

基于多模态信息融合的仓储AGV的激光惯性导航方法

张博¹, 张吟龙^{2,3,4*}, 梁炜^{2,3,4}, 王鑫¹, 杨雨沱^{2,3,4}

¹沈阳建筑大学电气与控制工程学院, 辽宁 沈阳 110168;

²中国科学院网络化控制系统重点实验室, 辽宁 沈阳 110169;

³中国科学院机器人与智能制造创新研究院, 辽宁 沈阳 110169;

⁴中国科学院沈阳自动化研究所机器人学国家重点实验室, 辽宁 沈阳 110169

摘要 提出一种基于激光惯性二维码融合的自动导引运输车(AGV)导航方法。针对惯性偏差漂移的问题,提出融合二维码的惯性测量单元(IMU)预积分模型,利用二维码约束信息优化惯性残差,估计和校正惯性偏差。针对实时性差的问题,提出一种具有全局一致性的优化模型,通过选择性地引入关键帧和二维码,执行融合二维码的分层局部捆绑约束(BA)优化,以有效缩短优化时间;提出激光雷达/IMU/二维码紧耦合优化方法,通过将预积分因子、回环因子、二维码因子、跟踪因子纳入因子图系统,实现多层次的数据融合,以有效提高定位精度与鲁棒性。在搭建的仓储AGV导航平台上进行了大量的实验和分析,并与几种代表性开源方法进行对比。结果表明,本文方法的导航精度优于传统方法,其中定位精度误差小于0.02 m,角度误差小于2°。

关键词 激光雷达; 同时定位和建图; 惯性测量单元预积分; 二维码; 因子图优化

中图分类号 TN958.98

文献标志码 A

DOI: 10.3788/AOS231613

1 引言

仓储物流车间是一个专门用于存储、组织和运输各种货物的场所,该环境通常包括密集的货架、多样的货物,以及自动导引运输车(AGV)^[1]等自动化设备。随着自动化水平的不断提高,运用同时定位与建图(SLAM)^[2]技术实现自主导航的自动导引车在实际应用中变得越来越重要。

SLAM算法根据所采用的传感器类型主要可分为视觉SLAM^[3]与激光SLAM^[4-5]。其中,激光雷达具有高精度、不受光照影响等优势^[6]。然而,激光雷达在退化场景^[7]下无法提供机器人的准确姿态信息,其导航精度不高。因此,激光SLAM常与惯性测量单元(IMU)^[8-9]相融合,以提高定位和建图的准确性与稳定性。

激光雷达与IMU融合通常分为两类:松耦合融合^[10]和紧耦合融合^[11-12]。松/紧耦合算法的区别是IMU算法优化过程中的深度。在松耦合方面:Zhang等^[13]针对机器人运动产生的运动畸变,提出激光雷达里程计与地图构建方法(LOAM),通过引入IMU消除

激光雷达扫描带来的角度倾斜,使得运动估计的准确性提升15.8%,但缺少回环检测;Shan等^[14]针对LOAM累计误差大的问题,提出了一种轻量级的地面优化激光雷达定位与建图方法(LeGO-LOAM),以提高建图一致性,然而IMU没有参与到优化过程中;Ganesan等^[15]针对仓储环境下人工参与多的弊端,提出无需人工干预的自主机器人导航方法,但该方法存在多传感器时延和同步问题。与松耦合系统相比,紧耦合系统具有高精度和鲁棒性的优势。Ye等^[16]针对算法在高速环境下运动估计的准确性较低的问题,提出一种紧耦合的激光雷达惯性SLAM框架(LIOM),实现高速状态下系统状态的有效优化,然而批量优化的计算量过大;Qin等^[17]针对LIOM计算成本高的问题,提出一种以机器人为中心的激光雷达惯性状态估计器(LINS),使用误差状态卡尔曼滤波器以紧耦合方式递归纠正机器人的状态误差,使得扫描时间减少一个数量级,然而LOAM和LINS都缺少对绝对测量数据的姿态校正;Shan等^[18]针对此问题提出了一种基于平滑建图的紧耦合激光雷达惯性里程计框架(LIO-SAM),将多种测量数据作为因子实时插入到因子图

收稿日期: 2023-09-28; 修回日期: 2024-02-20; 录用日期: 2024-02-28; 网络首发日期: 2024-03-13

基金项目: 国家自然科学基金(62273332)、中国科学院青年创新促进会项目(2022201)、广东省基础与应用基础研究基金(2023A1515011363)

通信作者: *zhangyinlong@sia.cn

中,然而在仓储室内等 GPS 信号缺失环境中,算法的鲁棒性大打折扣;针对 LIO-SAM 问题,Zhang 等^[19]提出基于二维码的改进的自适应蒙特卡罗定位算法,通过对多源信息进行融合,使得导航定位精度提高 64.27%,然而该算法依然难以解决 IMU 的偏差漂移问题。

激光惯性融合方法需要 IMU 预积分来处理高频率的 IMU 数据,提供稳定、准确的状态估计。然而,IMU 预积分过程中存在非线性误差和偏差漂移等问题。Forster 等^[20]针对非线性误差问题,基于李群模型在流形空间估计 IMU 的位姿项和速度项,以减小增量式的累积误差,但该方法依然存在偏差漂移严重的问题;Qin 等^[21]针对偏差漂移问题,基于关键帧模型并采用非线性优化方式来降低 IMU 偏差和系统偏差对状态估计的影响,但该方法存在非线性优化计算复杂度较高带来的实时性差的问题;Bahnam 等^[22]提出一种多状态约束卡尔曼滤波器,联合优化 IMU 和视觉传感器的数据,同时对 IMU 误差进行建模和校准,但该方法在高动态环境下依旧存在一定的误差。

另外,在复杂的仓储车间中,导航系统需要更全面的地图信息来进行决策和规划。Xu 等^[23]针对递增式建图方法中固有的漂移和累积误差问题,利用位姿图优化(PGO)处理整个轨迹的位姿节点,得到更加精确的地图。然而,PGO 并不能直接通过优化提高点云的

一致性。Liu 等^[24]受视觉捆绑约束(BA)优化的启发,提出雷达 BA 优化,通过最小化协方差矩阵来约束从多帧提取的特征点到边缘线或者平面的距离,直接提高建图一致性,但优化过程中优化 N 个激光雷达位姿数时,计算 Hessian 矩阵至少需要 $O(N^3)$ 的求解时间,计算量巨大。

本文提出了一种新颖的激光惯性二维码紧耦合模型,通过在激光惯性中再融合二维码,并将预积分因子、跟踪因子、回环因子和二维码因子纳入因子图模型,实现多层次的数据融合,减小累积误差,提供具有全局一致性的 AGV 导航框架;提出融合二维码的 IMU 预积分模型,可硬性约束信息、更新惯性偏差,通过优化激光惯性下视角相机误差项,将通过二维码得到的绝对位姿作为初始化状态量,使得联合优化有良好的初始值,进而加快收敛并保证了估计精度;选择性地引入关键帧和二维码,执行从底层到顶层的分层局部 BA 优化以提高激光雷达建图一致性和定位精度,分层优化执行过程保持特定关键帧(二维码解算得到的关键帧)的姿态不变,并不参与优化进程,使得在保证精度的同时,缩短了优化时间。

2 算法概述

本文通过融合三维(3D)激光雷达、下视角二维码传感器和惯性传感器来实现仓储 AGV 的导航。算法框架如图 1 所示。

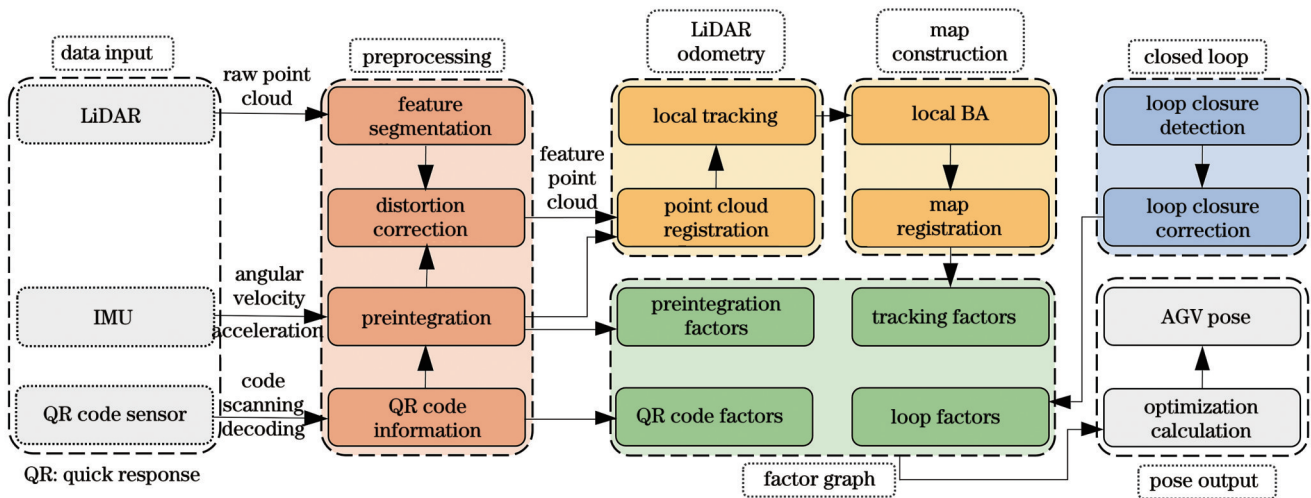


图 1 激光惯性二维码融合的仓储 AGV 导航框架

Fig. 1 Laser-inertial QR code fusion-based AGV navigation framework

系统整体分为如下 5 个部分:

1) 数据预处理。通过二维码传感器获取二维码标识,得到 AGV 相对于二维码的位置信息;通过对激光雷达获取的原始点云进行目标分割,提取特征点;将 IMU 输出的角速度和加速度数据进行预积分处理。需要注意的是,当扫描到二维码时,利用二维码的绝对位姿信息优化 IMU 预积分残差,获取运动估计值,对

特征点进行畸变校正。

2) 激光里程计。提出帧到稀疏局部地图跟踪模型,用于估计激光雷达的相对运动,提高定位精度和建图一致性。

3) 地图构建。利用优化模型来更新关键帧的姿态和地图点的位置,同时,由于二维码得到的位姿具有更高的置信度,因此设置特定关键帧的位姿固定,并更

新局部地图。

4) 回环检测。检测轨迹是否回环闭合,并将闭合处的点云配准结果作为约束条件优化 SLAM 系统的地图。

5) 因子图优化。将上述各部分得到的 IMU 预积分因子、二维码因子、跟踪因子和回环因子分别插入因子图中,实时进行优化计算,以实现仓储 AGV 的准确导航。

3 算法过程

本文算法针对动态、多变的仓库场景进行设计,重点解决了基于 3D 激光雷达、二维码传感器和惯性传感器数据融合的精确导航问题,以满足仓储系统中对 AGV 运行效率和可靠性的严格要求。

3.1 状态估计

定义 IMU 坐标系为载体坐标系 B,激光雷达坐标系 L 和下视角相机坐标系 D 分别经过 SE(3) 变换与载体保持一致;定义世界坐标系为 W,其原点为系统初始化情况下的载体坐标系原点,不同于文献[18]中第一帧姿态直接从 9 轴 IMU 中获取,车体初始位置和姿态可由初始扫描到的二维码信息得到。假设激光雷达第 i 次扫描到的全部点云为 \mathbf{P}_i ,且点云中任意一点记作 $\mathbf{p}_{k(B)} \in \mathbf{P}_i$; IMU 采集到的 $[t_i, t_{i+1}]$ 内的数据为

$$X_k = \arg \min_{X_k} \left[-\ln p(\mathbf{X}_k | \mathbf{Z}_k) \right] = \arg \min_{X_k} \left(\|\mathbf{r}_0\|_{\Sigma_0}^2 + \Sigma \|\mathbf{r}_{I(i,j)}\|_{\Sigma_{I(i,j)}}^2 + \Sigma \|\mathbf{r}_{M_i}\|_{\Sigma_{M_i}}^2 + \Sigma \|\mathbf{r}_{D(i,q)}\|_{\Sigma_{D(i,q)}}^2 + \Sigma \|\mathbf{r}_{L(i,j)}\|_{\Sigma_{L(i,j)}}^2 \right), \quad (4)$$

式中: \mathbf{r} 和 Σ 分别表示实际与模型观测结果之差(残差)和其对应的协方差矩阵。式(4)中的各项将在后文具体说明。

3.2 数据预处理

3.2.1 二维码识别

本文在地面上按照水平与垂直方向依次粘贴二维码,根据文献[25]对二维码进行图像处理,得到有效的二维码矩阵信息并进行解码,再进行坐标转换,从而得到 AGV 当前的绝对位姿信息。具体步骤如下:

1) 扫描二维码后,得到相应的二维码 ID d_i ,同时通过计算得到 x 、 y 轴上的位移量和角度偏转量,记为 $\{\Delta x, \Delta y, \Delta \varphi\}$ 。由于 AGV 是在平整地面运行,利用 Rodrigues 将偏转角 $\Delta \varphi$ 转为旋转矩阵 \mathbf{R} 。

2) 由 d_i 得到与此二维码相关的绝对世界坐标 $\{x_d, y_d, z_d\}$ 。通过结合 AGV 的水平位移偏移量与偏转角 $\{\Delta x, \Delta y, \Delta \varphi\}$,得到世界坐标系下下视角传感器的位置 $\{x_{(D)}, y_{(D)}, z_{(D)}\}_{(W)}$,最后得到世界坐标系下 AGV 的位置 $\{x_{(B)}, y_{(B)}, z_{(B)}\}_{(W)}$ 。

3.2.2 IMU 数据处理

IMU 是由三轴陀螺仪和三轴加速度计构成的六轴传感器,具有较高的采样速率,可获取加速度和角速度,其模型为

$\mathbf{I}_{(i,i+1)}$,由于 IMU 采样频率高, $[t_i, t_{i+1}]$ 中包含 M 组 B 坐标系下的角速度和加速度 $[\boldsymbol{\omega}_{i(B)}, \mathbf{a}_{i(B)}]$, $n = 1, 2, \dots, M$ 。激光雷达点云数据量庞大,为提高运算能力和节约计算资源,在数据处理过程中选择关键帧作为待优化的状态量。定义 t_k 时刻的全部关键帧为 F_k ,与之对应的状态量为 $\mathbf{X}_k = \{\mathbf{x}_i\}_{i \in F_k}$,与之对应的观测量为 $\mathbf{Z}_k = \{\mathbf{P}_i, \mathbf{I}_{(i,j)}\}_{(i,j) \in F_k}$, \mathbf{x}_i 为 t_i 时刻系统的状态,包括姿态 \mathbf{R}_i 、位置 λ_i 、速度 \mathbf{v}_i 和 IMU 零偏 \mathbf{b}_i , \mathbf{b}_i 由加速度零偏 $\mathbf{b}_a \in \mathbf{R}^3$ 与陀螺仪零偏 $\mathbf{b}_g \in \mathbf{R}^3$ 组成,故得到

$$\mathbf{x}_i = [\mathbf{R}_i, \lambda_i, \mathbf{v}_i, \mathbf{b}_a, \mathbf{b}_g]_0. \quad (1)$$

根据以上描述,可将状态估计问题描述为:在给定先验信息 \mathbf{X}_0 与观测信息 \mathbf{Z}_k 的状态下,估计 \mathbf{X}_0 的后验概率问题,即

$$p(\mathbf{X}_k | \mathbf{Z}_k) \propto p(\mathbf{X}_0) p(\mathbf{Z}_k | \mathbf{X}_k) = p(\mathbf{X}_0) \prod_{(i,j) \in F_k} p[\mathbf{P}_i, \mathbf{I}_{(i,j)} | \mathbf{X}_k]_0. \quad (2)$$

式(2)中观测已知,故在联合分布中可将其视为参数, t_i 时刻 \mathbf{P}_i 仅与状态有关,则式(2)可简化为

$$p(\mathbf{X}_k | \mathbf{Z}_k) \propto p(\mathbf{X}_0) \prod_{(i,j) \in F_k} p[\mathbf{I}_{(i,j)} | \mathbf{x}_i, \mathbf{x}_j] \prod_{i \in F_k} p(\mathbf{P}_i | \mathbf{x}_i)_0. \quad (3)$$

由式(3)可推得各因子的最大后验概率为

$$\begin{cases} \tilde{\boldsymbol{\omega}}_{(B)}(t_i) = \boldsymbol{\omega}_{(B)}(t_i) + \mathbf{b}_g(t_i) + \boldsymbol{\zeta}_g \\ \tilde{\mathbf{a}}_{(B)}(t_i) = \mathbf{R}_{WB}^T(t_i) [\mathbf{a}_{(W)}(t_i) - \mathbf{g}_{(W)}] + \mathbf{b}_a(t_i) + \boldsymbol{\zeta}_a \end{cases}, \quad (5)$$

式中: $\mathbf{R}_{WB}^T \in \text{SO}(3)$ 为从 W 到 B 的旋转矩阵; $\mathbf{b}_g(t_i)$ 和 $\mathbf{b}_a(t_i)$ 分别为陀螺仪与加速度计随时间缓慢变化的 bias; $\boldsymbol{\zeta}_g$ 和 $\boldsymbol{\zeta}_a$ 分别为陀螺仪与加速度计的观测噪声; $\mathbf{g}_{(W)}$ 为指向固定且模型恒定的重力矢量。结合 IMU 运动学模型,在采样间隔 Δt 内对 $\boldsymbol{\omega}_{(B)}(t_i)$ 和 $\mathbf{a}_{(W)}(t_i)$ 进行离散化积分以构建图优化模型,但由于 IMU 频率高,利用式(5)进行计算会造成计算资源的大量浪费,因此采用 IMU 预积分方法,将高频输出的观测(加速度和角速度)转化为状态量间的位姿变换,从而得到位姿间的约束因子。

假设在积分区间内陀螺仪和加速度计的 bias 恒定的情况下,预积分的理想观测模型可得。然而,在实际图优化中,对状态变量进行更新,如果 IMU 的 bias 发生变化,需要重新计算预积分,这会导致累积误差过大的问题。本文采用融合二维码更新 bias,以提高鲁棒性。

当 AGV 在二维码间隔之间运行时,通过线性修正来调整预积分分量,即假设观测随 bias 线性变化,当 bias 变化时,保留预积分项的一阶项,实现近似更新。Bias 的变化规则为: $\tilde{\mathbf{b}}_{i(c)} + \delta \mathbf{b}_{i(c)} \rightarrow \hat{\mathbf{b}}_{i(c)}$, 其中 $\hat{\mathbf{b}}_{i(c)}$ 为

新 bias, $\bar{\mathbf{b}}_{i(s)}$ 为旧 bias, $\delta\mathbf{b}_{i(s)}$ 为更新量。预积分关于 bias 变化的一阶近似更新公式如下:

$$\begin{cases} \Delta\bar{\mathbf{R}}_{ij}(\hat{\mathbf{b}}_{ig}, \hat{\mathbf{b}}_{ia}) \approx \Delta\bar{\mathbf{R}}_{ij}(\bar{\mathbf{b}}_{ig}, \bar{\mathbf{b}}_{ia}) \exp\left(\frac{\partial\Delta\bar{\mathbf{R}}_{ij}}{\partial\bar{\mathbf{b}}_g} \delta\mathbf{b}_{ig}\right) \\ \Delta\bar{\mathbf{v}}_{ij}(\hat{\mathbf{b}}_{ig}, \hat{\mathbf{b}}_{ia}) \approx \Delta\bar{\mathbf{v}}_{ij}(\bar{\mathbf{b}}_{ig}, \bar{\mathbf{b}}_{ia}) + \frac{\partial\Delta\bar{\mathbf{v}}_{ij}}{\partial\bar{\mathbf{b}}_g} \delta\mathbf{b}_{ig} + \frac{\partial\Delta\bar{\mathbf{v}}_{ij}}{\partial\bar{\mathbf{b}}_a} \delta\mathbf{b}_{ia} \\ \Delta\bar{\lambda}_{ij}(\hat{\mathbf{b}}_{ig}, \hat{\mathbf{b}}_{ia}) \approx \Delta\bar{\lambda}_{ij}(\bar{\mathbf{b}}_{ig}, \bar{\mathbf{b}}_{ia}) + \frac{\partial\Delta\bar{\lambda}_{ij}}{\partial\bar{\mathbf{b}}_g} \delta\mathbf{b}_{ig} + \frac{\partial\Delta\bar{\lambda}_{ij}}{\partial\bar{\mathbf{b}}_a} \delta\mathbf{b}_{ia} \end{cases} \quad (6)$$

通过 $\Delta\mathbf{R}_{ij}$ 、 $\Delta\mathbf{v}_{ij}$ 、 $\Delta\lambda_{ij}$ 与式(6)即可得到式(4)中的残差项, 即 $\mathbf{r}_{l(i,j)} = [\mathbf{r}_{\Delta\mathbf{R}_{ij}}^T, \mathbf{r}_{\Delta\mathbf{v}_{ij}}^T, \mathbf{r}_{\Delta\lambda_{ij}}^T]^T$ 。当检测到二维码时, 解算二维码坐标得到其水平偏移量和偏转角 $\{\Delta x, \Delta y, \Delta\varphi\}$, 更新 AGV 当前位姿, 同时更新 bias。此处 bias 变化规则不同于二维码间的变化规则, 即对当前二维码之前的旧零偏进行优化, 基于新的 bias 值, 首先对 IMU 的原始测量数据进行了重新校正, 以获得更准确的加速度和角速度, 然后重新计算了两关键帧间

$$\mathbf{r}_{iq} = [\mathbf{d}_{iq} - (\mathbf{T}_{LB} \mathbf{T}_i^{-1} \oplus \mathbf{x}_q)] + [\mathbf{u}_{iq} - \prod(\mathbf{T}_{DB} \mathbf{T}_i^{-1} \oplus \mathbf{x}_q)] + \beta \|\text{SE}(3)_i - \text{SE}(3)_{DM}\|, \quad (8)$$

式中: \mathbf{u}_{iq} 为由下视角传感器所得图像 i 处点 q 的观测值; $\mathbf{T}_{DB} \in \text{SE}(3)$ 为载体坐标系到下视角传感器坐标系的刚体转换矩阵; $\prod(\mathbf{T}_{DB} \mathbf{T}_i^{-1} \oplus \mathbf{x}_q)$ 为下视角传感器的投影模型; $\beta \|\text{SE}(3)_i - \text{SE}(3)_{DM}\|$ 为 IMU 预积分与下视角传感器之间的正则化约束; $\mathbf{u}_{iq} - \prod(\mathbf{T}_{DB} \mathbf{T}_i^{-1} \oplus \mathbf{x}_q)$ 为下视角传感器误差, 即式(4)中残差项 $\mathbf{r}_{D(i,q)} = \mathbf{u}_{iq} - \prod(\mathbf{T}_{DB} \mathbf{T}_i^{-1} \oplus \mathbf{x}_q)$ 。

本文中选择关键帧作为待优化的状态量, 并结合惯性项与上述 3D 点云位置的重投影误差项, 激光惯性二维码 SLAM 问题可被视作基于关键帧的最小化问题。给定一组 l 个 3D 点及其状态值为 $\mathcal{P} = \{\mathbf{p}_0, \mathbf{p}_1, \dots, \mathbf{p}_{l-1}\}$ 。

激光惯性二维码联合估计 AGV 位姿的优化问题可以表述为

$$\min_{\mathbf{X}, \mathcal{P}} \left[\sum_{(i,j) \in F_i} \|\mathbf{r}_{l(i,j)}\|_{\Sigma_{l(i,j)}}^2 + \sum_{q=0}^{l-1} \sum_{i \in F_q} \text{Hub}\left(\|\mathbf{r}_{iq}\|_{\Sigma_q}\right) \right], \quad (9)$$

式中: F_q 为观测到 3D 点 q 的一组关键帧; Hub 是一个鲁棒和函数。

3.2.3 激光点云数据处理

首先利用文献[26]中的运动估计模型来对点云进行畸变校正, 然后进行特征提取, 步骤如下:

1) 采用自适应比例系数为 α 的自适应阈值 $\epsilon^{(h)} = \alpha \mathbf{d}_i^{(h)} \epsilon_0^{(h)}(\mathbf{d}_i^{(h)})$ 为在 h 次迭代中第 i 次距离的最优值估计, $\epsilon_0^{(h)}$ 为距离误差的更新值) 对点云数据进行目标分割处理, 当激光光束 OM 与两激光点连线 MN 之间的夹角小于自适应阈值时, 判定两激光点不在同一目

的预积分值, 同时优化预积分计算值与测量值之间的残差, 即惯性残差, 更新后的惯性残差作为优化问题的一部分, 重新进行 SLAM 系统的优化。需要说明的是, 由于通过下视角摄像头捕捉的二维码信息估计 AGV 位姿更加准确, 因此此处预积分计算值为通过二维码获得的位姿信息计算部分导航状态, 并通过导航状态来求取两关键帧间预积分的计算值。

考虑惯性残差的同时, 本文还定义了在第 i 帧和位置 \mathbf{x}_q 的 3D 点 q 之间的重投影误差, 与上文中 bias 分析一样, 该误差分为码间(无二维码)和扫描到二维码时两种情况, 二维码间的重投影误差为

$$\mathbf{r}_{iq} = \mathbf{d}_{iq} - (\mathbf{T}_{LB} \mathbf{T}_i^{-1} \oplus \mathbf{x}_q), \quad (7)$$

式中: \mathbf{d}_{iq} 为激光雷达产生第 i 帧点云处点 q 的观测值; $\mathbf{T}_{LB} \in \text{SE}(3)$ 为载体坐标系到雷达坐标系的刚体转换矩阵; \mathbf{T}_i 为载体姿态; \oplus 为 $\text{SE}(3)$ 群到 3D 空间的变换运算。

当扫描到二维码时, 在激光重投影误差的基础上增加了下视角传感器对于二维码的误差分析模型:

标上。

2) 根据粗糙度 θ 选取面点与角点作为特征点, 如图 2 所示, 粗糙度 θ 由当前点 i 及其附近点集合 S 的深度值决定, 即

$$\theta = \frac{1}{|S| \cdot \|\mathbf{d}_i\|} \left\| \sum_{j \in S, j \neq i} (\mathbf{d}_i - \mathbf{d}_j) \right\|, \quad (10)$$

式中: \mathbf{d}_i 为第 i 次距离的最优值估计。

本文实验中通过逐渐调整阈值得到最终阈值, 粗糙度值 $\theta > 0.2$ 时记为边缘点 \mathcal{P}_E , 粗糙度值 $\theta < 0.2$ 时记为平面点 \mathcal{P}_F 。

3.3 激光里程计

针对激光里程计恒速跟踪模型在运动状态发生突变时导致跟踪效率低的问题, 本文提出帧到关键帧局部地图跟踪模型。利用帧到其附近关键帧局部地图匹配, 估计 AGV 当前姿态。假设当前帧为第 i 帧, 由当前帧提取的边缘点 $\mathcal{P}_E^{(i)}$ 与平面点 $\mathcal{P}_F^{(i)}$ 构成激光雷达帧 $F^{(i)} = \{\mathcal{P}_E^{(i)}, \mathcal{P}_F^{(i)}\}$ 的特征集合。关键帧局部地图为稀疏局部地图, 此稀疏局部地图由从当前帧 $F^{(i)}$ 附近的关键帧集合 $\mathcal{K}_S^{(i)}$ 中提取的特征构成, 即假设 $F^{(i)}$ 最近的关键帧为 F_c , 将 $\mathcal{K}_S^{(i)}$ 中关键帧的边缘与平面特征转换到 F_c 坐标系下, 构建稀疏局部地图 $M_c = \{M_c^{(E)}, M_c^{(F)}\}$, $M_c^{(E)}$ 和 $M_c^{(F)}$ 分别为局部地图中的边缘点和平面点。

具体跟踪模型为: 对于任意边缘特征点 $p_{i,k}^{(E)} \in \mathcal{P}_E^{(i)}$, 利用近邻搜索算法在由 $M_c^{(E)}$ 构建的 KD 树中搜索其最近两个匹配点为 $p_{c,a}^{(E)} \in M_c^{(E)}$ 和 $p_{c,b}^{(E)} \in M_c^{(E)}$, 得到 $p_{i,k}^{(E)}$ 到直线 $p_{c,a}^{(E)} p_{c,b}^{(E)}$ 的距离为

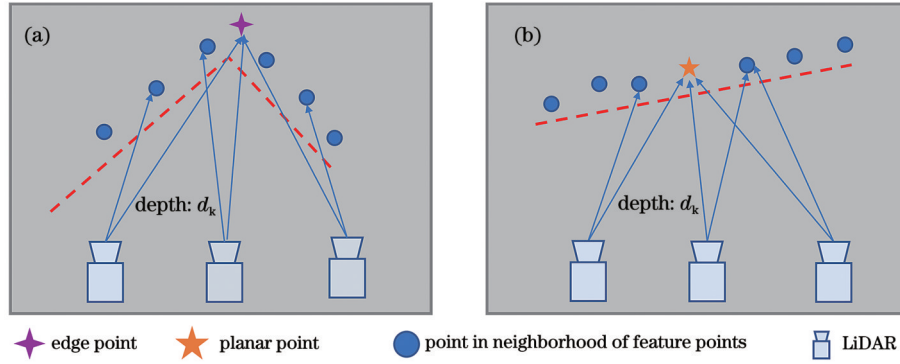


图 2 角点及其邻点和平面点及其邻点构成的点集。(a)角点及其邻点;(b)平面点及其邻点

Fig. 2 Set of points formed by a corner point and its neighbors and set of points formed by a plane point and its neighbors. (a) Corner point and its neighbors; (b) plane point and its neighbors

$$d_k^{(E)} = \frac{\left| [T_{C_i} p_{i,k}^{(E)} - p_{C,a}^{(E)}] [T_{C_i} p_{i,k}^{(E)} - p_{C,b}^{(E)}] \right|}{p_{C,a}^{(E)} - p_{C,b}^{(E)}}, \quad (11)$$

式中: T_{C_i} 为当前帧位姿。

类似地,对于任意平面特征点 $p_{i,k}^{(F)} \in \mathcal{P}_F^{(i)}$, 搜索其最近的一个点 $p_{C,a}^{(F)} \in M_C^{(F)}$, 以及其相邻线上的两个最近点 $p_{C,b}^{(F)} \in M_C^{(F)}$ 和 $p_{C,c}^{(F)} \in M_C^{(F)}$, 得到 $p_{i,k}^{(F)}$ 到平面 $\{p_{C,a}^{(F)}, p_{C,b}^{(F)}, p_{C,c}^{(F)}\}$ 的距离为

$$d_k^{(F)} = \frac{\left| [T_{C_i} p_{i,k}^{(F)} - p_{C,a}^{(F)}] \left\{ [p_{C,a}^{(F)} - p_{C,b}^{(F)}] [p_{C,a}^{(F)} - p_{C,c}^{(F)}] \right\} \right|}{\left| [p_{C,a}^{(F)} - p_{C,b}^{(F)}] [p_{C,a}^{(F)} - p_{C,c}^{(F)}] \right|}. \quad (12)$$

根据式(11)、(12), 并通过对以下优化问题进行求解, 得到当前帧位姿 T_{C_i} 为

$$T_{C_i} = \arg \min_{T_{C_i}} \left(\sum_{p_{i,k}^{(E)} \in \mathcal{P}_E^{(i)}} d_k^{(E)} + \sum_{p_{i,k}^{(F)} \in \mathcal{P}_F^{(i)}} d_k^{(F)} \right). \quad (13)$$

为得到更快的收敛速度, 本文通过 Levenberg-

Marquardt (LM) 算法进行优化问题的求解, 在每次迭代中使用雅可比矩阵构建近似 Hessian 矩阵, 并通过引入调整参数来稳定更新步骤, 直到达到预定的收敛条件, 从而找到使目标函数达到最小值的参数估计。

经测试验证, 在保证配准精度的情况下, 每帧匹配到相应特征点的时间复杂度有效降低, 匹配迭代收敛速度得到提升, 计算速度提升 30%。

3.4 地图构建

LOAM 或 LeGO-LOAM 的增量式建图过程会不可避免地出现配准错误问题。文献[24]提出的 BALM 算法被证明是减小累积误差的有效方式, 然而该算法具有计算量过大的问题。本文创新性地引入二维码, 以简化局部 BA 过程, 缩短优化时间, 结合姿态图优化时间效率高的性质, 提出融合二维码的分层局部 BA 优化, 以大幅缩短优化时间。具体的优化过程为从底层到顶层的分层 BA 优化和从顶层到底层的姿态图优化, 其结构示意图如图 3 所示, 过程如下:

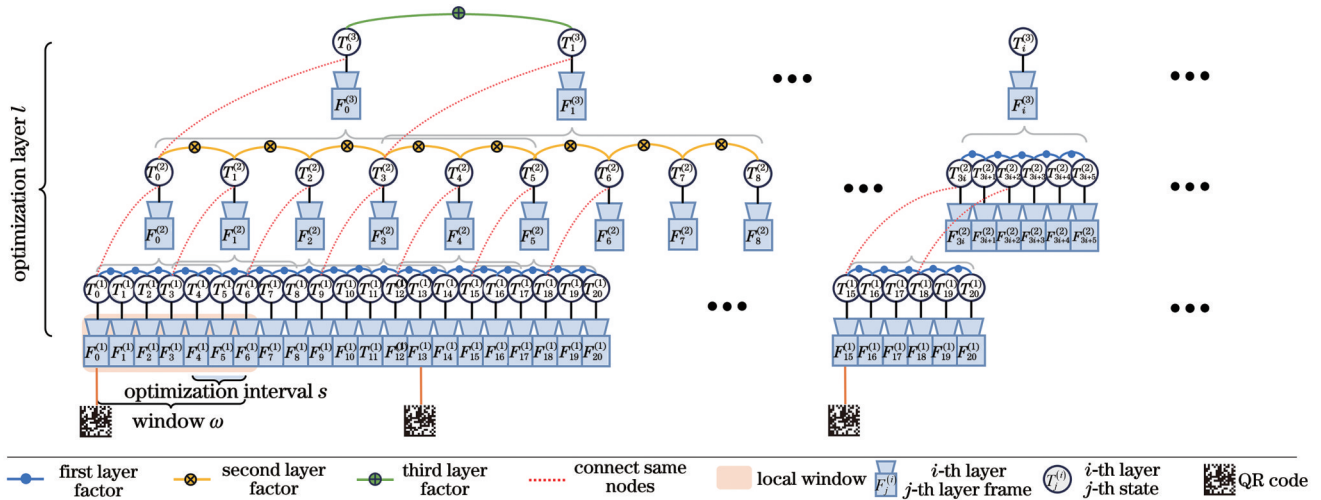


图 3 融合二维码的分层 BA 优化示意图

Fig. 3 Schematic diagram of hierarchical BA with QR code fusion

1) 底层到顶层的优化。设第 i 层第 j 个激光雷达帧 $\mathcal{F}_j^{(i)}$ 的状态为 $T_j^{(i)} = (R_j^{(i)}, t_j^{(i)})$, $T_j^{(i)}$ 与 $T_k^{(i)}$ 之间的相对位姿由 $T_{j,k}^{(i)} = [T_j^{(i)}]^{-1} T_k^{(i)}$ 表示, 构建局部 BA 窗口大小为 ω , 扫描二维码数为 q , 同一层两个相邻窗口的起点间隔为 s , 第 i 层雷达帧总数为 N_i 。

在底层到顶层的优化过程中, 根据里程计得到的初始姿态轨迹进行局部 BA, 由于下视角扫描二维码得到的 AGV 位姿比激光惯性测量估计的位姿精度更高, 因此当扫描到二维码时标记特定关键帧 $\mathcal{F}_{j^*}^{(i)}$, 该关键帧所在窗口内的所有帧不参与优化进程, 并直接为上一层构造关键帧。任一局部窗口中包含 ω 帧 $\left\{ \mathcal{F}_{s_j+k}^{(i)} \mid j=0, 1, \dots, \left[\frac{N_i - \omega - q}{s} \right]; k=0, 1, \dots, \omega - q - 1 \right\}$ ($[\cdot]$ 代表取整运算), 在窗口内优化第一帧与其他帧的相对位姿 $\{T_{s_j, s_j+k}^{(i)}\}$, 并通过固定第一帧和特定关键帧位姿来解决量规自由度问题。通过局部 BA 构造 Hessian 矩阵 \mathbf{H} , 作为后续姿态图优化的信息矩阵, 同时求解最优相对位姿 $\{T_{s_j, s_j+k}^{*(i)}\}$ 为上一层构造关键帧 $\mathcal{F}_j^{(i+1)}$, 新关键帧姿态由之前所有局部窗口的最优相对位姿相乘所得, 记为

$$T_j^{(i+1)} = T_{s_j}^{*(i)} = \prod_{k=1}^j T_{s_k - s, s_k}^{*(i)} \quad (14)$$

通过反复执行该过程得到最优层数。为了加速 Hessian 矩阵求解过程, 本文算法仅保留原始 Hessian 矩阵中的块对角元素, 并在解决这个简化的矩阵时考虑不同局部窗口之间的相对姿态约束。

第一层激光雷达帧的个数即为雷达帧总数 N , 即 $N_1 = N$, 当从下一层的一窗口内 ω 帧聚合成一帧到上一层时, 并行处理线程为 n 。由于 BA 的计算时间为 $O(M^3)$, 其中 M 为位姿数, 因此可以得到 l 层的总优化时间为 $O(T_l)$, 包括每层局部 BA 消耗时间和顶层全局 BA 消耗的时间, 表示为

$$T_l = \begin{cases} (N - q\omega)^3, & l = 1 \\ \frac{\omega^3}{n} \sum_{i=1}^{l-1} \frac{N - q\omega}{s^i} + \left(\frac{N - q\omega}{s^{l-1}} \right)^3, & l > 1, i < l \end{cases} \quad (15)$$

式中: $\frac{N - q\omega}{s^i}$ 为局部窗口数, 每个局部窗口的消耗时间为 $O(\omega^3)$; $\frac{\omega^3}{n} \sum_{i=1}^{l-1} \frac{N - q\omega}{s^i}$ 为局部 BA 消耗时间的总和; $\left(\frac{N - q\omega}{s^{l-1}} \right)^3$ 为顶层全局 BA 消耗时间。

由式(15)可知, T_l 为 l 的函数, 可以通过对式(15)求导并且令导数为零得到最优解 l^* , 记为

$$l^* = \left\lceil \frac{1}{2} \log_s \left[\frac{3(N - q\omega)^2 (s^3 - s)n}{\omega^3} \right] \right\rceil \quad (16)$$

经测试验证, 层数为 l^* 时的计算时间比层数为 1 时的计算时间大大减少, 这验证了分层 BA 的有效性。分层 BA 参数设置如表 1 所示。

表 1 分层 BA 参数设置

Table 1 Hierarchical BA parameter settings

Parameter	Description	Setting
ω	Window size	12
s	Stride	6
n	Parallel thread	8

2) 顶层到底层的姿态图优化。该优化过程的主要目的在于减小自底层到顶层优化过程中的姿态估计误差, 且该过程只考虑同一窗口下的共同特征, 从顶层到底层的每一层中, 因子为相邻两帧的姿态变化。由于二维码推断出的姿势具有更高的置信度, 因此将对应的特定关键帧位姿固定, 由图 3 与式(14)可知, $T_j^{(i+1)}$ 与 $T_{s_j}^{(i)}$ 两节点本质上是相同的, 即 $T_j^{(i)} = T_{s_j}^{(i-1)} = \dots = T_{s^{i-1}j}^{(1)}, \forall i \in \mathcal{L}, j \in \mathcal{E}^{(i)}$, 其中 $\mathcal{L} = \{1, 2, \dots, l\}$ 为层数的集合, $\mathcal{E}^{(i)} = \{0, 1, \dots, N_i - 1\}$ 为每层帧数的集合, 因此, 目标函数的最小化函数为

$$f(F, T) = \sum_{i \in \mathcal{L}} \sum_{j \in \mathcal{E}^{(i)}} c \left[T_{s^{i-1}j}^{(1)}, T_{s^{i-1}(j+1)}^{(1)} \right], \quad (17)$$

式中: F 为第一层所有帧的集合; T 为第一层所有姿态的集合; c 为权重系数。式(17)的代价函数是通过将顶层到底层 BA 优化过程中 Hessian 矩阵进行加权所得。

3.5 回环检测

在仓储物流车间中, AGV 通常是在预定轨道上定期循环运行, 因此可以定期进行回环检测以纠正累积漂移问题。本文采取大小回环结合的方式进行回环检测。大回环表示 AGV 回到之前的位置, 由于二维码的唯一性, 当扫描到相同二维码时, 得到二维码 ID d_i , 即可认定为检测到大回环, 修正全局累积误差; 小回环表示当前关键帧与历史关键帧之间的共视关系, 采用与视觉回环相似的方法, 利用 BoW3D^[27] 词袋模型检测回环, 以为 AVG 提供转角约束, 提升激光里程计对激光雷达旋转运动的稳定性。当检测到回环时, 利用 NDT 算法将当前时刻的特征点云与回环处的特征点云进行点云配准, 得到位姿转换关系 T^* , 生成回环因子。

3.6 因子图优化

因子图优化即将各部分产生的因子实时插入到全局因子图中, 分别对二维码因子、跟踪因子、预积分因子和回环因子进行泰勒展开, 构建全局雅可比矩阵, 利用 LM 迭代算法求解稀疏线性系统, 不断更新变量估

计,逐步调整这些变量以最小化整个系统的误差。每次迭代中,算法评估并更新变量的估计值,直至满足收敛条件,从而找到一组最优的变量值。因子图结构示意图如图 4 所示,由第 3.1 节可知当给定初始状态 \mathbf{X}_0 , 对应式(4)中的 $\|\mathbf{r}_0\|_{\Sigma_0}^2$ 项。当检测到二维码时,向因子图中插入二维码因子,对应式(4)中 $\|\mathbf{r}_{D(i,q)}\|_{\Sigma_{D(i,q)}}^2$ 项。地图构建模块向因子图中插入跟踪因子,对应式(4)中 $\|\mathbf{r}_{M_i}\|_{\Sigma_{M_i}}^2$, 其中, $\mathbf{r}_{M_i} = (\mathbf{x}_i \odot \mathbf{m}_{i-1}) \odot \mathbf{T}_{(i,i-1)}^*$, \mathbf{m}_{i-1} 为局部

地图点, \odot 表示位姿变换的逆运算。通过计算相邻关键帧之间的预积分得到预积分因子,对应式(4)中的 $\|\mathbf{r}_{I(i,j)}\|_{\Sigma_{I(i,j)}}^2$, 其中, $\mathbf{r}_{I(i,j)} = (\mathbf{x}_i \odot \mathbf{x}_j) \odot \int \mathbf{I}_{(i,j)} dt$ 。当检测到回环时,回环检测模块向因子图插入回环因子,对应式(4)中的 $\|\mathbf{r}_{L(i,j)}\|_{\Sigma_{L(i,j)}}^2$, 其中, $\mathbf{r}_{L(i,j)} = (\mathbf{x}_i \odot \mathbf{x}_j) \odot \mathbf{T}_{(i,j)}^*$, 因子图的优化计算随着新的因子的插入而实时更新,从而更新当前时刻的位姿估计,实现激光惯性二维码的深度融合。

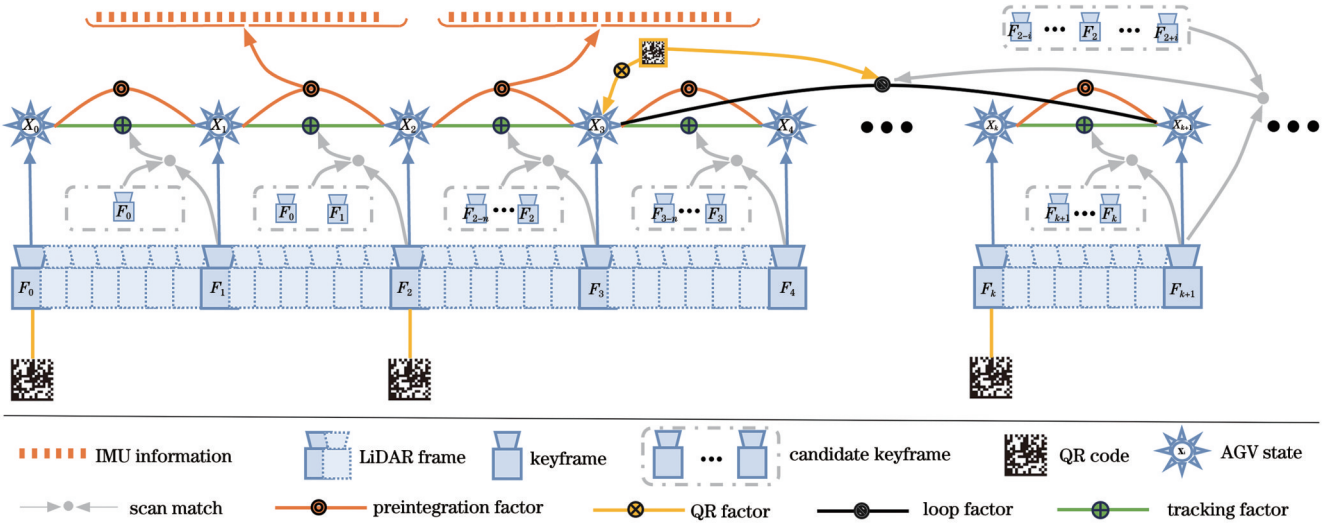


图 4 因子图结构示意图

Fig. 4 Factor graph structure diagram

4 实验与分析

4.1 实验平台与设备

在本文实验中,模拟仓储车间场景布局搭建

硬件平台,对本文提出的算法进行了验证评估。实验平台如图 5 所示,通过在地面上规律性地布置二维码,按照 1.2 m 的间隔将二维码粘贴在地面。

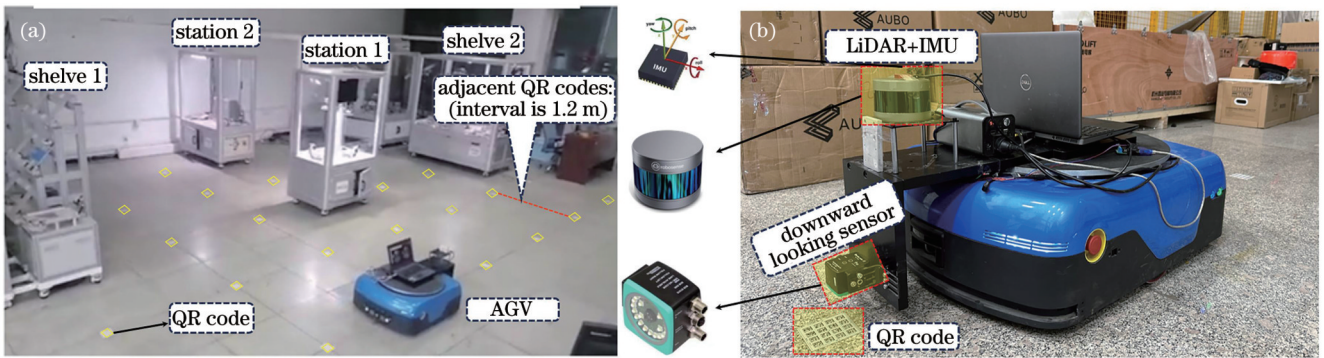


图 5 模拟仓储车间场景布局及实验硬件平台。(a)模拟仓储车间场景;(b)实验硬件平台

Fig. 5 Simulated warehouse workshop scene layout and experimental hardware platform. (a) Simulation of warehouse workshop scene; (b) experimental hardware platform

将激光雷达 (RS-LiDAR-16, 10 Hz) 与 IMU (Bosch BMI055, 100 Hz) 以刚性结构安装在 AGV 的前端,将下视角传感器 (倍加福 PGV100, 图像分辨率 640×480 , 采样率 20 Hz) 安装在距地面 100 mm 的高

度以扫描 AGV 运行路径上的地面二维码。

4.2 定位精度分析

直线与转弯为仓储物流车间中 AGV 最具代表性的运行轨迹类型,因此本文提出两种 AGV 运行轨迹,

即直线形和矩形,并利用 EVO 评估工具处理位姿估计数据,对轨迹准确性进行系统评估。本文将所提框架与几种主流开源算法 LeGO-LOAM^[14]、BALM^[24]、LIO-SAM^[18]和 LIC-Fusion2^[28]进行比较,在预定的轨迹上进行实时运行。

本实验的真实轨迹由精度为毫米级的 Leica TS60 激光跟踪仪获得。具体实验及结果分析如下:

1) 直线形轨迹。控制 AGV 以 0.5 m/s 的速度在学校长廊上运行,模拟仓储环境下直线运行情况,测试的轨迹长度分别为 24000 mm、36000 mm、48000 mm、60000 mm,针对每组轨迹分别进行了 100 次实验,本文提出的 SLAM 算法定位与建图效果如图 6(a)所

示。恢复出不同算法的轨迹如图 6(b)所示,得益于二维码的周期性位姿补偿,本文方法估计得到的轨迹与真实运行轨迹之间的偏差最小。由于缺少绝对测量数据,LeGO-LOAM^[14]算法结果相对于真实轨迹产生较大程度的偏移,同时由于累积误差的存在,并且室内长廊里 GPS 信号差,BALM^[24]和 LIO-SAM^[18]算法结果与真实轨迹仍有不同程度的偏差,虽然 BALM^[24]通过 BA 优化进行全局一致性的优化,但由于其缺少周期性修正,其运行过程也产生不可忽视的偏差。由于长廊中光照条件的变化,LIC-Fusion2^[28]算法结果依然与真实轨迹有较大的偏差。

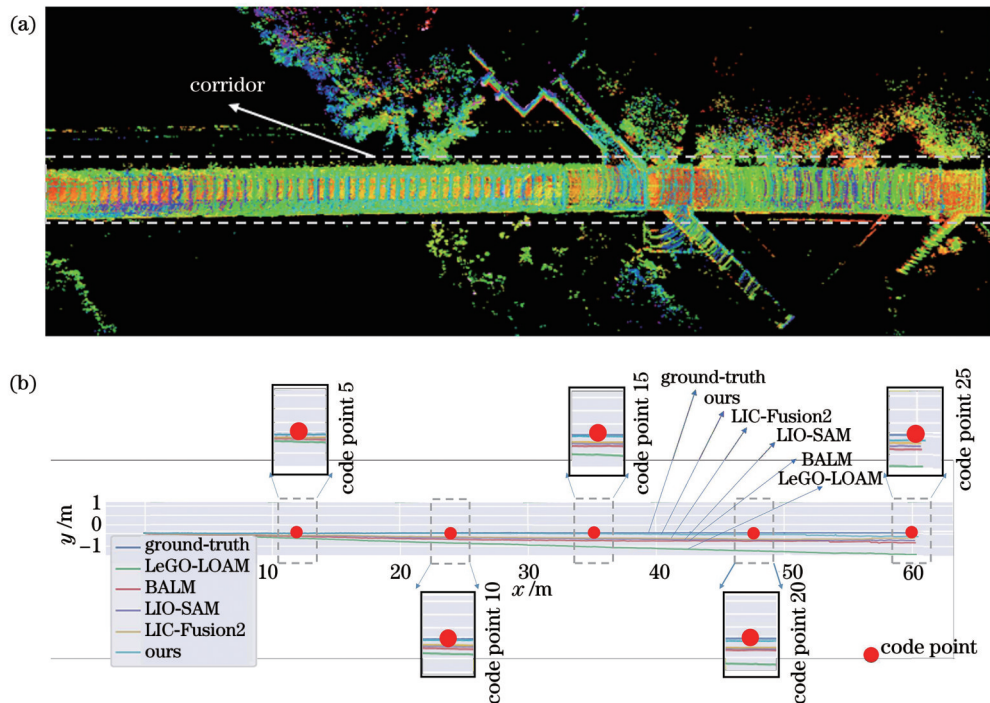


图 6 直线轨迹的实验效果图及不同 SLAM 方法对比。(a) 直线实验效果图;(b) 不同 SLAM 方法的直线轨迹对比

Fig. 6 Experimental result of line trajectory and comparison of different SLAM methods. (a) Linear experiment effect; (b) comparison of line trajectories of different SLAM methods

本文基于 AGV 的固定运行速度,定义长期(大于 24000 mm)与短期(小于等于 24000 mm)两种运行状态为基于运行距离的长度,并分别以两种运行状态进行实验分析,当 AGV 短期运行时,本文方法的绝对平移误差小于 15 mm,绝对旋转误差仅为 1.12°。相比之下,LeGO-LOAM^[14]、BALM^[24]、LIO-SAM^[18]和 LIC-Fusion2^[28]的绝对平移误差远大于本文方法。图 7 是 AGV 长期运行时,不同轨迹长度下,不同激光惯性导航方法的绝对轨迹误差变化情况,本文方法的绝对平移误差小于 20 mm,绝对旋转误差约为 1.6°,LeGO-LOAM^[14]、BALM^[24]、LIO-SAM^[18]和 LIC-Fusion2^[28]的绝对平移误差分别达到 351 mm、310 mm、91 mm 和 70 mm,绝对旋转误差均大于 2.5°,LeGO-LOAM^[14]的绝对旋转误差更是达到了 5°以上,表示该算法已经严

重失准,无法满足高精度位姿估计的仓储 AGV 导航任务需求。不同方法下估计轨迹的绝对轨迹误差如表 2 所示(表中 A_{trans} 为绝对平移误差, A_{rot} 为绝对旋转误差),由于二维码绝对数据的周期性修正,当轨迹从 24000 mm 增加到 60000 mm 时,本文方法的绝对平移误差和绝对旋转误差仅增加了约 2 mm 和 0.5°,这进一步说明本文方法在直线轨迹方面相对于其他经典方法的优势。

2) 矩形轨迹。为验证本文方法在复杂工作情况下依旧具有鲁棒性,使 AGV 沿更具挑战的矩形轨迹运行。AGV 保持 0.5 m/s 的运行速度,并以 45 (°)/s 的旋转角速度在指定的二维码处转弯,同样以短期运行(小于等于 16800 mm)和长期运行(大于 168000 mm)两种运行状态进行实验分析。所提方法的实验效果如

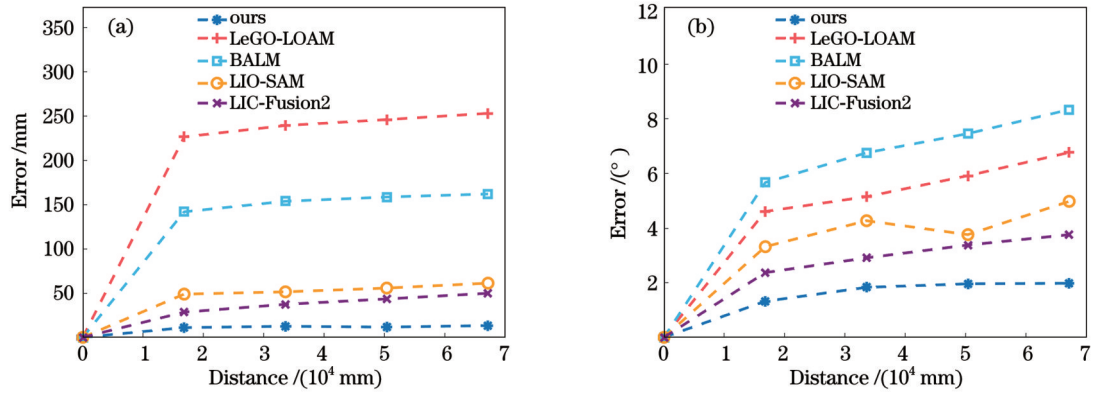


图 7 直线形轨迹长期数据下的绝对轨迹误差分析。(a)直线轨迹绝对平移误差分析;(b)直线轨迹绝对旋转误差分析

Fig. 7 Analysis of absolute trajectory error for long-term data of linear trajectories. (a) Absolute translation error of linear trajectories; (b) absolute rotation error of linear trajectories

表 2 直线形轨迹的绝对轨迹误差对比

Table 2 Comparison of absolute trajectory error for line trajectories

Trajectory	Length /mm	Metric	LeGO-LOAM	BALM	LIO-SAM	LIC-Fusion2	Ours
Line	24000	A_{trans}	332.85 mm	295.52 mm	75.56 mm	54.34 mm	14.56 mm
		A_{rot}	3.61°	2.35°	2.12°	1.77°	1.12°
	36000	A_{trans}	343.26 mm	301.72 mm	77.78 mm	58.55 mm	15.95 mm
		A_{rot}	4.15°	2.92°	2.27°	1.85°	1.13°
	48000	A_{trans}	346.65 mm	307.25 mm	86.23 mm	65.78 mm	17.27 mm
		A_{rot}	4.52°	3.17°	2.76°	2.16°	1.35°
	60000	A_{trans}	351.35 mm	309.67 mm	90.74 mm	69.91 mm	18.38 mm
		A_{rot}	5.17°	3.53°	2.98°	2.49°	1.63°

图 8(a)所示,由 EVO 工具恢复出的不同算法的定量估计轨迹如图 8(b)所示。可以看出,LeGO-LOAM^[14]的轨迹漂移明显,且由于激光雷达扫描畸变导致点云数

据中角度信息失真,相机的视场变化导致环境特征的丢失或识别困难,以及 AGV 自身抖动等不良因素,LeGO-LOAM^[14]、BALM^[24]、LIO-SAM^[18]和 LIC-

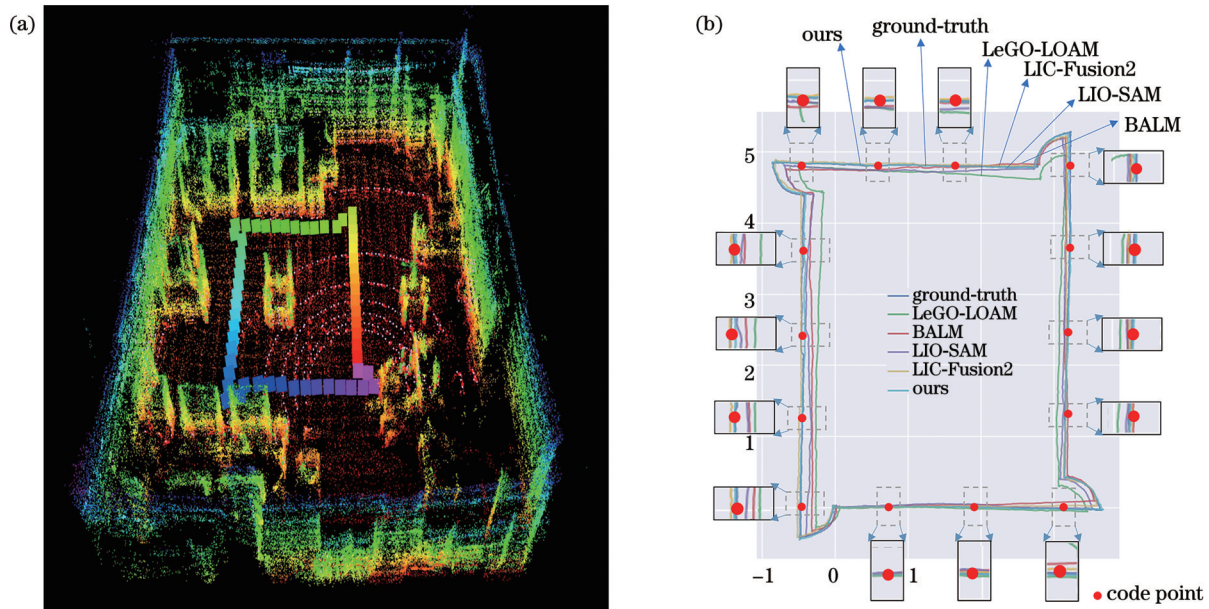


图 8 矩形轨迹的实验效果图及不同 SLAM 方法对比。(a)矩形实验效果图;(b)不同 SLAM 方法的矩形轨迹对比

Fig. 8 Experimental results of rectangle trajectory and comparison of different SLAM methods. (a) Rectangular experiment effect; (b) comparison of rectangle trajectories of different SLAM methods

Fusion2^[28]在转弯处的旋转角度分别与真实轨迹产生明显差异。本文方法在有二维码数据校正的情况下,通过向因子图中添加闭环因子来消除漂移,因此大大减小了全局轨迹误差,所得轨迹与真实轨迹偏差最小。

值得注意的是,轨迹图中出现的约 90°的转弯弧,是由传感器安装在 AGV 车头处,车体转弯时形成的真实转弯弧所致。矩形轨迹运行下,不同方法的绝对轨迹误差结果如表 3 所示。

表 3 矩形轨迹的绝对轨迹误差对比
Table 3 Comparison of absolute trajectory error for rectangle trajectories

Trajectory	Length /mm	Metric	LeGO-LOAM	BALM	LIO-SAM	LIC-Fusion2	Ours
Rectangle	16800	A_{trans}	226.36 mm	141.73 mm	48.77 mm	28.41 mm	10.96 mm
		A_{rot}	4.61°	5.67°	3.32°	2.37°	1.32°
	33600	A_{trans}	239.22 mm	153.65 mm	51.34 mm	37.26 mm	12.47 mm
		A_{rot}	5.15°	6.76°	4.27°	2.91°	1.83°
	50400	A_{trans}	245.89 mm	158.42 mm	55.62 mm	43.35 mm	11.52 mm
		A_{rot}	5.92°	7.46°	3.76°	3.38°	1.96°
	67200	A_{trans}	252.94 mm	161.86 mm	61.15 mm	49.74 mm	13.27 mm
		A_{rot}	6.77°	8.34°	4.98°	3.76°	1.98°

图 9 直观表示不同轨迹长度下,不同激光惯性导航方法的绝对轨迹误差变化情况。矩形轨迹的误差相比直线轨迹的误差有所减小,这是由于直线的测试距离更远并且 LeGO-LOAM^[14]、LIO-SAM^[18]和 LIC-Fusion2^[28]中使用了简单的基于轨迹位姿的回环检

测。然而,不论短期运行还是长期运行,LeGO-LOAM^[14]、BALM^[24]、LIO-SAM^[18]和 LIC-Fusion2^[28]循环中依旧有明显的累积误差,得益于绝对校正数据,本文方法保持较小的绝对平移误差与绝对旋转误差。

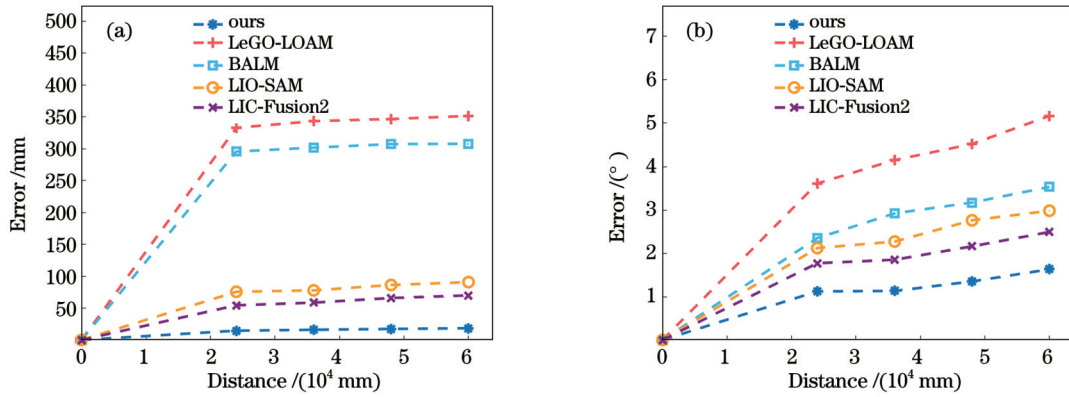


图 9 矩形轨迹长期数据下的绝对轨迹误差分析。(a)矩形轨迹绝对平移误差分析;(b)矩形轨迹绝对旋转误差分析
Fig. 9 Analysis of absolute trajectory error for long-term data of rectangle trajectories. (a) Absolute translation error of rectangular trajectories; (b) absolute rotation error of rectangular trajectories

4.3 运行效率对比

本文在激光惯性导航方法的基础上融入了二维码信息,采用非线性优化方式对 AGV 位姿信息进行优化,不可避免地会导致计算成本增加。为评估系统数

据处理的速度和效率,分别对本文算法、LeGO-LOAM^[14]、BALM^[24]、LIO-SAM^[18]和 LIC-Fusion2^[28]不同线程的运行时间进行对比。

如表 4 所示,在仓储物流车间实验环境下,本文算

表 4 各线程时间效率对比
Table 4 Comparison of time efficiency of threads

Thread	LeGO-LOAM	BALM	LIO-SAM	LIC-Fusion2	Ours
Date preprocessing	52.43	46.38	58.12	58.34	65.68
Laser odometry	40.12	31.22	28.36	27.17	25.64
Optimized mapping	653.34	627.35	234.86	462.15	140.14
Loop detection	368.32	—	382.95	351.49	332.31
System operation	1114.21	704.95	704.29	899.15	563.77

法的时间效率相对于 LeGO-LOAM^[14]、BALM^[24]、LIO-SAM^[18]和 LIC-Fusion2^[28]的时间效率总体上分别提高了 49.40%、20.03%、19.95% 和 37.29%。由于 LeGO-LOAM^[14]和 BALM^[24]并不需要处理下视角二维码信息,且由于 BALM^[24]没有回环,所以系统前期处理阶段和回环检测阶段的时间效率要高于本文算法。但由于本文采用分层 BA 优化模型,同时优化时考虑了置信度更高的二维码位姿信息,这使得本文方法后端需要进一步优化的参数量大大减少,进而使得建图效率得到显著提高。

5 结 论

针对仓储物流车间,基于激光惯性融合的导航方法存在惯性偏差漂移、实时性差、在退化场景下位姿估计精度低等问题,本文提出了一种精确的激光惯性二维码融合的导航方法,用于仓储物流环境下 AGV 自主精确导航。通过融合二维码的 IMU 预积分模型和全局一致性优化,成功估计和校正了惯性偏差,减少了优化时间。同时,采用激光雷达/IMU/二维码紧耦合优化,实现多层次的数据融合,大幅提高了定位精度与鲁棒性。实验结果表明,本文算法具有较高的时间效率以及较小的位姿误差。无论运行轨迹长度如何,平移和旋转误差分别小于 0.02 m 和 2°。

未来的研究一方面考虑融合视觉传感器实现更深层次的多传感器融合以提高导航精度,包括使用高精度相机捕获特征点,并通过视觉 SLAM 技术与激光和 IMU 数据进行协同优化,从而增强系统在光线变化或特征缺失情况下的性能;另一方面考虑在多传感器融合算法中开发一种新的实时自适应标定方法,该方法能够利用传感器的实时数据来连续调整传感器模型参数。这种方法的关键在于使用先进的滤波技术(如卡尔曼滤波器或粒子滤波器)实时估计并修正传感器误差。

参 考 文 献

- [1] Sun P Z H, You J P, Qiu S Q, et al. AGV-based vehicle transportation in automated container terminals: a survey[J]. IEEE Transactions on Intelligent Transportation Systems, 2023, 24(1): 341-356.
- [2] Xuan Y W, Zhang H, Yan F J, et al. Gaze control for active visual SLAM via panoramic cost map[J]. IEEE Transactions on Intelligent Vehicles, 2023, 8(2): 1813-1825.
- [3] 徐陈,周怡君,罗晨. 动态场景下基于光流和实例分割的视觉 SLAM 方法[J]. 光学学报, 2022, 42(14): 1415002. Xu C, Zhou Y J, Luo C. Visual SLAM method based on optical flow and instance segmentation for dynamic scenes[J]. Acta Optica Sinica, 2022, 42(14): 1415002.
- [4] Zhu Y W, Zheng C R, Yuan C J, et al. CamVox: a low-cost and accurate lidar-assisted visual slam system[C]//2021 IEEE International Conference on Robotics and Automation (ICRA), May 30-June 5, 2021, Xi'an, China. New York: IEEE Press, 2021: 5049-5055.
- [5] 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, 2022, 23(7): 6907-6921.
- [6] 王明军,李乐,易芳,等. 模拟真实水体环境下目标激光点云数据的三维重建与分析[J]. 中国激光, 2022, 49(3): 0309001. Wang M J, Li L, Yi F, et al. Three-dimensional reconstruction and analysis of target laser point cloud data under simulated real water environment[J]. Chinese Journal of Lasers, 2022, 49(3): 0309001.
- [7] 许宇伟,颜文旭,吴炜. 相似场景下基于局部地图的激光 SLAM 前端算法改进[J]. 机器人, 2022, 44(2): 176-185. Xu Y W, Yan W X, Wu W. Improvement of LiDAR SLAM front-end algorithm based on local map in similar scenes[J]. Robot, 2022, 44(2): 176-185.
- [8] Bhattacharjee A, Bhatt C. Human arm motion capture using IMU sensors[M]//Namrata K, Priyadarshi N, Bansal R C, et al. Smart energy and advancement in power technologies. Lecture notes in electrical engineering. Singapore: Springer, 2023, 927: 805-817.
- [9] Yi C Z, Rho S, Wei B C, et al. Detecting and correcting IMU movements during joint angle estimation[J]. IEEE Transactions on Instrumentation and Measurement, 2022, 71: 4004714.
- [10] Liu J X, Gao W, Hu Z Y. Optimization-based visual-inertial SLAM tightly coupled with raw GNSS measurements[C]//2021 IEEE International Conference on Robotics and Automation (ICRA), May 30-June 5, 2021, Xi'an, China. New York: IEEE Press, 2021: 11612-11618.
- [11] Golodetz S, Vankadari M, Everitt A, et al. Real-time hybrid mapping of populated indoor scenes using a low-cost monocular UAV[C]//2022 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS), October 23-27, 2022, Kyoto, Japan. New York: IEEE Press, 2022: 325-332.
- [12] 周维超,黄俊. 激光雷达与相机自适应紧耦合的同时定位与建图算法[J]. 激光与光电子学进展, 2023, 60(20): 2028009. Zhou W C, Huang J. Adaptive tightly coupled lidar-visual simultaneous localization and mapping framework[J]. Laser & Optoelectronics Progress, 2023, 60(20): 2028009.
- [13] Zhang J, Singh S. Low-drift and real-time lidar odometry and mapping[J]. Autonomous Robots, 2017, 41(2): 401-416.
- [14] Shan T X, Englot B. LeGO-LOAM: lightweight and ground-optimized lidar odometry and mapping on variable terrain[C]//2018 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS), October 1-5, 2018, Madrid, Spain. New York: IEEE Press, 2018: 4758-4765.
- [15] Ganesan P, Priyadarshini R, Felix Mathan M, et al. Autonomous guided vehicle for smart warehousing[C]//2022 Algorithms, Computing and Mathematics Conference (ACM), August 29-30, 2022, Chennai, India. New York: IEEE Press, 2022: 42-47.
- [16] Ye H Y, Chen Y Y, Liu M. Tightly coupled 3D lidar inertial odometry and mapping[C]//2019 International Conference on Robotics and Automation (ICRA), May 20-24, 2019, Montreal, QC, Canada. New York: IEEE Press, 2019: 3144-3150.
- [17] Qin C, Ye H Y, Pranata C E, et al. LINS: a lidar-inertial state estimator for robust and efficient navigation[C]//2020 IEEE International Conference on Robotics and Automation (ICRA), May 31-August 31, 2020, Paris, France. New York: IEEE Press, 2020: 8899-8906.
- [18] Shan T X, Englot B, Meyers D, et al. LIO-SAM: tightly-coupled lidar inertial odometry via smoothing and mapping[C]//2020 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS), October 24-January, 2020-2021, Las Vegas, NV, USA. New York: IEEE Press, 2020: 5135-5142.
- [19] Zhang B W, Li S Y, Qiu J T, et al. Application and research on improved adaptive Monte Carlo localization algorithm for automatic guided vehicle fusion with QR code navigation[J].

- Applied Sciences, 2023, 13(21): 11913.
- [20] Forster C, Carlone L, Dellaert F, et al. *On-manifold preintegration for real-time visual: inertial odometry*[J]. IEEE Transactions on Robotics, 2017, 33(1): 1-21.
- [21] Qin T, Li P L, Shen S J. *VINS-mono: a robust and versatile monocular visual-inertial state estimator*[J]. IEEE Transactions on Robotics, 2018, 34(4): 1004-1020.
- [22] Bahnam S, Pfeiffer S, de Croon G C H E. *Stereo visual inertial odometry for robots with limited computational resources*[C]// 2021 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS), September 27-October 1, 2021, Prague, Czech Republic. New York: IEEE Press, 2021: 9154-9159.
- [23] Xu W, Cai Y X, He D J, et al. *FAST-LIO2: fast direct LiDAR-inertial odometry*[J]. IEEE Transactions on Robotics, 2022, 38(4): 2053-2073.
- [24] Liu Z, Zhang F. *BALM: bundle adjustment for lidar mapping*[J]. IEEE Robotics and Automation Letters, 2021, 6(2): 3184-3191.
- [25] Barron I R, Sharma G. *Optimized modulation and coding for dual modulated QR codes*[J]. IEEE Transactions on Image Processing, 2023, 32: 2800-2810.
- [26] Li S X, Li G Y, Zhou Y L, et al. *Real-time dead reckoning and mapping approach based on three-dimensional point cloud*[M]// Sun J D, Yang C F, Guo S R. China satellite navigation conference. Lecture notes in electrical engineering. Singapore: Springer, 2018, 499: 643-662.
- [27] Cui Y G, Chen X Y, Zhang Y L, et al. *BoW3D: bag of words for real-time loop closing in 3D LiDAR SLAM*[J]. IEEE Robotics and Automation Letters, 2023, 8(5): 2828-2835.
- [28] Zuo X X, Yang Y L, Geneva P, et al. *LIC-fusion 2.0: LiDAR-inertial-camera odometry with sliding-window plane-feature tracking*[C]// 2020 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS), October 24-January 24, 2020-2021, Las Vegas, NV, USA. New York: IEEE Press, 2020: 5112-5119.

Warehouse AGV Navigation Based on Multimodal Information Fusion

Zhang Bo¹, Zhang Yinlong^{2,3,4*}, Liang Wei^{2,3,4}, Wang Xin¹, Yang Yutuo^{2,3,4}

¹*School of Electrical and Control Engineering, Shenyang Jianzhu University, Shenyang 110168, Liaoning, China;*

²*Key Laboratory of Networked Control System, Chinese Academy of Sciences, Shenyang 110169, Liaoning, China;*

³*Institute of Robotics and Intelligent Manufacturing Innovation, Chinese Academy of Sciences, Shenyang 110169, Liaoning, China;*

⁴*State Key Laboratory of Robotics, Shenyang Institute of Automation, Chinese Academy of Sciences, Shenyang 110169, Liaoning, China*

Abstract

Objective In the rapidly evolving domain of warehouse logistics, the deployment of automated guided vehicles (AGVs) with advanced navigation capabilities is becoming increasingly essential. This research is driven by the need to address significant challenges in existing laser-inertial navigation systems used in warehouse environments. These challenges include susceptibility to inertial bias drift, compromised real-time performance, and reduced pose estimation accuracy, particularly in areas with repetitive structures or dynamic environmental changes. The study aims to not only enhance the operational efficiency of AGVs but also significantly contribute to the broader field of industrial automation and intelligent robotics systems. By improving the precision and reliability of AGV navigation, the research endeavors to optimize warehouse operations, reduce operational costs, and increase throughput. This objective is critical in addressing the limitations of current navigation systems and ensuring the adaptability and effectiveness of AGVs in complex warehouse settings, thereby contributing to the evolution of automated logistics and enhancing overall supply chain management.

Methods A comprehensive methodology was developed to enhance AGV navigation in warehouse environments, integrating a multimodal fusion of laser light detection and ranging (LiDAR), inertial measurement unit (IMU), and quick response (QR) code technologies. This fusion approach was meticulously engineered to synergistically combine the unique strengths of each sensing modality, thereby overcoming the inherent limitations of traditional laser-inertial navigation systems.

In the warehouse setting, QR codes were strategically affixed to the floor at intervals of 1200 mm. When an AGV scanned a QR code, the system received precise positional and angular information, providing an essential absolute reference for recalibrating the AGV's navigational state. Furthermore, IMUs were uniquely calibrated using QR code data to compensate for inertial bias drift, significantly enhancing inertial measurement accuracy. In addition to considering inertial residuals, a reprojection error between the 3D point q at position x_q and frame i was defined, incorporating error analysis from the downward-facing sensor for QR codes on top of the laser reprojection error.

According to the bundle adjustment for LiDAR mapping (BALM) algorithm, an innovative layered local bundle adjustment (BA) optimization process integrated with QR code data was introduced. This process streamlined the BA procedure, markedly reducing computational load and optimization time. The optimization process was structured from the

bottom layer to the top, with each layer consisting of a set number of LiDAR frames. Keyframes within these layers, particularly those identified through QR code scans, were used to construct a more precise and consistent global trajectory for the AGV. During the layered BA optimization, specific keyframes within each window were maintained without participating in the BA optimization. Following this layered optimization, a top-down pose graph optimization was implemented, crucial for minimizing cumulative pose estimation errors that might have propagated through the bottom-up optimization process. This phase of the optimization considered common features within each window of frames, particularly focusing on frames associated with QR code scans. The fixed positions from QR code scans ensured high confidence in pose estimates, significantly enhancing the overall accuracy of the navigation system. This dual optimization process effectively addressed scale drift and time-consuming issues commonly encountered in incremental mapping methods, ensuring a more accurate and efficient navigation system for AGVs. The integration of QR code data not only provided high positional accuracy but also contributed to the robustness and reliability of the AGV navigation system in complex warehouse environments.

Results and Discussions In our research, we address the challenge of inertial bias drift by proposing an IMU pre-integration model integrated with QR code data. This model utilizes the rigid constraint information provided by QR codes to update inertial biases. By considering inertial residuals and jointly optimizing the errors from laser-inertial and downward-facing camera systems, we establish a robust initial state estimation using the absolute pose derived from the QR codes captured by the downward-facing camera. This approach ensures a solid starting point for the joint optimization, accelerating the convergence speed, and enhancing the accuracy of the estimates. Experimental validations have been conducted on linear and rectangular trajectories. The performance of our method is compared with open-source algorithms such as LeGO-LOAM, BALM, LIO-SAM, and LIC-Fusion2. Notably, as the trajectory length increases from 24000 mm to 60000 mm, the absolute translational and rotational errors of our method only grow by approximately 2 mm and 0.5° , respectively. This represents a 1–4 times improvement in overall positioning accuracy (Table 2 and Table 3).

To address the issue of real-time performance, we propose a globally consistent optimization model, selectively incorporating keyframes and QR codes to execute a layered local BA optimization from the bottom layer to the top. This process significantly enhances the consistency and precision of LiDAR mapping and AGV positioning. During the layered optimization process, the pose of specific keyframes (derived from QR code solutions) is maintained constant and not involved in the optimization process, ensuring accuracy while significantly reducing optimization time. In our experimental setup within a warehouse logistics environment, our algorithm demonstrates a substantial improvement in time efficiency, outperforming LeGO-LOAM, BALM, LIO-SAM, and LIC-Fusion2 by 49.40%, 20.03%, 19.95%, and 37.29%, respectively (Table 4). Finally, leveraging factor graph optimization, we propose a globally consistent navigation framework that fuses laser-inertial and QR code data. This framework integrates pre-integration factors, tracking factors, loop closure factors, and QR code factors into the factor graph model, realizing multi-level data fusion. This approach effectively reduces cumulative errors and provides a globally consistent AGV navigation outcome (Fig. 4). This innovative navigation system represents a significant advancement in AGV technology, offering enhanced accuracy, efficiency, and consistency in complex warehouse environments (Fig. 4).

Conclusions To address the challenges inherent in laser-inertial-based navigation methods in warehouse logistics environments, such as inertial bias drift, poor real-time performance, and low pose estimation accuracy in degraded scenarios, we present a precise laser-inertial-QR fusion navigation method for autonomous and accurate AGV navigation in warehouse logistics settings. By integrating the IMU pre-integration model with QR data and employing a globally consistent optimization approach, we successfully estimate and correct inertial biases while reducing optimization time. The tight coupling of LiDAR, IMU, and barcode data facilitates multi-level data fusion, significantly enhancing positioning accuracy and robustness. The method has been extensively compared with leading laser-inertial navigation methods on a developed navigation platform. Experimental results demonstrate the superior time efficiency and reduced pose errors of the algorithm that maintains translational and rotational errors below 0.02 m and 2° , respectively, regardless of the trajectory length.

Future research will explore deeper multi-sensor fusion by integrating visual sensors to further enhance navigational accuracy. This includes capturing feature points using high-precision cameras and synergistically optimizing them with laser and IMU data using visual SLAM techniques, thereby strengthening system performance in variable lighting conditions or feature-deprived scenarios. Additionally, the development of a new real-time adaptive calibration method within the multi-sensor fusion algorithm is considered. This method aims to utilize real-time sensor data for continuous adjustment of sensor model parameters. The key lies in employing advanced filtering techniques, such as Kalman filters or particle filters, to estimate and correct sensor errors in real time, potentially achieving significant improvement in system accuracy and reliability.

Key words LiDAR; simultaneous localization and mapping; inertial measurement unit preintegration; quick response code; factor graph optimization