件组成与交互示意图

采用上位机控制器 EI-52 和 PC 计算机为控制器，均运行 ROS 操作系统，导航定位软件和车控软件均为节点模式运行，采用 ROS 提供的发布/订阅机制。首先，主机创建并建立发布数据的节点和订阅数据的节点间的关系；然后，两节点

之间通过同一主题进行通信。

(2) 实验场地布局




图 5-3 实验中心俯视图

实际实验环境搭建在导航实验室内，场地内主要包括实验室场地，堆垛式无人叉车实验对象。数字1代表了实验路径中的路径节点，每个节点都表示路径中的特征表示点。首先，起点代表堆垛式无人叉车的起始点，终点代表实验路径2的停止目标点，堆垛式无人叉车的行驶方向，在图5-3中用箭头标出，具体参照图5-3所示。




图 5-4 实验中心环境及路径

在堆垛式无人叉车的路径设计中，为保证堆垛式无人叉车的任务正常进行。堆垛式无人叉车行驶过程中，路径的跟踪也需要实现对设计好的路径的追踪。在实验场地内，主要的实验路径包括直线和转弯。

5.2 堆垛式无人叉车优化算法高精度定位实验与实验结果分析

5.2.1 堆垛式无人叉车指定路径定位实验

为了验证单一的传感器定位与多传感器紧耦合系统定位以及LIDAR-IMU紧耦合融合的自适应IEKF算法定位与是否加入基于自适应半径搜索策略的回环检测定位效果的差距。进行堆垛式无人叉车指定路径实验，计算堆垛式无人叉车在行驶过程中每一种定位方法的定位误差，并对定位误差的最大值、最小值和平均进行对比，计算出具体效果提升比例。

测量堆垛式无人叉车在沿所设定路径运动时的位姿曲线，图 5-5 给出了堆垛式无人叉车沿指定路径行驶时的定位信息示意图。




图 5-5 堆垛式无人叉车定位信息示意图

从图 5-5 中可以看到，当 IMU 传感器随着行驶距离的增加以及行驶时间的延长时，IMU 的定位误差逐渐积累，导致精度逐渐下降。这种误差的累积是由于 IMU 自身存在的偏差无法得到有效修正，导致定位精度随时间逐渐降低。相比之下，使用激光雷达进行定位时，能够获取较为精确的定位信息，尤其是在短时间内。然而，激光雷达的定位方法存在周期性数据扫描的问题，意味着其无法实时提供连续定位数据，这使得其在动态环境中的应用受到一定的限制。

当激光雷达与 IMU 紧耦合进行定位时，尽管能够在一定程度上减少 IMU 的误差积累，但由于两者数据融合时的同步问题，可能会导致系统在特定情境下仍然出现一定的精度下降，特别是在长时间运行后，激光雷达提供的信息有助于修正 IMU 的漂移，但由于激光雷达周期性的扫描特性，无法实时补偿 IMU 的持续漂移。本文算法通过将激光雷达数据与 IMU 数据进行紧耦合融合，充分发挥两

者优势,从而克服了单一传感器存在的问题,通过引入自适应迭代次数调整机制的 IEKF 算法,进一步提高了滤波精度。后端结合基于自适应半径搜索策略与密度计算模型结合的回环检测方法,能够在长时间运行过程中有效抑制定位漂移,从而大幅提升系统的全局定位精度和稳定性。

通过对堆垛式无人叉车在实际运行过程中不同方案下的定位误差数据进行了定量分析,本研究评估了各方案在定位精度方面的差异,为进一步优化定位系统提供了重要的参考依据。如表 5-1 所示。

表 5-1 动态定位精度表

传感器	定位误差均值(mm)	定位误差最大值(mm)	定位误差最小值(mm)
激光雷达	48.963	59.657	1.545
紧耦合系统	44.584	58.983	1.367
自适应IEKF融合	38.431	51.165	0.076
自适应IEKF融合 +回环检测	20.493	22.619	0.026

根据表 5-1 中的实验结果,在动态行驶过程中,激光雷达由于噪声和扫描周期的影响,定位精度约为 48.963 mm,尽管紧耦合系统能够提供较好的融合结果,但由于误差积累,系统的定位误差均值达到了 44.584 mm;采用基于直接点云处理与 IMU 融合自适应 IEKF 算法后,定位精度得到了显著改善,定位误差均值降低至 38.431 mm,表明该方法有效提升了堆垛式无人叉车的定位精度;进一步引入基于自适应半径搜索策略与密度计算模型的回环检测方法后,定位精度得到了更大幅度的提升,误差均值降至 20.493 mm,与基于直接点云处理与 IMU 融合的自适应 IEKF 算法相比,定位精度提升了 46.675%,充分验证了基于自适应半径搜索策略的回环检测方法在提升长期定位精度方面的重要作用。

5.2.2 堆垛式无人叉车自主导航重复定位实验

为验证加入基于自适应半径搜索策略的回环检测的稳定性,进行堆垛式无人叉车到达目标点后停止的定位精度实验。在指定路径实验基础上,开展 50 次实验测试。目标点位置为所设路径终点(14,3),测量到达目标点的定位精度。定位精度为指定目标点与堆垛式无人叉车实验到达位置的坐标误差,误差表达为:

$$\delta = \sqrt{(14 - x_t)^2 + (3 - y_t)^2} \quad (5-1)$$

具体结果如图 5-6，图 5-7 与图 5-8 所示。




图 5-6 x 坐标对比图




图 5-7 y 坐标对比图




图 5-8 定位误差 δ 对比图

表 5-2 定位误差测试结果对比

	坐标			定位峰值到理论位置之差(m)		定位
	均值(x,y)	最大误差坐标(m)		Δx	Δy	偏差 (mm)
		x	y			
理论位置	(14,3)	0	0	0	0	0
自适应 IEKF	(13.966842, 3.02545)	13.9499	3.0299	0.0501	0.0299	±20.8991
自适应 IEKF+ 回环检测	(13.997206, 3.013256)	13.985	3.0169	0.015	0.0169	±6.7736
优化效果	--	--	--	70.658%	43.478%	67.589%

在图 5-4、图 5-5、图 5-6 以及表 5-2 中所列的误差对比结果显示，堆垛式无人叉车在未引用基于自适应半径搜索策略的回环检测时，其定位偏差为±20.8991 mm。经过引入基于自适应半径搜索策略回环检测后，定位偏差显著降低至±6.7736 mm，定位精度提升约为 67.589%。在 x 方向的定位误差方面，未加入自适应半径搜索策略的回环检测时， x 方向的最大定位误差为 0.0501 m；而经过引入自适应半径搜索策略回环检测后， x 方向最大定位误差降至 0.015 m，定位精度提升约为 70.059%。在 y 方向的定位误差方面，未采用自适应半径搜索策略回环检测时， y 方向最大定位误差为 0.0299 m，而经过该策略后， y 方向的最大定位误差缩小至 0.0169 m，提升效率约为 43.478%。这些实验结果表明，引入基于自适应半径搜索策略的回环检测能够显著提高堆垛式无人叉车的定位精度，从而有效提升其在复杂环境中的定位性能。

此外，在本研究中使用了标准偏差和置信区间来评估实验数据的置信度。置信度是指基于样本数据，估计真实总体参数（如总体标准差）所在区间的概率。在进行定位误差评估时，置信度的计算可以帮助了解定位精度的可靠性。具体来说，通过计算样本数据的标准差 s_x 和 s_y 以及 95%的置信区间来定量描述定位误差的范围。

首先根据实验数据计算的各个坐标的标准差 s ：

$$\begin{cases} s_x = \sqrt{\frac{1}{N-1} \sum_{i=1}^N (x_i - \bar{x})^2} \\ s_y = \sqrt{\frac{1}{N-1} \sum_{i=1}^N (y_i - \bar{y})^2} \end{cases} \quad (5-2)$$

其中： x_i 和 y_i 分别是每个坐标点的 x 和 y 值， $\bar{x}$ 和 $\bar{y}$ 是 x 和 y 坐标的均值， N 为样本数量。标准差是描述数据离散程度的常用指标，能够反映出测量误差的大小。随即，根据标准差计算 95% 的置信区间半宽度 h ，该区间表示在 95% 的置信水平下，真实的总体标准差位于该范围内。具体公式如下：

$$h = t_{\alpha/2, N-1} \times \frac{8}{\sqrt{N}} \quad (5-3)$$

其中： $t_{\alpha/2, N-1}$ 是 t 分布的临界值， α 是显著性水平（通常取 0.05，对应 95% 的置信区间）， N 是样本数量。通过该公式，可以计算出在 95% 的置信水平下，标准差可能的波动范围。

因此，95% 的置信区间半宽度 h 为定位误差的可靠范围，表明真实的定位误差有 95% 的概率落在这个区间内。较小的半宽度意味着更高的定位精度和更小的测量误差，反之则表示较低的置信度和更大的误差范围。




图 5-9 重复定位实验（50 次）分布图

如图 5-9 为重复定位实验的分布图，在本实验中，我们分别评估了堆垛式无

人叉车在两种不同定位条件下的精度表现：一种是在 LIDAR-IMU 紧耦合融合的自适应 IEKF 算法与采用基于自适应半径搜索策略的回环检测，另一种是在仅 LIDAR-IMU 紧耦合融合的自适应 IEKF 算法。实验中， x_1 和 y_1 分别为在 LIDAR-IMU 紧耦合融合的自适应 IEKF 算法与采用基于自适应半径搜索策略的回环检测计算得出的坐标，而 x_2 和 y_2 则是在仅使用 LIDAR-IMU 紧耦合融合的自适应 IEKF 算法时计算的坐标。

实验结果表明，在 LIDAR-IMU 紧耦合融合的自适应 IEKF 算法与采用基于自适应半径搜索策略的回环检测下， x_1 坐标的标准差为 0.0069，95%置信区间半宽度为 0.0020， y_1 坐标的标准差为 0.0018，95%置信区间半宽度为 0.0005。这表明引入基于自适应半径搜索策略的回环检测后，定位精度得到了显著提升，尤其是在 y_1 方向上的精度进一步提高。

相比之下，在仅 LIDAR-IMU 紧耦合融合的自适应 IEKF 算法下， x_2 坐标的标准差为 0.0086，95%置信区间半宽度为 0.0024， y_2 坐标的标准差为 0.0028，95%置信区间半宽度为 0.0008。虽然仅使用自适应 IEKF 融合时，定位精度仍然较高，但与引入基于自适应半径搜索策略的回环检测后定位结果相比， x_2 和 y_2 坐标的误差范围更大，尤其在 x_2 坐标方向上，精度相对较低。

从这些结果可以看出，基于自适应半径搜索策略的回环检测显著提高了定位精度，尤其是在 x 坐标方向上，能够有效减少长期运行过程中的漂移，并提升全局定位精度，进一步验证了其在堆垛式无人叉车实现了更高精度和稳定性的定位。

5.3 本章小结

本章围绕堆垛式无人叉车的高精度定位实验与结果分析展开研究，设计了试验方案，实验部分包括指定路径实验与自主导航重复定位实验，通过对定位信息进行分析，用定位误差与基于标准偏差与 95%置信区间表示，进一步确认了本文算法对长距离自主导航的稳定性。所设计实验的结果验证了本文算法能够有效的抑制舵轮形变带来的误差与长距离行驶的定位漂移，从而提高堆垛式无人叉车的定位精度。

第 6 章 总结与展望

随着工业自动化和智能物流系统的快速发展,高精度定位技术已成为堆垛式无人叉车实现自主导航和高效作业的关键技术。本论文围绕堆垛式无人叉车高精度定位关键技术展开研究,通过建立激光雷达和 IMU 的观测模型以及堆垛式无人叉车的运动学与动力学模型,为多传感器数据融合提供了理论依据,并就垂向动力学模型进行了误差机理分析;在此基础上,提出了基于直接点云处理与 IMU 融合的自适应 IEKF 算法,通过统一时间戳和基于卡尔曼增益调整策略,有效提高了状态估计的精度;随即,针对长时间运行中产生的累积误差问题,设计了基于自适应半径搜索策略的回环检测与定位优化方法,实现了全局轨迹误差的修正;最后,通过实物实验验证了所提算法在不同工况下的高精度定位性能。本章将对全文研究工作进行系统总结,并对未来工作方向提出展望。

6.1 论文总结

随着科学技术的不断进步,堆垛式无人叉车在组合导航高精度定位领域取得了显著成果,但仍存在若干待改进之处。为进一步提升定位效果,本文构建了激光雷达与 IMU 紧耦合系统,并在此基础上提出了基于 IEKF 算法的多传感器数据融合方法,同时引入基于卡尔曼增益的动态调整策略以优化迭代次数,从而降低估计误差;另一方面,为改善长距离运行中的定位性能,本文提出了一种基于自适应半径搜索策略的回环检测方法,并利用图优化技术对轨迹进行全局修正。这些方法在不同工况下均显著提高了堆垛式无人叉车的定位精度。主要取得成果如下:

(1) 提出一种多维信息融合定位优化算法,通过实验验证了该算法在计算效率、定位精度及复杂场景适应性方面的优势。首先,构建激光雷达观测模型与 IMU 测量模型,推导 IMU 惯性解算方法,并建立堆垛式无人叉车运动学与动力学模型,以分析运动特性及误差来源。同时,基于作业环境需求,构建控制系统与导航系统。在此基础上,针对舵轮形变误差与非线性误差,提出基于直接点云处理与 IMU 融合的自适应 IEKF 算法。该算法在激光雷达与 IMU 紧耦合框架下,利用三次样条插值进行时间同步,消除时钟偏差,并基于全点云几何配准避免特

征匹配误差。此外,采用基于卡尔曼增益的动态调整策略,以抑制非线性误差和传感器噪声,从而提升状态估计精度与系统实时性。实验基于多个数据集进行验证,结果表明,该算法在点云处理效率与定位精度方面均优于 LOAM、LIOM 等方法。其中,在 KITTI 数据集中,平均处理时间为 0.06 秒/帧,较 LOAM、LIOM 和 LIO-GPS 分别提升 50%、25%和 60%;在 Campus 数据集中, RMSE 为 94.4 mm,显著优于 LOAM 和 LIOM;在 Park 数据集中, RMSE 为 263.6 mm,较 LOAM 和 LIOM 分别降低 78.34%和 51.73%。

(2) 提出一种回环检测和全局定位优化方法,通过实验验证了该方法有效提升了定位精度,不仅提高了回环检测的准确性,而且显著改善了整体定位精度和系统的稳定性。为了解决长时间运行中累积误差和定位漂移的问题,设计了基于自适应半径搜索策略的回环检测与定位优化方法。通过引入密度计算模型和局部几何特征模型,对环境点云进行高效特征匹配,并构建姿态图利用图优化技术对全局轨迹进行修正。实验结果表明,在 Campus 场景中, LIDAR-IMU 紧耦合融合的自适应 IEKF 算法与采用基于自适应半径搜索策略的回环检测的 RMSE 为 65.6 mm,较未引入基于自适应半径搜索策略的回环检测降低 30.5%,且精度接近 LIO-GPS;在 Park 场景中,该方法的 RMSE 为 149.8 mm,相较于仅使用 LIDAR-IMU 紧耦合融合的自适应 IEKF 算法提升 43.17%,显著优于 LOAM 和 LIOM,并达到 LIO-GPS 的精度水平。

(3) 针对本文提出信息融合与回环检测的算法,设计了指定路径实验和自主导航重复定位实验,验证了本文所提算法在抑制长期漂移、提升全局定位精度与稳定性方面的显著效果,为复杂场景下的高精度自主导航提供了可靠支撑。实验结果表明,在指定路径实验中, LIDAR-IMU 紧耦合融合的自适应 IEKF 算法与采用基于自适应半径搜索策略的回环检测定位误差均值降至 20.493 mm,较未引入基于自适应半径搜索策略的回环检测定位精度提升 46.675%,且显著优于激光雷达和 IMU 紧耦合系统;在 50 次重复定位实验中, LIDAR-IMU 紧耦合融合的自适应 IEKF 算法与采用基于自适应半径搜索策略的回环检测定位偏差为 ± 6.7736 mm,较仅 LIDAR-IMU 紧耦合融合的自适应 IEKF 算法算法优化 67.589%,其中 x 、 y 方向最大误差分别从 50.1 mm、29.9 mm 降至 15 mm、16.9 mm,提升效率达 70.658%和 43.478%;并通过置信区间分析进一步表明,加入基于自适应

半径搜索策略的回环检测后, x 、 y 坐标标准差由 0.0086 和 0.0028 分别降至 0.0069 和 0.0018, 95%置信区间半宽度由 0.0024 和 0.0008 缩窄至 0.0020 和 0.0005。

6.2 研究展望

堆垛式无人叉车通过多传感器信息融合与后端优化技术,在智慧物流和智能制造系统中发挥着关键作用,实现了实时智能化操作,显著推动了智能制造的发展。尽管本研究在定位精度与系统稳定性等方面取得了初步成果,但由于研究对象的固有局限性以及实验平台未能在真实工厂环境中进行充分验证,仍有以下几个方面可以在未来进行进一步的研究和探索:

(1) 多传感器深度融合与多模态感知。目前的研究主要集中于激光雷达与 IMU 的紧耦合数据融合,未来可引入视觉、毫米波雷达、超宽带(UWB)等多种传感器,实现多模态数据的深度融合。通过构建更加全面的感知系统,不仅能够充分利用各类传感器的优势,弥补单一传感器在特定场景下的局限性,还可以提高系统在复杂环境中的鲁棒性与适应性。此外,结合深度学习方法进行传感器数据的特征提取与融合,也将为提升整体定位与导航精度提供新的思路。

(2) 多机器人协同与系统集成。随着智能物流和自动化生产的发展,多台堆垛式无人叉车的协同作业已成为必然趋势。未来的研究可以扩展到多机器人协同调度与路径规划,通过分布式控制与信息共享机制,实现各单元之间的协同定位与避碰控制。此外,将高精度定位技术与智能调度、任务分配及自主决策系统进行深度融合,构建完整的智能物流系统,也是一个重要的研究方向。

参考文献

- [1] 梁军, 韩冬冬, 盘朝奉, 等. 基于移动机器人的智能车库关键技术综述[J]. 机械工程学报, 2022, 58(3): 1-20.
- [2] G. Bresson, Z. Alsayed, L. Yu, et al. Simultaneous Localization and Mapping: A Survey of Current Trends in Autonomous Driving[J]. IEEE Transactions on Intelligent Vehicles, 2017, 2(3): 194-220.
- [3] 胡建. 世界级工厂视角下烧料车间 AGV 智能导航定位方法研究[J]. 机电信息, 2021, (15): 33-36.
- [4] Y.Y. Huang, L. Horvath, P. Böröcz. Measurement and Analysis of Industrial Forklifts Vibration Levels for Unit Load Testing Purposes[J]. Applied Sciences, 2021, 11(7): 2901.
- [5] Z. Xiong, H. Zhou, X. Wu, et al. Work Efficiency and Economic Efficiency of Actual Driving Test of Proton Exchange Membrane Fuel Cell Forklift[J]. Molecules, 2022, 27(15): 4918.
- [6] R. Stefanini, G. Vignali. Environmental and economic sustainability assessment of an industry 4.0 application: the AGV implementation in a food industry[J]. The International Journal of Advanced Manufacturing Technology, 2022, 120(5-6): 2937-2959.
- [7] Z. Xiong, H. Zhou, X. Wu, et al. Work Efficiency and Economic Efficiency of Actual Driving Test of Proton Exchange Membrane Fuel Cell Forklift[J]. Molecules, 2022, 27(15): 4918.
- [8] S. Su, X. Zeng, S. Song, et al. Positioning Accuracy Improvement of Automated Guided Vehicles Based on a Novel Magnetic Tracking Approach[J]. IEEE Intelligent Transportation Systems Magazine, 2020, 12(4): 138-148.
- [9] 薛光辉, 李瑞雪, 张钰昊等. 基于 3D 激光雷达的 SLAM 算法研究现状与发展趋势[J]. 信息与控制, 2023, 52 (01): 18-36.
- [10] 黄加俊, 卿兆波, 张珠耀. 基于激光 SLAM 的全方位移动机器人控制系统设计[J]. 科技通报, 2020, 36 (7): 81-85.

- [11]姚陈鹏, 石文博, 刘成菊等. 移动机器人导航技术综述[J]. 中国科学:信息科学, 2023, 53 (12): 2303-2324.
- [12]毛军, 付浩, 褚超群等. 惯性/视觉/激光雷达 SLAM 技术综述[J]. 导航定位与授时, 2022, 9(04): 17-30.
- [13]王天玉. 智能工厂磁导航 AGV 技术实现方法研究[D].南昌: 华东交通大学, 2022.
- [14]Jones T, Walker D. Development of Electromagnetic Guided Vehicles in the UK. *Journal of Intelligent & Robotic Systems*, 2020, 98(3): 421-435.
- [15]CamposC, ElviraR,RodríguezJJG, et al Orb-slam3:An accurat eopen-source library for visual, visual-inertial and multi-map slam [J]. *IEEE Transactions on Robotics*, 2021, 37(6):1874-1890.
- [16]董雪菲. 基于车载多传感器融合的定位与建图研究[D].哈尔滨: 哈尔滨工业大学, 2021.
- [17]Z. Lin, W. Chen, Q. Lou, et al. Review on the recent progress of laser frontiers in China[J]. *Science China Technological Sciences*, 2013, 56(7): 1571-1588.
- [18]Cadena C, Carlone L, Carrillo H, et al. Past, present, and future of simultaneous localization and map:Toward the robust-perception age[J]. *IEEE Transactions on robotics*, 2016, 32(6): 1309-1332.
- [19]郑川川. 融合 IMU/激光雷达的无人车三维建图与导航研究[D].南京: 南京信息工程大学, 2023.
- [20]曹斌. 基于动态匹配的激光导航 AGV 定位技术研究[D].杭州: 浙江大学, 2020.
- [21]蒋旭东.基于多传感器融合的紧耦合 SLAM 算法的设计与实现[D].长春: 吉林大学, 2023.
- [22]Zou Q, Sun Q, Chen L, et al. A comparative analysis of LiDAR SLAM-based indoor navigation for autonomous vehicles[J]. *IEEE Transactions on Intelligent Transportation Systems*, 2021, 23(7): 6907-6921.
- [23]S. Su, X. Zeng, S. Song, et al. Positioning Accuracy Improvement of Automated Guided Vehicles Based on a Novel Magnetic Tracking Approach[J]. *IEEE Intelligent Transportation Systems Magazine*, 2020, 12(4): 138-148.

- [24]Q. Zou, Q. Sun, L. Chen, et al. A Comparative Analysis of LiDAR SLAM-Based Indoor Navigation for Autonomous Vehicles[J]. IEEE Transactions on Intelligent Transportation Systems, 2022, 23(7): 6907-6921.
- [25]Kim H, Lee C, et al. Multi-Sensor SLAM for Warehouse AGVs. IEEE Transactions on Industrial Informatics, 2023, 19(2): 890-902.
- [26]Huang L. Review on LiDAR-based SLAM techniques[C]//2021 International Conference on Signal Processing and Machine Learning (CONF-SPML). IEEE, 2021: 163-168.
- [27]张鹏. 托盘式 AGV 叉车结构设计和稳定性研究[D].淮南: 安徽理工大学, 2019.
- [28]W. Hess, D. Kohler, H. Rapp, et al., Real-time loop closure in 2D LIDAR SLAM, 2016 IEEE International Conference on Robotics and Automation (ICRA), 2016, pp. 1271-1278.
- [29]Chen, Li-Hsin, Peng, et al. A Robust 2D-SLAM Technology With Environmental Variation Adaptability[J]. IEEE Sensors Journal, 2019, 19(23): 11475-11491.
- [30]刘铭哲, 徐光辉, 唐堂, 等. 激光雷达 SLAM 算法综述[J]. 计算机工程与应用, 2024, 60(01): 1-14.
- [31]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.
- [32]丁声雷. 激光导航 AGV 车载控制系统设计与路径跟踪算法研究[D].成都: 西华大学, 2018.
- [33]王强. 叉车式 AGV 室内精确定位与运动控制方法研究[D].成都: 西华大学, 2022.
- [34]李恒恒. 基于 SLAM 导航的堆垛式叉车 AGV 研究与设计[D].合肥: 合肥工业大学, 2022.
- [35]彭慕蓉. 仓储叉车的激光导引技术研究[D].合肥: 合肥工业大学, 2018
- [36]刘铭哲, 徐光辉, 唐堂, 等. 激光雷达 SLAM 算法综述[J]. 计算机工程与应用, 2024, 60(01): 1-14.

- [37]Zeng W, Huang W, et al. Multi-Sensor Fusion for Autonomous Forklift Localization in Dynamic Warehouse Environments. *IEEE Sensors Journal*, 2018, 18(9): 3791-3802.
- [38]徐京邦. 基于激光反射板的激光导航 AGV 定位与地图构建方法研究[D]. 北京: 机械科学研究总院, 2020.
- [39]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.
- [40]Kohlbrecher S, Meyer J, Von Stryk O, et al. A flexible and scalable SLAM system with full 3D motion estimation[C]//2011 IEEE International Symposium on Safety, Security, and Rescue Robotics. IEEE, 2011: 155-160.
- [41]Konolige K, Grisetti G, Kümmerle R, et al. Efficient sparse pose adjustment for 2D mapping[C]//2010 IEEE/RSJ International Conference on Intelligent Robots and Systems. IEEE, 2010: 22-29.
- [42]Hess W, Kohler D, Rapp H, et al. Real-time loop closure in 2D LIDAR SLAM[C]//2016 IEEE International Conference on Robotics and Automation (ICRA). IEEE, 2016: 1271-1278.
- [43]W.P.N. dos Reis, O. Morandin Junior. Sensors applied to automated guided vehicle position control: a systematic literature review[J]. *The International Journal of Advanced Manufacturing Technology*, 2021, 113(1-2): 21-34.
- [44]Hess W, Kohler D, Rapp H, et al. Real-time loop closure in 2D LIDAR SLAM[C]//2016 IEEE international conference on robotics and automation (ICRA). IEEE, 2016: 1271-1278.
- [45]Smith R, Taylor C, et al. Advances in LiDAR-Based Positioning for Industrial Vehicles. *Robotics and Autonomous Systems*, 2019, 113: 1-10.
- [46]秦齐. 基于激光导引的叉车式 AGV 定位建图与路径规划技术研究[D]. 济南: 山东大学, 2022.
- [47]Júnior G P C, Rezende A M C, Miranda V R F, et al. EKF-LOAM: an adaptive fusion of LiDAR SLAM with wheel odometry and inertial data for confined

- p spaces with few geometric features[J]. IEEE Transactions on Automation Science and Engineering, 2022, 19(3): 1458-1471.
- [48]L. Kong, X. Peng, Y. Chen, et al. Multi-sensor measurement and data fusion technology for manufacturing process monitoring: a literature review[J]. International Journal of Extreme Manufacturing, 2020, 2(2): 022001.
- [49]Kailath,T. A view of three decades of linear filtering theory[J]. IEEE Transactions on information theory, 1974, 20(2): 146-181.
- [50]Bersani M, Biral F, Pietrini L. Multi-sensor fusion for vehicle tracking using millimeter-wave radar and LIDAR[C]//2019 IEEE Intelligent Vehicles Symposium (IV). IEEE, 2019: 2364-2370.
- [51]Park S, Lee J, Lee K. Sonar-based vehicle localization in dynamic environments using map-matching technique[J]. Sensors, 2018, 18(8): 2615.
- [52]Hyunhak K, Kim J, Hwang S. Enhanced localization method for magnetic-guided AGV using real-time encoder calibration[J]. IEEE Access, 2020, 8: 22371-22379.
- [53]S. Gao, Y. Zhong, W. Li. Random Weighting Method for Multisensor Data Fusion[J]. IEEE Sensors Journal, 2011, 11(9): 1955-1961.
- [54]Guo H, Zhu J, Chen Y. E-LOAM: LiDAR odometry and mapping with expanded local structural information[J]. IEEE Transactions on Intelligent Vehicles, 2022, 8(2): 1911-1921.
- [55]Xu W, Cai Y, He D, et al. Fast-lid2: Fast direct lidar-inertial odometry[J]. IEEE Transactions on Robotics, 2022, 38(4): 2053-2073.
- [56]Júnior G P C, Rezende A M C, Miranda V R F, et al. EKF-LOAM: an adaptive fusion of LiDAR SLAM with wheel odometry and inertial data for confined spaces with few geometric features[J]. IEEE Transactions on Automation Science and Engineering, 2022, 19(3): 1458-1471.
- [57]Shi P, Zhu Z, Sun S, et al. Invariant Extended Kalman Filtering for Tightly Coupled LiDAR-Inertial Odometry and Mapping[J]. IEEE/ASME Transactions on Mechatronics, 2023.

- [58]Salti S, Tombari F, Di Stefano L. SHOT: Unique signatures of histograms for surface and texture description [J]. Computer Vision and Image Understanding, 2014, 125: 251-264.
- [59]Prakhya S M, Liu B, Lin W. B-SHOT: A binary feature descriptor for fast and efficient keypoint matching on 3D point clouds [C]. IEEE/RSJ international conference on intelligent robots and systems (IROS), 2015: 1929-1934.
- [60]Guo J, Borges P V, Park C, et al. Local descriptor for robust place recognition using lidar intensity [J]. IEEE Robotics and Automation Letters, 2019, 4(2): 1470- 1477.
- [61]Rusu R B, Blodow N, Beetz M. Fast point feature histograms (FPFH) for 3D registration [C]. IEEE international conference on robotics and automation, 2009: 3212-3217
- [62]Wohlkinger W, Vincze M. Ensemble of shape functions for 3d object classification [C]. IEEE international conference on robotics and biomimetics, 2011: 2987-2992.
- [63]He L, Wang X, Zhang H. M2DP: A novel 3D point cloud descriptor and its application in loop closure detection [C]. IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS), 2016: 231-237.
- [64]Kim G, Kim A. Scan context: Egocentric spatial descriptor for place recognition within 3d point cloud map [C]. IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS), 2018: 4802-4809.
- [65]Wang H, Wang C, Xie L. Intensity scan context: Coding intensity and geometry relations for loop closure detection [C]. IEEE International Conference on Robotics and Automation (ICRA), 2020: 2095-2101.
- [66]Fan Y, He Y, Tan U-X. Seed: A segmentation-based egocentric 3D point cloud descriptor for loop closure detection [C]. IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS), 2020: 5158-5163.
- [67]Wang Y, Sun Z, Xu C-Z, et al. Lidar iris for loop-closure detection [C]. IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS), 2020: 5769- 5775.

- [68] Li L, Kong X, Zhao X, et al. SSC: Semantic scan context for large-scale place recognition [C]. IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS), 2021: 2092-2099.
- [69] 丁盼云. 基于三维激光雷达的回环检测算法[D]. 南京: 南京理工大学, 2022.
- [70] 廖礼洲. 面向激光雷达同时定位与建图的回环检测研究[D]. 重庆: 重庆大学, 2023.
- [71] 武东杰, 仲训昱, 崔晓珍, 等. 可在线配置结构的多源融合位姿估计框架[J]. 机器人, 2022, 44 (06): 660-671.
- [72] 姚二亮, 宋海涛, 赵婧, 等. 考虑点云结构和表观信息的激光雷达-惯性 SLAM 算法[J]. 机器人, 2024, 46 (04): 436-449.
- [73] 路春晓, 钟焕, 刘威, 等. 复杂地形环境下的多传感器融合 SLAM 技术[J]. 机器人, 2024, 46 (04): 425-435.

攻读硕士专业学位期间学术成果

参与项目：

- [1] 安徽省属公办普通本科高校领军骨干人才项目
- [2] 安徽省经信委“揭榜挂帅项目”：“新一代嵌入式无人叉车专用控制器及片上系统研发”
- [3] 徐州徐工特种工程机械有限公司横向项目“搬运型 AGV 运动控制及作业调度系统研发”
- [4] 安徽工程大学-鸠江区产业协同创新专项基金项目：“基于 5G 云化的无人叉车及其作业调度系统研发与应用”
- [5] 安徽工程大学产业创新技术研究有限公司横向项目：“数字孪生驱动的复合移动机器人协同制造关键技术研究”

致谢

三载春秋，荏苒而过。回望硕士求学之路，既有钻研时的专注，也有迷茫时的踟蹰；既有豁然开朗的喜悦，也有独自咬牙前行的沉默。这段旅程不仅是知识的积淀，更是心智的磨砺，是我生命中一段不可复制的经历。如今，论文完成之际，提笔回望，心中满是感激，愿将这份沉甸甸的谢意，献给在这段旅途中给予我帮助与温暖的每一个人。

首先，最深的感谢，献给我的父母。您们始终是我生命中最坚实的依靠，在我追梦的每一个日子里，是您们在背后默默支持，给予我勇气与底气。所有的坚持与努力，背后都有无条件的守望与等待。谢谢，让我有了披荆斩棘的底气，也让我始终相信，无论走得多远，家始终是最温暖的归宿。

感谢导师汪步云教授、实验室的同门与师兄师弟们。在无数个实验调试的过程，在一次次数据分析与推导的过程中，共同见证了彼此的成长。每一声寒暄，每一次讨论，都是我珍藏于心的宝贵回忆。

此外，我还想感谢一位从本科到硕士一路相伴的挚友：陈矗。从国旗护卫队到如今各自奔赴前程，曾无数次在迷茫时彼此打气，互为支撑。如今你即将踏上求学的更高阶梯，愿你怀揣初心，步履不停。他日再见，不论身在何方，愿我们都能以最好的姿态，笑对未来，再叙旧时。

最后将一份深埋心底的谢意，留给始终坚持的自己。一路走来，或有迷惘，或曾犹豫，但从未止步。如今学业将毕，未来的道路或许更为宽阔，但仍愿保持一份热诚与清醒，在新的岗位上厚积薄发。愿不为喧嚣所扰，于平凡之中积蓄力量，于奔忙之间守住初心，步履不停，心有所向，目光有光。

在论文完成之际，我愿以平静之心回顾这段旅程中一个曾与我同行的身影。人生如长路，某些段落因特定缘分而交汇，又因各自的轨迹而分离。感谢某段时光中的彼此陪伴与成长，那些经历已然成为塑造今日之我的无形组成部分。

感谢所有曾经给予我指导、帮助与善意的人：每一位老师、朋友，甚至那些素未谋面却在某个瞬间带给我鼓励的人。我也将继续怀着一颗敬畏之心，走向更远的地方，脚踏实地，心怀光亮。

谨以此致谢，献给所有给予我成长、理解与支持的人。

尚德敏学 唯实惟新

