

面向未知环境的紧耦合激光 SLAM 方法

李荣华, 祁宇峰, 谢 辉, 韩兴元

(大连交通大学 机械工程学院, 辽宁 大连 116028)

摘要: 针对传统激光 SLAM 在长走廊、隧道等退化环境下系统精度低或算法失效, 且存在常规环境下回环检测稳健性差等问题, 提出一种面向未知环境的紧耦合激光 SLAM 方法。首先, 采用紧耦合框架, 融合 LiDAR 与 IMU 信息, 修正 IMU 零偏, 为 LiDAR 里程计提供高精度先验信息; 其次, 计算 LiDAR 里程计雅克比矩阵, 实时检测环境几何信息维度, 融合轮式里程计与 IMU 数据, 补偿 LiDAR 里程计自由度; 最后, 构建变阈值回环搜索模型, 采用不同配准方法分析对应阈值的关键帧信息, 提高回环检测召回率。长走廊环境中, 所提方法定位误差较 A-LOAM、LIO-SAM 分别降低了 91.04% 和 97.37%; 常规环境中, 在满足回环检测准确率为 100% 的条件下, 所提方法召回率较 LIO-SAM 提高了 35%。实验结果表明, 所提方法具有较高的鲁棒性与定位精度。

关键词: 激光 SLAM; 长走廊; 未知环境; 紧耦合; 回环检测

中图分类号: TP242.6 **文献标志码:** A **DOI:** 10.3788/IRLA20220839

0 引 言

随着人工智能和互联网技术的快速发展, 无人驾驶、无人机与智能机器人逐渐走进人们的日常生活中^[1]。同步定位与地图构建 (Simultaneous Localization and Mapping, SLAM) 作为这些领域的重要技术之一, 扮演着不可或缺的角色。

根据使用的观测传感器不同, SLAM 主要分为视觉 SLAM 和激光 SLAM。相机不能直接获取特征点的深度信息, 并且容易受到相机运动和外界光线因素的影响^[2]。激光雷达可以快速并稳健提供周围环境的高精度点云数据^[3], 提供周围环境的几何信息, 不易受到环境影响。因此, 相比于视觉 SLAM, 激光 SLAM 稳健性更高。

2016 年, Google 团队提出的 Cartographer^[4] 可用于 2D 及 3D 激光 SLAM, 具有较高精度的室内定位与建图能力, 而 3D 建图算法的实时性较差。2017 年, LOAM^[5] 仅使用激光雷达传感器, 采用一种基于曲率特征的前端里程计, 保证了准确性与高效性, 是激光 SLAM 中表现较好的算法之一, 在旋转较快的场景稳

健性不足。惯性测量单元 (Inertial Measurement Unit, IMU) 受零偏干扰, 累积误差较大, 但不易受外界干扰, 使用积分方法可快速提供高频率的位置和姿态^[6]。2018 年, Shan 等^[7] 在 LOAM 算法的基础上, 采用松耦合的方式融合 IMU 数据, 提出 LeGO-LOAM, 使用广度遍历优先算法提取地面点和非地面点, 利用两步优化的帧间里程计以提高计算效率, 并增加回环检测功能, 降低累积误差。松耦合的融合方式对传感器数据利用不够充分, 没有为传感器下一次定位提供帮助。2019 年, Ye 等^[8] 受 VINS 系统^[9] 的启发, 采用紧耦合的融合方式融合 IMU 与激光雷达, 修正 IMU 的零偏, 实现了实时的激光里程计与建图方法 LIO-mapping, 简称为 LIOM, 但该算法的耗时较高。GPS^[10] 是一种全局定位传感器, 可以获得全局信息。2020 年, Shan 等^[11] 提出 LIO-SAM, 使用紧耦合融合方式的同时, 有效地加入 GPS 约束, 可以很好地对抗快速移动和旋转等具有挑战性的大场景建图, 在精度与运行时间上均有不俗表现, 但是在极端环境下鲁棒性较低。长走廊、隧道等退化环境缺乏某个或多个自由度的几何信

收稿日期: 2022-11-22; 修订日期: 2023-02-11

基金项目: 辽宁省教育厅科学研究项目重点项目 (LJKZ0475); 大连市杰出青年科技人才项目 (2022RJ03)

作者简介: 李荣华, 男, 教授, 博士, 主要从事移动机器人 SLAM 技术方面的研究。

息, LIO-SAM 存在系统精度低或算法失效的问题。常规环境中, 前端里程计累积误差随场景变大而提高, LIO-SAM 采用的基于欧氏距离回环检测方法存在漏检问题, 无法消除前端里程计的累积误差。

针对上述问题, 提出一种面向未知环境的紧耦合激光 SLAM 算法, 在退化环境中更加稳健, 回环检测的召回率更高。文中算法主要的创新之处在于以下两个方面:

1) 提出一种退化环境中鲁棒的定位方法, 计算 LiDAR 里程计雅克比矩阵, 对比最小特征值低于阈值, 判断环境的几何信息维度缺失, 融合轮式里程计与 IMU 数据, 补偿 LiDAR 里程计缺失的自由度, 提升系统稳定性。

2) 提出一种变阈值回环检测方法, 合理剔除退化帧与邻近帧, 扩大搜索阈值, 构建变阈值回环搜索模型, 采用不同配准方法分析对应阈值关键帧信息, 提高回环检测召回率, 修正历史帧位姿, 保证建图的全局一致性。

1 紧耦合激光 SLAM 方法

1.1 紧耦合激光 SLAM 算法框架

文中方法框架见图 1, 简单分为以下四个部分:

1) IMU 里程计模块: 对 IMU 数据进行预积分, 为 LiDAR 里程计提供高精度的先验信息, 采用因子图优化方法, 利用补偿后的 LiDAR 里程计修正 IMU 的零偏。

2) LiDAR 里程计模块: 利用 IMU 里程计的先验信息补偿点云数据的运动畸变, 根据曲率大小提取特征点云, 采用 IMU 里程计作为初值对特征点云配准。计算 LiDAR 里程计的雅克比矩阵, 对比最小特征值低于阈值, 判断环境的几何信息维度缺失, 融合轮式里程计与 IMU 数据, 补偿 LiDAR 里程计自由度。

3) 回环检测模块: 利用 LiDAR 里程计构建关键帧队列, 剔除队列中退化帧与邻近帧。构建变阈值回环搜索模型, 采用不同配准方法分析对应阈值的关键帧信息, 提高回环检测召回率。

4) 后优化模块: 构建最小二乘模型, 将 LiDAR 里程计和回环检测的约束作为残差, 求解所有关键帧

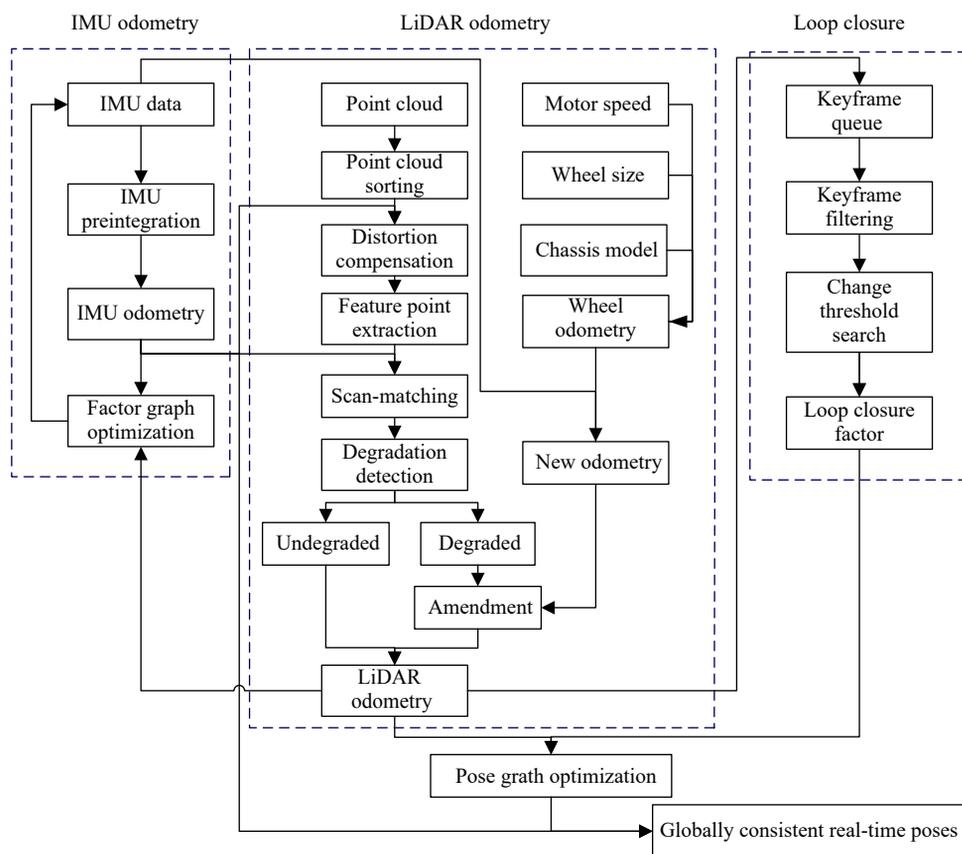


图 1 紧耦合激光 SLAM 算法框架

Fig.1 Framework of tightly coupled laser SLAM algorithm

位姿的最优解, 保证建图的全局一致性。

1.2 IMU 预积分

IMU 预积分的核心思想是预积分结果与上一时刻系统状态无关^[12], 因此, IMU 的零偏经过修正后, 求解下一时刻结果不需要对前一时刻的系统状态重新积分。加速计与陀螺仪的真值 a_k^\wedge 、 ω_k^\wedge 表示为: $a_k^\wedge = a_k + b_{a_k} + n_a$ 、 $\omega_k^\wedge = \omega_k + b_{\omega_k} + n_\omega$ 。其中 a_k^\wedge 、 ω_k^\wedge 为加速计与陀螺仪的观测值, b_{a_k} 、 b_{ω_k} 为加速计与陀螺仪的零偏, n_a 、 n_ω 为加速计与陀螺仪的高斯噪声。

计算位姿、速度、旋转的预积分量:

$$\alpha_{k+1}^k = \iint_{t_k}^{t_{k+1}} R_t^k (a_t^\wedge - b_{a_t} - n_a) dt^2 \quad (1)$$

$$\beta_{k+1}^k = \int_{t_k}^{t_{k+1}} R_t^k (a - b_{a_t} - n_a) dt \quad (2)$$

$$\gamma_{k+1}^k = \int_{t_k}^{t_{k+1}} q_t^k \otimes \begin{bmatrix} 1 \\ \omega_t^\wedge \times \Delta t / 2 \end{bmatrix} dt \quad (3)$$

IMU 频率较高, 将所有时刻 IMU 零偏进行优化计算量过于庞大。可以假设短时间内 IMU 零偏保持不变, 减少算力负担。计算位姿 p 、速度 v 、旋转 q :

$$p_{k+1} = p_k + v_k + \overline{a_k^\wedge} \times \Delta t^2 / 2 \quad (4)$$

$$v_{k+1} = v_k + \overline{a_k^\wedge} \times \Delta t \quad (5)$$

$$q_{k+1} = q_k \otimes \begin{bmatrix} 1 \\ \overline{\omega_k^\wedge} \times \Delta t / 2 \end{bmatrix} \quad (6)$$

$$\overline{a_k^\wedge} = [q_k (a_k^\wedge - b_{a_k}) + q_{k+1} (a_{k+1}^\wedge - b_{a_{k+1}}) - 2g] / 2 \quad (7)$$

$$\overline{\omega_k^\wedge} = (\omega_k + \omega_{k+1} - 2 \times b_{\omega_k}) / 2 \quad (8)$$

1.3 环境几何信息维度检测

环境几何信息维度检测是评估 LiDAR 里程计可靠性的关键能力。定位系统大多因不可观测失效^[13], 基于视觉的系统缺乏纹理和显著特征, 激光雷达的前端里程计在长走廊等退化环境缺乏某个或多个维度的几何信息。

利用 IMU 里程计去除点云运动畸变, 根据曲率提取面特征与线特征, 计算点云曲率 c :

$$c = \frac{1}{|s| \cdot \|X_{(k,j)}\|} \left\| \sum_{j \in s, j \neq i} (X_{(k,i)} - X_{(k,j)}) \right\| \quad (9)$$

使用 kd-tree 获得每个线点 O_i 临近的两个共线点 A_i 、 B_i 和每个面点 O_p 邻近的三个不共线点 A_p 、 B_p 、 C_p ,

计算点到线的距离 d_l 与点到面的距离 d_p 之和作为残差 e :

$$d_l = \frac{|\overrightarrow{B_i O_i} \times \overrightarrow{A_i O_i}|}{|\overrightarrow{A_i B_i}|} \quad (10)$$

$$d_p = \frac{|(\overrightarrow{C_p B_p} \times \overrightarrow{A_p B_p}) \cdot \overrightarrow{B_p O_p}|}{|\overrightarrow{C_p B_p} \times \overrightarrow{A_p B_p}|} \quad (11)$$

$$e = \sum d_l + \sum d_p \quad (12)$$

目标函数对优化变量求导获得雅克比矩阵 J , 对 $J^T J$ 进行特征值分解。

$$J = \frac{\partial e}{\partial x} \quad (13)$$

$$|J^T J - \lambda E| = 0 \quad (14)$$

$$J^T J x = \lambda x \quad (15)$$

小于阈值的特征值对应特征向量方向的几何信息缺失, 该方向 LiDAR 里程计发生退化。特征值大于阈值, 计算相邻帧位姿:

$$J^T J \Delta x = -J^T e \quad (16)$$

1.4 基于欧氏距离改进的变阈值回环检测

为减轻回环检测与后端优化的计算负担, 根据 LiDAR 里程计选取关键帧。关键帧的选取指标通常分为时间指标、距离指标、共视特征点指标^[14], 文中采用的观测传感器为激光雷达, 共视特征点较多, 使用较为合理的距离指标选取关键帧。

求解几何信息缺失的闭环约束易丢失自由度, 去除发生退化的关键帧。为避免误检邻近帧, 并解决机器人停留问题, 剔除距离当前帧帧数差值较小的关键帧。

如图 2 所示, LiDAR 里程计存在累积误差, LiDAR 里程计中的漂移可能大于搜索阈值, 导致错过检测到闭合回路的机会。

为提高回环检测召回率, 如图 3 所示, 构建变阈值回环搜索模型, 采用不同配准方法分析对应阈值关键帧信息。使用最大检测阈值 T_0 筛选出备选关键帧, 为保证阈值设置合理性, 将相邻帧相对位姿方差分为退化方差 v_{de} 与非退化方差 v_{no} 。

设置不同的回环检测阈值 T_1 、 T_2 、 T_3 , 使用对应的求解方法求得回环处的相对位姿, 并将 ICP 得分小于阈值的帧作为备选约束。

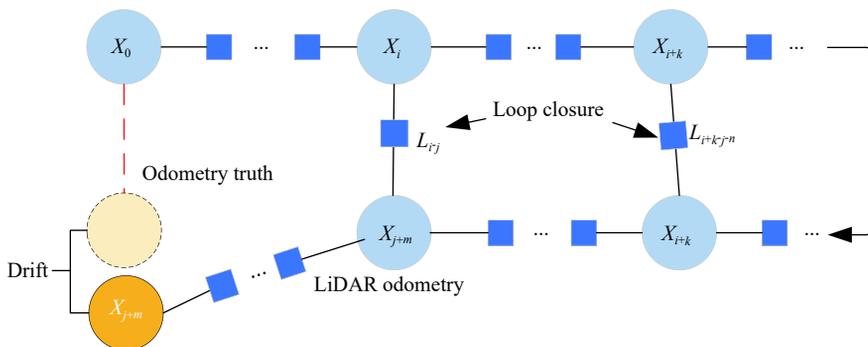


图 2 里程计累积误差

Fig.2 Cumulative error of the odometer

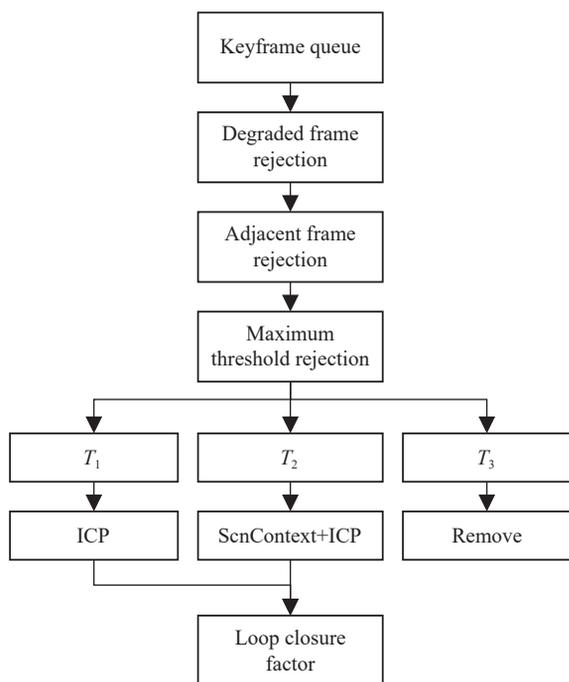


图 3 变阈值回环检测

Fig.3 Loop detection of variable threshold

其中 $T_0 : [0, F_m)$ 、 $T_1 : [0, F_c - F_v)$ 、 $T_2 : [F_c - F_v, F_c + F_v]$ 、 $T_3 : (F_c + F_v, F_m]$ 、 $F_v = n_{de} \cdot v_{de} + n_{no} \cdot v_{no}$ 、 F_c 为可检测到的回环距离， F_v 为备选帧到当前帧的方差， n_{de} 、 n_{no} 为备选帧到当前帧中退化帧数与非退化帧数。

当有新的备选约束进入，等待固定时间是否有新的备选约束^[15]，选取最小欧氏距离的备选约束作为回环约束，添加到位姿图中。

1.5 位姿图优化

位姿图优化旨在消除 LiDAR 里程计的累积误差，保证全局一致性。将每一关键帧位姿作为待优化变量，LiDAR 里程计中相邻关键帧之间的相对位姿和回环作为约束，构建位姿图模型，即求解最小二乘问

题，如公式 (17) 所示：

$$\min \frac{1}{2} \sum_{i,j \in \mathcal{E}} e_{ij}^T \sum_{ij}^{-1} e_{ij} \quad (17)$$

由于目标函数为非线性函数，使用列文伯格马夸尔特优化方法进行求解，获得每个关键帧的最优位姿，然后利用优化后的位姿对点云地图进行修正，保证地图的全局一致性。

2 实验

2.1 实验设备

为测试文中方法的性能，采用如图 4 所示的轮式移动机器人进行测试。文中机器人搭载 9 轴 IMU、大疆 M3508 电机、C620 电调和 RS-LiDAR-16 激光雷达，水平视角为 360°，垂直视角为 30°，点云输出频率为 10 Hz，有效距离 0.4~150 m，精度小于 3 cm。移动机器人底盘配有四个麦克纳姆轮，可实现全向移动，搭载装有 Ubuntu16.04 系统的 NUC8 i5 BEK1 工控机上运行，算法主体基于 ROS 平台进行开发。



图 4 实验机器人平台

Fig.4 Experimental robot platform

2.2 退化环境实验

2.2.1 实验场景说明

退化测试场景为校园中的长走廊,见图 5,长为 76.78 m、宽为 1.85 m,两侧是大面积的白墙,场景重复度高,运动方向几何特征较少。为防止扫描到室内环境破坏退化场景,在录制数据集时关闭了所有办公室的门窗,该走廊符合文中所讨论的退化场景特点。



图 5 长走廊环境

Fig.5 Long corridor environment

针对该数据集,使用了 A-LOAM (LiDAR)、LIO-SAM (LiDAR+IMU) 和文中方法算法 (LiDAR+IMU+轮速计) 进行了测试,采用文献 [16] 中“场景还原度”为评估指标,验证文中方法的有效性。场景还原度为 γ ,其计算方式为:

$$\gamma = \frac{l_m}{l_t} \times 100\% \quad (18)$$

式中: l_m 为最后建成的点云地图里场景长度的测量值; l_t 为实际走廊长度的手工测量值。

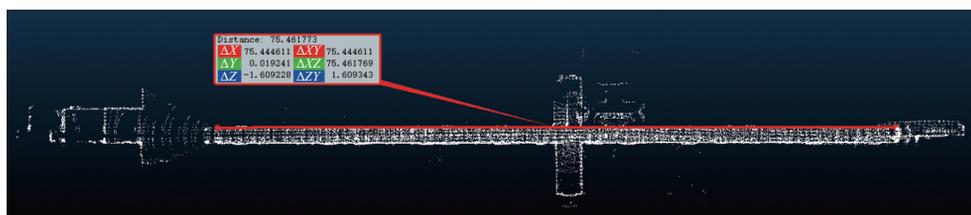
2.2.2 实验结果及分析

图 6 展示了 A-LOAM 算法、LIO-SAM 算法和文中方法建图实验结果的俯视图和侧视图。为鲜明对比三种算法的建图精度,在长走廊中部楼梯处对齐三个地图。如图 6(a)~(c) 所示, A-LOAM、LIO-SAM 和文中方法的建图长度分别为 72.22、75.44、76.66 m,由 CloudCompare 软件测得。如图 6(d)~(f) 所示, A-LOAM 建图结果的 Z 轴产生了严重漂移, LIO-SAM 与文中方法的 Z 轴无明显漂移。



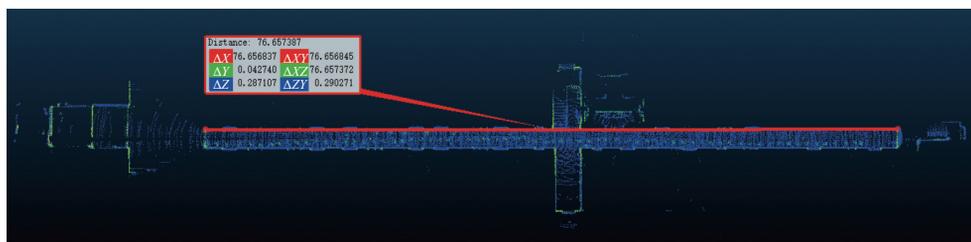
(a) A-LOAM 算法实验结果的俯视图

(a) Top view of experimental results of A-LOAM algorithm



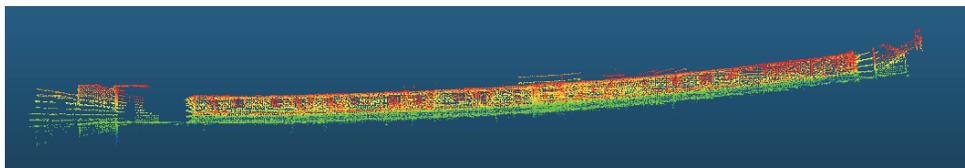
(b) LIO-SAM 算法实验结果的俯视图

(b) Top view of experimental results of LIO-SAM algorithm



(c) 文中方法实验结果的俯视图

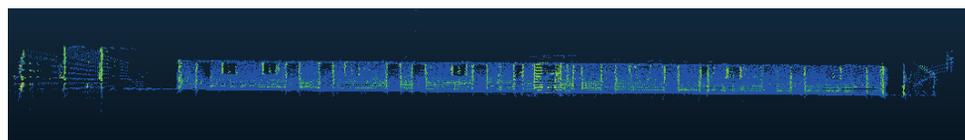
(c) Top view of the experimental results of the method in this paper



(d) A-LOAM 算法实验结果的侧视图
(d) Side view of experimental results of A-LOAM algorithm



(e) LIO-SAM 算法实验结果的侧视图
(e) Side view of experimental results of LIO-SAM algorithm



(f) 文中方法实验结果的侧视图
(f) Side view of the experimental results of the method in this paper

图 6 算法对比实验

Fig.6 Algorithm comparison experiment

表 1 为 A-LOAM、LIO-SAM 与文中方法的实验结果,场景还原度由公式 (18) 与测试场景走廊长度求出,长走廊中不易精确获取里程计真值,里程计漂移由建图长度推算出。文中方法在长走廊退化场景中场景还原度达到 99.71%,里程计漂移降低至 0.12 m,较 A-LOAM、LIO-SAM 分别降低了 91.04% 和 97.37%。

表 1 算法性能对比

Tab.1 Algorithm performance comparison

Item	Proposed	LIO-SAM	A-LOAM
Odometry drift/m	0.12	1.34	4.56
Scene restoration degree	99.71%	98.25%	94.06%

2.3 回环检测实验

2.3.1 回环检测评价说明

如表 2 所示,SLAM 的回环检测性能主要使用准确率 (*precision*) 和召回率 (*recall*)^[17] 这两个参数评估。

表 2 回环检测评估参数

Tab.2 Evaluation parameters of loop detection

Algorithm/Fact	Loop closure		Not loop closure	
	TP	FN	FP	TN
Loop closure	TP	FN	FP	TN
Not loop closure	FN	TP	FP	TN

准确率表示所有算法检测到的回环中真实回环的概率,召回率表示所有真实回环中被正确检测到的概率,计算方式分别为:

$$precision = \frac{TP}{TP + FP} \quad (19)$$

$$recall = \frac{TP}{TP + FN} \quad (20)$$

2.3.2 回环检测实验结果与分析

文中回环检测实验采用自制数据集,A-LOAM 算法无回环检测模块,文中方法与 LIO-SAM 的回环检测实验结果如表 3 所示。通过控制建图范围调节算法前端里程计漂移大小,分别选取三个漂移阈值的数据集测试 LIO-SAM 算法与文中方法的回环检测性能,为避免偶然性,每个阈值选取 20 个数据集进行测试。测试结果表明,随着前端里程计漂移的不断增

表 3 回环检测结果对比

Tab.3 Comparison of loop detection results

Drift/m	Proposed		LIO-SAM	
	<i>precision</i>	<i>recall</i>	<i>precision</i>	<i>recall</i>
0-5	20/20	20/20	20/20	20/20
5-10	20/20	20/20	14/14	14/20
10-15	19/19	19/20	4/4	4/20

加, LIO-SAM 算法回环检测的召回率由 100% 逐渐降低至 20%。在满足回环检测准确率为 100% 的条件下, 文中方法回环检测的召回率受里程计漂移影响较小, 相对 LIO-SAM 算法平均提高 35%。

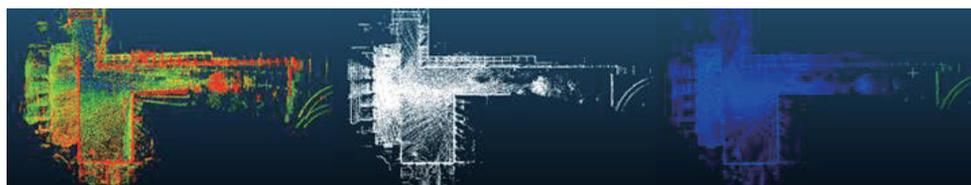
2.4 快速旋转实验

针对快速旋转场景的测试如图 7 所示, 图 7(a)~(f) 为六个由角速度递增的旋转数据集分别采用 A-

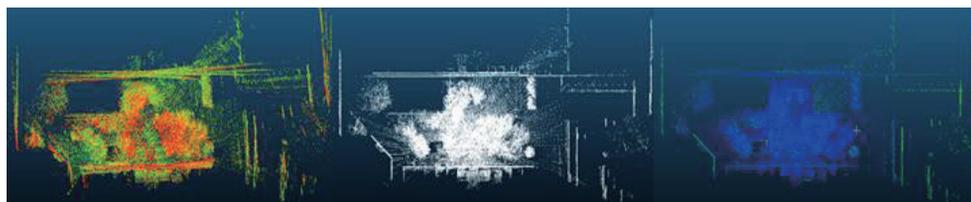
LOAM、LIO-SAM 和文中方法实时建图的结果。随着旋转速度的提升, A-LOAM 算法的前端里程计收敛效果下降, 产生的漂移递增, 建图结果中重影更加明显。LIO-SAM 和文中方法较好地克服了旋转速度提升带来的影响, 建图结果无明显重影, 较好地还原了场景的几何信息。在快速旋转场景, 利用 IMU 预积分结果作为初值, 提升系统稳健性。



(a) 快速旋转场景一实验结果
(a) Experiment results of fast rotating scene I



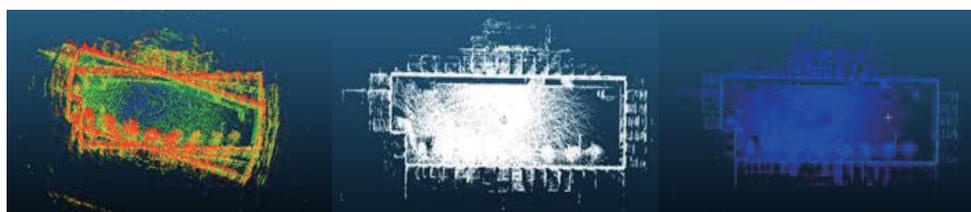
(b) 快速旋转场景二算法实验结果
(b) Experiment results of fast rotating scene II



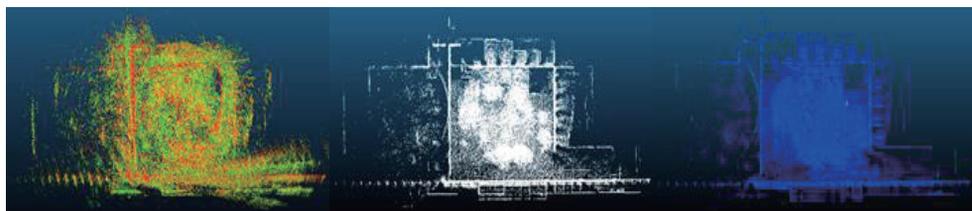
(c) 快速旋转场景三实验结果
(c) Experiment results of fast rotating scene III



(d) 快速旋转场景四实验结果
(d) Experiment results of fast rotating scene IV



(e) 快速旋转场景五实验结果
(e) Experiment results of fast rotating scene V



(f) 快速旋转场景六实验结果
(f) Experiment results of fast rotating scene VI

图 7 快速旋转场景实验结果对比

Fig.7 Comparison of experimental results of fast rotating scene

2.5 运行效率对比实验

在文中的七个数据集上, A-LOAM、LIO-SAM 和文中方法的单帧平均运行时间如表 4 所示。

表 4 单帧运行时间对比

Tab.4 Comparison of single frame run time

Dataset	A-LOAM/ms	LIO-SAM/ms	Proposed/ms
Long corridor	22.4	12.2	13.4
Fast rotating scene I	139.2	67.6	67.8
Fast rotating scene II	99.6	58.3	58.7
Fast rotating scene III	114.7	57.1	57.6
Fast rotating scene IV	92.0	58.1	58.5
Fast rotating scene V	198.2	63.6	64.0
Fast rotating scene VI	294.4	57.8	58.1

在所有测试过程中, 激光雷达数据的输出频率为 10 Hz 时, 如果运行时需要超过 100 ms, 那么一些激光雷达帧就会丢失。与 LOAM 相比, LIO-SAM 与文中方法每帧平均运行时间要少得多, 更适合于部署在低功耗的嵌入式系统上。安装文中方法的移动机器人在各类数据集中均可稳定运行, 说明文中方法满足实时性需求。

3 结 论

文中针对传统激光 SLAM 在长走廊、隧道等退化环境下系统精度低或算法失效, 且存在常规环境下回环检测稳健性差等问题, 提出了一种面向未知环境的紧耦合激光 SLAM 方法, 采用紧耦合融合方式, 利用 LiDAR 里程计修正 IMU 零偏, 使用 IMU 数据提供高精度先验信息。通过计算 LiDAR 里程计雅克比矩阵, 实时检测环境退化情况, 融合轮式里程计与 IMU 数据, 提升系统稳定性。提出一种基于欧氏距离改进

的变阈值回环检测方法, 提高回环检测召回率, 保证了地图的全局一致性。文中方法在长走廊环境中场景还原度达到 99.71%, 在满足回环检测准确率为 100% 的条件下, 召回率达到 98.3%, 较 LIO-SAM 算法平均提高 35%。解决了紧耦合系统在退化环境中定位与建图稳健性差的问题, 改善了室外大场景回环检测召回率的现象。

参考文献:

- [1] Chai J H, Dong M L, Sun P, et al. Model and compensation method of image point drift caused by self-heating of industrial camera [J]. *Infrared and Laser Engineering*, 2021, 50(6): 20200494. (in Chinese)
- [2] Zhu Z J, Zhang G Y, Yang M, et al. Multi-camera fast bundle adjustment algorithm based on normalized matrix dimensionality reduction [J]. *Infrared and Laser Engineering*, 2021, 50(2): 20200156. (in Chinese)
- [3] Du R J, Ge B Z, Chen L. Texture mapping of multi-view high-resolution images and binocular 3D point clouds [J]. *Chinese Optics*, 2020, 13(5): 1055-1064. (in Chinese)
- [4] 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.
- [5] Zhang J, Singh S. Low-drift and real-time lidar odometry and mapping [J]. *Autonomous Robot*, 2017, 41: 401-416.
- [6] Zhao Yaozhong, Xian Jinlong, Gao Wei. Research on a real-time odometry system integrating vision, LiDAR and IMU for autonomous driving [J]. *Infrared and Laser Engineering*, 2022, 52(8): 20210651. (in Chinese)
- [7] Shan T X, Englot B. LeGO-LOAM: Lightweight and ground optimized lidar odometry and mapping on variable terrain[C]// IEEE/RSJ International Conference on Intelligent Robots and Systems. Piscataway, USA. New York: IEEE, 2018: 4758-4765.

- [8] Ye H, Chen Y, Liu M. Tightly coupled 3D lidar inertial odometry and mapping[C]//2019 International Conference on Robotics and Automation (ICRA), 2019: 3144–3150.
- [9] Qin T, Li P, Shen S. VINS-Mono: a robust and versatile monocular visual-inertial state estimator [J]. *IEEE Transactions on Robotics*, 2018, 34(4): 1004-1020.
- [10] Li J P, Jiang T, Gong Z H, et al. GPS-supported 3D reconstruction of UAV images based on robust Lie-algebraic rotation averaging [J]. *Optics and Precision Engineering*, 2017, 25(6): 1607-1618. (in Chinese)
- [11] Shan T, Englot B, Meyers D, et al. LIO-SAM: tightly-coupled lidar inertial odometry via smoothing and mapping[C]//Proceedings of 2020 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS), 2020: 5135-5142.
- [12] Forster C, Carlone L, Dellaert F, et al. IMU Preintegration on manifold for efficient visual-inertial maximum-a-posteriori estimation [C]//Robotics: Science and Systems XI, Rome, Italy, 2015.
- [13] Chen X D, Ai D H, Zhang J S, et al. Gabor filter fusion network for pavement crack detection [J]. *Chinese Optics*, 2020, 13(6): 1293-1301. (in Chinese)
- [14] Yin F, Wu Y. Model reconstruction and pose optimization of non-cooperative rotating space target [J]. *Optics and Precision Engineering*, 2019, 27(8): 1854-1862. (in Chinese)
- [15] Frosi M, Matteucci M. ART-SLAM: accurate real-time 6 DoF LiDAR SLAM [J]. *IEEE Robotics and Automation Letters*, 2021, 7(2): 2692-2699.
- [16] Xu Y W, Yan W X, Wu W, et al. Improvement of LiDAR SLAM front-end algorithm based on local map in similar scenes [J]. *Robot*, 2022, 44(2): 176-185. (in Chinese)
- [17] Capdevila M, Márquez Flórez, Oscar W. A Communication perspective on automatic text categorization [J]. *IEEE Transactions on Knowledge & Data Engineering*, 2009, 21(7): 1027-1041.

Tightly coupled LiDAR SLAM method for unknown environment

Li Ronghua, Qi Yufeng, Xie Hui, Han Xingyuan

(School of Mechanical Engineering, Dalian Jiaotong University, Dalian 116028, China)

Abstract:

Objective Three-dimensional lidar is widely used in simultaneous localization and mapping (SLAM) research due to its accurate and reliable measurement performance, and has achieved fruitful results. However, in the scene where the geometric features such as long corridors and tunnels are not rich enough, the point cloud registration will have an additional degree of freedom in one direction, and the laser SLAM based on the point cloud information will degenerate, resulting in the failure of robot positioning and mapping, which will lead to the failure of subsequent navigation tasks. That is to say, when moving along a long corridor, the laser point cloud obtained is the same, which makes the matching algorithm unable to accurately estimate the motion in this direction. And in the conventional environment, the accumulated error of the front-end odometer increases with the increase of the scene. The loopback detection method based on the Euclidean distance of the traditional laser SLAM algorithm has the problem of missing detection and cannot eliminate the accumulated error of the front-end odometer. For this reason, a close-coupled laser SLAM method for an unknown environment is proposed in this paper.

Methods First of all, a close-coupled framework (Fig.1) is used to fuse LiDAR and IMU information, correct IMU bias, and provide high-precision prior information for the LiDAR odometer. Secondly, the LiDAR odometer Jacobi matrix is calculated, the environmental geometric information dimension is detected in real-time, the wheel odometer and IMU data is integrated, and the freedom of LiDAR odometer is compensated. Finally, in view of the loopback detection method based on Euclidean distance that has missed detection due to the accumulated error of the odometer (Fig.2), a variable-threshold loopback search model is constructed, and the corresponding threshold

key frame information is analyzed by different registration methods to improve the loopback detection recall rate (Fig.3).

Results and Discussions A-LOAM, LIO-SAM and the method in this paper are used to test in a 76.78 m long and 1.85 m wide corridor respectively. The corridor is flanked by large white walls, with high scene repetition and fewer geometric features in the direction of motion. In the long corridor degradation scenario, the scene restoration degree of the method in this paper reaches 99.71%, and the odometer drift is reduced to 0.12 m, which is 91.04% and 97.37% lower than A-LOAM and LIO-SAM, respectively (Tab.1). In addition, the data sets with three drift thresholds are selected, and 20 data sets are selected for each threshold to test the loopback detection performance. Under the condition that the accuracy of loopback detection is 100%, the recall rate of loopback detection is 98.3%, which is 35% higher than that of the LIO-SAM algorithm on average (Tab.3).

Conclusions In this study, a close-coupled laser SLAM method for an unknown environment is proposed. This method uses a tight coupling framework to improve the efficiency of sensor information utilization, and can detect the geometric information dimension of the environment in real-time. In the environment of fast-rotating scenes and missing geometric information, it can still achieve high-precision positioning and mapping. A variable threshold loopback search model is built, which can maintain a high loopback detection recall rate in large scenes. The position and posture of historical frames are corrected, and the global consistency of the map is ensured. The proposed method is proved to be robust and accurate by many scene experiments.

Key words: LiDAR SLAM; long corridors; degraded environment; tightly coupled; loop detection

Funding projects: Liaoning Provincial Department of Education Scientific Research Funding Project (LJKZ0475); Dalian High-Level Talent Innovation Support Program (2022RJ03)