

DOI: 10.13382/j.jemi.B2306831

复杂环境下机器人多传感器融合定位方法*

邓 鹏 罗 静

(荆楚理工学院电子信息工程学院 荆门 448000)

摘要:为了解决在斜坡、特征退化以及 GNSS 信号丢失等复杂环境下连续精确的定位问题,提出了基于地面约束的多传感器融合方案,用于提高 SLAM 算法的整体性能。首先提出了不同系统状态下的关键帧选取策略。通过在起始位置增加关键帧的数量,避免了因子图优化后产生的定位跳变,从而得到连续准确的位姿输出。同时,针对误差累积所导致回环检测失效,利用该关键帧策略,有效地增大当前帧的子关键帧集合,提高了回环检测算法的鲁棒性。其次,针对 IMU 在长时间运行后高度方向上漂移过大的问题,本文根据提取的地面点构建地面约束,并引入因子图中进行优化。最后,利用搭建的移动机器人实验平台,完成了校园不同场景的数据采集,验证本文算法的有效性,并在 KITTI 数据集与 LIO-SAM 算法进行了对比测试,通过误差分析表明本文算法具有更优的定位精度。

关键词: 多传感器融合; 复杂环境; 地面点云提取; 关键帧选取策略

中图分类号: TP242.6 **文献标识码:** A **国家标准学科分类代码:** 510.8050

Robot multi-sensor fusion localization method in complex environment

Deng Peng Luo Jing

(School of Electronic Information Engineering, Jingchu University of Technology, Jingmen 448000, China)

Abstract: In order to solve the problem of continuous and accurate localization in complex environments such as slope, feature degradation and GNSS signal loss, a multi-sensor fusion scheme based on ground constraints is proposed in this paper to improve the overall performance of SLAM algorithm. Firstly, the key frame selection strategy under different system states is proposed. By increasing the number of key frames in the starting position, the positioning jump caused by factor map optimization is avoided, and continuous and accurate pose output is obtained. At the same time, in order to prevent the loopback detection failure caused by error accumulation, this keyframe strategy is used to effectively increase the subkeyframe set of the current frame, and improve the robustness of the loopback detection algorithm. Secondly, to solve the problem that IMU drifts too much in the height direction after long-term operation, this paper constructs the ground constraint according to the extracted ground points and introduces it into the factor graph for optimization. Finally, the mobile robot experiment platform is used to complete the data collection of different scenes on campus, and the effectiveness of the proposed algorithm is verified. The comparison test between KITTI data set and LIO-SAM algorithm is carried out, and the error analysis shows that the proposed algorithm has better positioning accuracy.

Keywords: multi-sensor fusion; complex environment; ground point cloud extraction; key frame selection strategy

0 引 言

近年来,随着社会智能化加速,移动机器人在日常生

活中的使用较为广泛。SLAM 是近年来迅速发展的机器人感知技术之一,已经应用在自主导航^[1-3]、增强现实^[4-5]和医疗设备^[6-7]等领域,并且经过不断地完善,形成了以前端里程计、后端图优化、地图构建以及回环检测为主的

收稿日期:2023-08-17 Received Date: 2023-08-17

* 基金项目:荆门市科技计划项目(2023YFYB040)、湖北省高等学校优秀中青年科技创新团队项目(T2021028)、荆楚理工学院教学研究项目(JX2023-014)资助

经典框架。根据不同的传感器类型,主要分为激光 SLAM 和视觉 SLAM^[8]。视觉 SLAM 以相机为核心传感器,依据相机的不同类型,可分为单目 SLAM^[9-10]、多目 SLAM^[11] 和 RGB-D SLAM^[12]。以激光雷达为核心的 SLAM 中,依据优化方法可分为基于滤波的 SLAM 和基于优化的 SLAM。Murphy 等^[13] 基于粒子滤波将高维度状态空间转为低维度状态空间,提出 RBPF (Rao-blackwellised particle filter) 算法,有效降低了计算量。Montemerlo 等^[14] 结合 EKF 和 RBPF 算法提出 FastSLAM,该算法使用 RBPF 算法估计机器人位姿,然后利用 EKF 进行地图更新,实现了在未知环境中机器人的精确定位。随后,基于粒子服从高斯分布的假设提出 FastSLAM2.0,证明改进后的算法对线性 SLAM 问题的收敛性,精度比原来的 FastSLAM 算法提高了一个数量级^[15]。Grisetti 等^[16] 提出了 Gmapping,该算法把定位与建图分解为两部分,并提出精确计算粒子分布的方法,在滤波预测过程中,极大地减少了机器人位姿的不确定性。随着激光雷达技术的成熟,以及自动驾驶对空间感知需求的提高,基于三维激光的 SLAM 算法逐渐得到发展。Ji 等^[17] 提出了经典的 LOAM (Lidar odometry and mapping) 算法,通过匀速模型进行运动畸变校正,并构建一种可以同时获取低漂移和低复杂度的定位框架。Shan 等^[18] 基于 LOAM 算法,提出定位精度和实时性能更好的 LeGO-LOAM 算法。由于上述研究均使用单一传感器构建 SLAM 系统,因此无法避免复杂环境下的特征退化问题。

多传感器融合的优势是通过组合不同传感器特性,克服单传感器的缺点,提高位姿估计的精度和在不同应用场景下的鲁棒性。在融合 IMU 与其他感知传感器的 SLAM 系统中,能够输出高频率且精确的定位结果。考虑到激光定位的精度和稳定性,基于激光的多传感器融合方案得到许多研究人员的关注。Opromolla 等^[19] 融合三维激光点云和 IMU 数据,通过迭代最近点算法 (iterative closest point, ICP) 的扫描匹配实现定位,从激光点云中提取线特征进行建图。论文中使用主成分分析法检测线特征,比传统的最小二乘法拟合节省计算时间。Geneva 等^[20] 使用最近点平面因子,基于图优化框架融合 IMU 预积分。通过对比实验证明,在不同噪声水平下实现更好的定位精度和鲁棒性。Graeter 等^[21] 提出 LIMO (Lidar-Monocular) 算法,利用激光雷达的深度进行相机运动的跟踪。通过基于关键帧的捆集调整估计位姿,有效提高位姿估计的实时性。Chen 等^[22] 提出使用二维激光扫描建图,基于 EKF 的视觉惯性融合系统实现机器人的位姿估计。Xu 等^[23] 针对视觉特征不稳定的环境,提出融合 RGB-D 和低成本激光的 SLAM 方案,通过模式切换和数据融合提高室内 SLAM 的鲁棒性,但是该方法主要适用于室内场景,针对室外斜坡、GNSS 信号丢失等复

杂场景不具备较高鲁棒性。Chan 等^[24] 提出新颖的融合雷达和单目视觉的 SLAM 方案,相比特征匹配的方法,利用轨迹匹配实现的融合在运行时非常轻量,提高精度的同时不会产生计算资源的浪费。

针对复杂环境下,由于高楼和树木的影响导致 GNSS 受限,导致以 GNSS 信号为主要数据源的定位方法存在无法消除的累计误差。为解决上述存在的问题,本文提出一种基于激光雷达、IMU 和 GNSS 的多传感器融合 SLAM 方案。在数据预处理阶段对激光点云进行分割聚类,接着根据环境的线面特征构建 SLAM 前端,将激光里程计和 IMU 预积分融合,输出高频的里程计结果。在 SLAM 后端部分,把地面约束加入全局因子图进行优化,并在 GNSS 数据可用时引入全局测量。

1 整体融合策略

近年来,许多研究人员提出基于激光雷达的状态估计和建图方法。在这些方案中,LOAM 算法由于能够进行低漂移和实时性的状态估计和建图被广泛地使用。即使该方案仅使用激光雷达和 IMU 器件,仍获得非常优异的性能,并且在 KITTI 里程计数据集^[25] 的测试结果排行靠前,主要缺点是将数据保存在全局体素地图中,因而难以实现回环检测和融入其他绝对观测进行修正。当在结构特征丰富的场景时,体素地图会因变得稠密而降低优化过程的效率。由于 LOAM 核心是基于扫描匹配的方法,因此也会在大场景中产生严重漂移,需要辅助其他传感器。IMU 作为融合系统的主动型传感器,不依赖于结构特征和环境纹理等因素的影响,被广泛使用在激光雷达-惯性和视觉-惯性系统。基于 IMU 的状态估计方案能够在短时间内输出高频率、高精度的定位结果,但较为明显的缺点是,估计误差会随着时间不断累积。激光里程计输出的也是相对定位,经过长时间的运行后,SLAM 系统会产生不可忽视的误差。GNSS 能够提供地球坐标系下的全局位置,但是输出频率通常为 1 Hz,且易受到高层建筑和树林遮挡。由于使用单一传感器难以满足实际需求,移动机器人通常会搭载多源传感器,利用不同传感器的优势提升系统的整体性能。

本文阐述了一种在复杂环境下的激光里程计框架,可实现在因子图中加入激光雷达和 IMU,并在 GNSS 数据可用时引入全局观测。通过将点云去畸变过程假设为非线性模型,在激光雷达扫描过程中使用 IMU 估计位姿。估计的运动不仅用于去畸变,还可作为激光里程计优化的初值,然后根据输出的里程计估计因子图中 IMU 的 bias 随机游走。本文使用全局因子图进行状态估计,可以有效地实现激光雷达和 IMU 测量的融合,并在绝对观测可用时加入因子图,根据传感器类型构建相应的因

子进行联合优化。此外,以帧-局部地图匹配代替 LOAM 中帧-全局地图匹配进行位姿优化,极大地提高了系统的实时性能,这与关键帧的选取和高效的滑窗方法相似。同时,紧耦合的优化框架使得融合系统在长时间运行后,仍可以输出高精度的定位结果,即使在复杂环境下运行,比如 GNSS 数据不可用、结构特征退化的场景。

不同于其他的融合算法,本文首先在数据预处理中,基于激光雷达的安装高度分割出地面点,接着对处理后的点云进行聚类,去除环境中的异常点,包括噪声和不稳定的结构特征。在前端里程计部分,由曲率公式识别并提取的线特征点和面特征点,通过帧-局部地图匹配优化,输出在全局坐标系下的高精度定位信息。在后端部

分,用分割的地面点构建地面约束,优化相邻帧之间的变换,获取精度更高的激光雷达位姿。此外,在关键帧筛选过程中,根据系统不同的状态进行关键帧选取策略的切换,减小初始状态的定位误差,提高回环检测算法的鲁棒性。SLAM 系统融合框架如图 1 所示,首先接收激光雷达、IMU 和 GNSS 数据,通过这些观测估计机器人的状态和轨迹。这个状态估计可描述为最大后验问题,并将该问题建模为适合推理的因子图形式。假设环境噪声服从高斯模型,则状态估计等价于求解非线性最小二乘问题。在因子图中引入地面约束和 4 种类型的因子,包含 IMU 预积分因子、激光里程计因子、GNSS 因子、回环因子。




图 1 SLAM 系统框架图

Fig. 1 SLAM system framework diagram

2 图优化算法框架

首先对坐标系和符号进行说明,记世界坐标系为 W , 机器人坐标系为 B , 出于简化的考虑,假设 IMU 坐标系与机器人坐标系是一致的。因此,机器人状态可表示为:

$$\mathbf{x} = [\mathbf{R}^T, \mathbf{p}^T, \mathbf{v}^T, \mathbf{b}^T]^T \quad (1)$$

其中, $\mathbf{R}$ 为旋转矩阵, $\mathbf{p}$ 为表示位置的三维向量, $\mathbf{v}$ 为速度, $\mathbf{b}$ 为 IMU 的 bias 随机游走误差,机器人坐标系到世界坐标系的变换记为 $\mathbf{T} = [\mathbf{R} | \mathbf{p}]$ 。某一时刻的机器人状态 $\mathbf{x}$, 在因子图中表示为节点属性。当机器人的位姿超过自定义的阈值,在图中添加一个状态节点 $\mathbf{x}$ 。在插入新节点时,使用基于贝叶斯树的方法^[26]对因子图优化。以下小节分别介绍 4 种因子的构建过程。

2.1 IMU 预积分因子

由 IMU 的误差模型可知,考虑主要的高斯白噪声和 bias 随机游走情况下,角速度和加速度测量模型为:

$$\hat{\omega}_t = \omega_t + b_{\omega_t} + n_{\omega} \quad (2)$$

其中, $\hat{\omega}_t$ 为角速度测量值, ω_t 为角速度真实值, b_{ω_t} 、

n_{ω} 分别为陀螺仪的偏置和噪声。此处假设 bias 偏置服从随机游走模型,噪声服从高斯正态分布。

$$\hat{a}_t = a_t + R_t^T g^w + b_{a_t} + n_a \quad (3)$$

其中,左侧为加速度的测量值,右侧分别为加速度的真实值、重力加速度、加速度计的偏置和加速度噪声项。

根据连续时刻的 IMU 预积分公式:

$$\begin{aligned} \alpha_{b_{k+1}}^{b_k} &= \iint_{t \in [k, k+1]} [R_t^k (\hat{a}_t - b_{a_t} - n_a)] dt^2 \\ \beta_{b_{k+1}}^{b_k} &= \int_{t \in [k, k+1]} [R_t^k (\hat{a}_t - b_{a_t} - n_a)] dt \\ \gamma_{b_{k+1}}^{b_k} &= \int_{t \in [k, k+1]} \frac{1}{2} \Omega (\hat{\omega}_t - b_{\omega_t} - n_{\omega}) \gamma_t^{b_k} dt \end{aligned} \quad (4)$$

可以看到式(4)只与不同时刻的加速度测量值 $\hat{a}_t$ 和角速度测量值 $\hat{\omega}_t$ 相关。对该式进行重新讨论,由于 $\alpha_{b_{k+1}}^{b_k}$ 与 IMU 的 bias 随机游走相关,而 bias 也是待优化的变量,使得每次迭代求解得到 bias 后,仍需要对第 k 帧与第 $k+1$ 帧之间的 IMU 数据重新积分,重复地传递 bias 值是非常消耗计算资源的过程。假设预积分的变化量与 bias 成线性关系,可得式(5):

$$\begin{aligned}
\alpha_{b_{k+1}}^{b_k} &\approx \hat{\alpha}_{b_{k+1}}^{b_k} + J_{b_a}^\alpha \delta b_a + J_{b_\omega}^\alpha \delta b_\omega \\
\beta_{b_{k+1}}^{b_k} &\approx \hat{\beta}_{b_{k+1}}^{b_k} + J_{b_a}^\beta \delta b_a + J_{b_\omega}^\beta \delta b_\omega \\
\gamma_{b_{k+1}}^{b_k} &\approx \hat{\gamma}_{b_{k+1}}^{b_k} \otimes \begin{bmatrix} 1 \\ \frac{1}{2} J_{b_\omega}^\gamma \delta b_\omega \end{bmatrix}
\end{aligned} \quad (5)$$

同理,根据欧拉法推导离散时间的 IMU 预积分公式,可得第 i 时刻与第 $i+1$ 时刻的变量关系为:

$$\begin{aligned}
\hat{\alpha}_{i+1}^{b_k} &= \hat{\alpha}_i^{b_k} + \hat{\beta}_i^{b_k} \delta t + \frac{1}{2} R(\hat{\gamma}_i^{b_k}) (\hat{\alpha}_i - b_{a_i}) \delta t^2 \\
\hat{\beta}_{i+1}^{b_k} &= \hat{\beta}_i^{b_k} + R(\hat{\gamma}_i^{b_k}) (\hat{\alpha}_i - b_{a_i}) \delta t \\
\hat{\gamma}_{i+1}^{b_k} &= \hat{\gamma}_i^{b_k} \otimes \hat{\gamma}_{i+1}^i = \hat{\gamma}_i^{b_k} \otimes \begin{bmatrix} 1 \\ \frac{1}{2} (\hat{\omega}_i - b_{\omega_i}) \delta t \end{bmatrix}
\end{aligned} \quad (6)$$

采用基于中值法的 IMU 预积分,此处积分所得结果是前后两帧之间 IMU 增量信息,如式(7)所示:

$$\begin{aligned}
\hat{\alpha}_{i+1}^{b_k} &= \hat{\alpha}_i^{b_k} + \hat{\beta}_i^{b_k} \delta t + \frac{1}{2} \hat{\tilde{\alpha}}_i' \delta t^2 \\
\hat{\beta}_{i+1}^{b_k} &= \hat{\beta}_i^{b_k} + \hat{\tilde{\alpha}}_i' \delta t \\
\hat{\gamma}_{i+1}^{b_k} &= \hat{\gamma}_i^{b_k} \otimes \hat{\gamma}_{i+1}^i = \hat{\gamma}_i^{b_k} \otimes \begin{bmatrix} 1 \\ \frac{1}{2} \hat{\tilde{\omega}}_i' \delta t \end{bmatrix}
\end{aligned} \quad (7)$$

式中:

$$\begin{aligned}
\hat{\tilde{\alpha}}_i' &= \frac{1}{2} [q_i(\hat{a}_i - b_{a_i}) + q_{i+1}(\hat{a}_{i+1} - b_{a_i})] \\
\hat{\tilde{\omega}}_i' &= \frac{1}{2} (\hat{\omega}_i + \hat{\omega}_{i+1}) - b_{\omega_i}
\end{aligned} \quad (8)$$

2.2 激光里程计因子

当接收到新的激光雷达扫描时,通过计算局部子区域内点的平滑度提取线面特征。具有较大平滑度的点为边缘点,类似地,平面点的平滑度较小。记在 i 时刻提取的线面特征分别为 F_i^e 和 F_i^p , F_i 为 i 时刻所有特征构成的集合,即表示在机器人坐标系下的 $F_i = \{F_i^e, F_i^p\}$ 。

假设添加到因子图中新的状态变量为 x_{i+1} ,将相关联的激光雷达关键帧记为 F_{i+1} ,则基于局部的体素地图的激光里程计因子的构建过程如下:

基于滑动窗口的方法创建局部点云地图,点云图中包含固定数量的近邻关键帧。通过提取 n 帧最近的关键帧进行位姿估计,而不是仅优化相邻两帧之间的变换。关键帧构成的集合 $\{F_{i-n}, \dots, F_i\}$ 使用关联的变换关系 $\{T_{i-n}, \dots, T_i\}$ 转到 W 系,转换后的关键帧拼接形成体素地图 M_i 。由前文特征提取过程可知, M_i 的组成包括线特征构成的体素地图 M_i^e 和面特征构成的体素地图 M_i^p 。关键帧和体素地图之间的关系如下:

$$M_i = \{M_i^e, M_i^p\}$$

$$M_i^e = \tilde{F}_i^e \cup \tilde{F}_{i-1}^e \cup \dots \cup \tilde{F}_{i-n}^e \quad (9)$$

$$M_i^p = \tilde{F}_i^p \cup \tilde{F}_{i-1}^p \cup \dots \cup \tilde{F}_{i-n}^p$$

其中, $\tilde{F}_i^e$ 和 $\tilde{F}_i^p$ 为变换到世界坐标系下的线面特征。然后将 M_i^e 和 M_i^p 分别以分辨率 0.2 和 0.4 m 进行降采样,消除属于相同体素单元中的冗余特征,本文将 n 设置为 25。

2.3 GNSS 因子

即使只有 IMU 预积分因子和激光里程计因子就能够得到可靠的位姿估计,但在长时间的导航任务中,SLAM 系统仍会产生严重的漂移误差。为解决该问题,引入具有绝对观测的 GNSS 数据。在 GNSS 完成初始化后,使用式(10)将接收到的数据转化到笛卡尔坐标系。

$$T = \begin{bmatrix} c\theta c\varphi & c\varphi s\Phi s\theta - c\Phi s\varphi & c\Phi c\varphi s\theta + s\theta s\varphi & x_{utm_0} \\ c\theta c\varphi & c\Phi c\varphi + s\Phi s\theta s\varphi & -c\varphi s\Phi + c\Phi s\theta s\varphi & y_{utm_0} \\ -s\theta & c\theta s\Phi & c\Phi s\theta & z_{utm_0} \\ 0 & 0 & 0 & 1 \end{bmatrix} \quad (10)$$

其中, Φ, θ, φ 分别为 UTM 坐标系下载体初始的 roll, pitch, yaw。c 和 s 分别为 $\cos(\cdot)$ 函数和 $\sin(\cdot)$ 函数的简写, $x_{utm_0}, y_{utm_0}, z_{utm_0}$ 为第 1 个 GNSS 数据的 UTM 坐标。对于任意时间 t ,通过式(11)将 GNSS 测量转化到移动机器人的世界坐标系:

$$\begin{bmatrix} x_{world} \\ y_{world} \\ z_{world} \\ 1 \end{bmatrix} = T^{-1} \begin{bmatrix} x_{utm_t} \\ y_{utm_t} \\ z_{utm_t} \\ 1 \end{bmatrix} \quad (11)$$

每次在因子图添加新节点后,将新的 GNSS 因子与该节点进行关联。在算法实现中,若首尾关键帧之间距离小于 5 m,表明移动机器人运行距离很短,此时并不添加 GNSS 因子。由于激光雷达-IMU 融合系统的里程计漂移误差很缓慢,因此只有在估计的位姿协方差大于 GNSS 位置协方差时,才将 GNSS 因子加入因子图中优化。

2.4 回环因子

回环检测作为经典 SLAM 框架中重要的环节,可以有效地消除长时间的累积误差。考虑到相机在机器人领域的普遍应用,并且能够真实地表现环境纹理,提高回环检测的准确率,因此也随之融入到 SLAM 系统。为了识别错误的回环,通过视觉词袋模型对周围点云环境建模,查找与当前图像相似的状态节点。该模型实现原理是基

于贝叶斯滤波器,因此采集到每帧图像后都计算与前一帧的相似程度,形成基于图像信息的位置识别方法。通过生成的模型,可以表示两帧图像之间的相似度,进一步地,判断是否为相同环境进行回环优化。应该注意到,当不同环境中存在相似的特征时,可能误识别为已经采样过的相同环境,从而得出错误的匹配结果。

在激光雷达的 SLAM 系统中,若机器人当前的位姿 x_{i+1} 与前一帧位姿 x_i 的旋转和平移变化量超过定义的阈值,则将激光雷达数据 F_{i+1} 选为关键帧。然后将保存的关键帧与因子图中 x_{i+1} 节点相关联,以这种方式选择关键帧,可以实现机器人状态估计和内存消耗之间的平衡,提高了 SLAM 系统的鲁棒性。虽然能够满足较小场景的定位需求,但是这种关键帧选取策略仍然存在问题。在经过长时间的里程计误差累积后,导致最后回到原点时回环检测失效,尤其是在经过特征退化的场景时,位姿的漂移会迅速增大。为减小初始状态的定位误差和长时间的累积漂移,本文提出一种关键帧策略,根据不同系统状态设置相应的关键帧筛选条件,具体实现如算法 1 所示。

算法 1: 关键帧选取策略

```

1 输入: 前一帧  $L_k$ 
   当前帧  $L_c$ 
   帧间旋转变换  $\Delta R$  和平移变换  $\Delta X$ 
2 输出: 激光雷达关键帧
3 开始
4 If 机器人的运动距离  $D \leq 1$ 
   | 融合系统未完成初始化
   | 设定关键帧选取时的旋转增量  $\Delta R = 0.1$ 
   | 设定关键帧选取时的平移增量  $\Delta X = 0.1$ 
5 else
   | SLAM 系统完成初始化状态
   | 设置  $\Delta R = 0.2$ 
   | 设置  $\Delta X = 1$ 
6 end
7 满足条件,选取当前帧为关键帧
8 结束
  
```

通过上述基于关键帧的回环检测过程,能够有效识别激光雷达起始处扫描过的环境,在大场景下能够有效地减少定位误差。在解决较大的漂移时,回环检测作为常用的方法得到广泛使用。回环线程以较低的频率进行循环,根据扫描的当前帧点云,使用 KD-tree 查找距离阈值范围内的关键帧集合,若没有满足条件的关键帧,则表示未检测到回环。若满足距离条件,则对相应的候选关键帧集合再次进行筛选。

在基于关键帧搜索的回环检测中,当长时间运行产生较大误差时,难以检测到有效的回环状态。即在移动机器人运行一圈回到原点,并没有进行位姿的回环修正或者出现错误的回环。

因此,如果仅根据距离判断候选关键帧,会对整体的轨迹造成严重误差。通过将当前关键帧与候选关键帧时间间隔条件设置为 $\Delta t > 30$ s,可避免在激光雷达速度较慢时频繁发生回环优化,造成不必要的计算资源的消耗。尽管如此,在人群较多或交叉路口的环境中,导致停留时间很长,仍会产生上述问题。

本文在候选匹配帧选择时,不考虑当前关键帧之前的部分近邻关键帧。即当前关键帧的索引与候选匹配帧的索引之间需满足条件 $loopKeyCur - loopKeyLast > 30$ 。此外,在调用 ICP 算法前,对将要匹配的两部分特征点集合进行降采样,若处理后的特征点太少,则认为没有出现回环。通过算法 3 增加系统初始位置的关键帧数量,避免在 ICP 匹配时约束过少导致最终匹配效果不好甚至未收敛,具体的回环过程如图 2 所示。




图 2 改进的回环检测流程

Fig. 2 Improved loop detection flow chart

不同于 LOAM 系统,本文因子图的优化框架能够方便地引入回环约束。假设状态节点 x_{i+1} 添加到因子图中,并对因子图进行搜索,基于欧氏距离查找靠近 x_{i+1} 之前节点。如图 3 所示,圆圈为机器人状态节点,菱形为当前节点对应的关键帧。 x_2 为返回的候选节点,先将 F_{i+1} 和之前的子关键帧集合转换到 W 坐标系,然后使用扫描匹配算法将 F_{i+1} 关联到子关键帧集合 $\{F_{2-n}, \dots, F_2, \dots, F_{2+n}\}$ 。在获取相对变换 $\Delta T_{2,i+1}$ 后,将其作为回环因子添加到因子图。文中将索引 n 设置为 12,与新节点 x_{i+1} 回环检测的搜索距离设为 15 m。

3 地面约束

对于在地面运行的机器人,可以在 z 轴方向引入地面约束^[27-28]。但实际情况通常处于凹凸不平的路面,石拱桥,斜坡等其他非水平地面的场景,这种情况下的全局约束不再成立。因此,只有在满足相应条件时,才引入局




图 3 回环因子构建示意图

Fig. 3 Schematic diagram of loop factor construction

部的地面约束。若机器人在水平地面移动时,本文将相邻关键帧 z 轴位移建模为零均值的高斯分布。在满足水平地面的条件下,在后端优化中能够有效修正机器人的位姿。相反,在条件不成立的复杂路面,增加地面约束可能会加入错误信息,导致优化过程不收敛,本文通过以下两种情形来判定是否添加地面约束。

如图 4 所示,第 1 种情形考虑拟合的地平面法向量 $\vec{n}$ 与机器人 z 轴的夹角 α ,若超出给定的阈值范围,根据经验值中斜坡的定义,本文将边界条件设置为 $\alpha \geq 10^\circ$,则认为移动机器人不是在水平地面运动。另一个情形是基于拟合的地平面计算当前关键帧包含的点云中特征点比例 ρ ,若达到设置的边界条件 $\rho \leq 0.8$,则认为机器人运行在为非水平地面。




图 4 机器人在非水平地面上的示意图

Fig. 4 Schematic diagram of robot on non-horizontal ground

如果满足上述任意一种,则在后端的位姿优化中不添加地面约束。与之相反,若机器人在水平地面运动,则添加相应的地面约束,以提高位姿估计的准确性和鲁棒性。

4 实验与分析

4.1 实验平台

本文使用集成各种传感器和相关计算单元的四轮移动机器人实验平台来验证所提出的多传感器融合系统在复杂环境下的定位效果,如图 5 所示,包括激光雷达、IMU 传感器、一台 Intel Core-i7-10900 型号的车载计算机和供电系统。在机器人上还配备中海达组合定位模块,用于当 GNSS 数据可靠时收集机器人在室外的运动轨迹。基于该实验平台在不同校园场景下采集数据进行实

验,并在公开的 KITTI 数据集上与 LIO-SAM 算法进行了对比实验。




图 5 移动机器人实验平台

Fig. 5 Mobile robot experimental platform

4.2 回环检测实验

为验证在 GNSS 信号受限场景下,本文算法在后端加入地面约束和运用关键帧选取策略后对回环检测过程的影响。由于在 GNSS 数据满足一定条件时,会进行因子图优化,对回环实验的分析造成干扰,因此仅使用激光雷达的点云和 IMU 数据。图 6 是 LIO-SAM 算法和本文算法的点云图和定位轨迹,该场景的特征是树木较密,并且狭长路段较多,图 6(a)、(b)、(c) 中椭圆框为建筑遮挡形成的长直特征区域。周围环境复杂,实验过程人群密集,前进速度较慢,轨迹长度为 953 m,最后总耗时 712 s 完成数据采集过程。相对于之前的实验场景,由于 IMU 经过长时间的误差累积,使得在本文算法和 LIO-SAM 算法的测试效果更为明显。图 6(a) 为 LIO-SAM 算法构建的点云地图和运行轨迹,实验结果显示未检测到回环状态。图 6(c) 为本文算法运行相同的环境中的效果,回到原点后发生回环,并进行了位姿优化。

图 7 是 LIO-SAM 算法与本文算法的位移变化曲线图。LIO-SAM 算法在经过图中局部放大图形成的特征退化环境时,会导致 z 轴方向上的漂移迅速增加。本文算法在移动机器人运动时进行地面约束判断,满足条件则引入地面约束,有效减少高度上误差的不断累积。然而 LIO-SAM 算法生成的点云图,由于在运动过程中误差会不断累积,最终造成回到起点后未检测到回环。同时,在进行定位初始化时,保留较多的关键帧。在运动到原点后,能够有效检测到候选回环帧,并获取较多相邻的候选关键帧组成局部地图,使得在当前帧到局部地图的 ICP 匹配过程中能够有效收敛,得到足够好的匹配结果。与 LIO-SAM 算法相比,本文算法减小了各轴方向上的位移误差,显著提高了在高度方向上的定位精度。

4.3 KITTI 数据集测试

为验证本文基于地面约束的融合 SLAM 算法整体性能,使用 LIO-SAM 算法与本文算法在编号为 2011_09_30




图 6 回环检测实验点云图
Fig. 6 Cloud diagram of loop detection experimental points




图 7 回环检测中各轴位移变化曲线
Fig. 7 Displacement change curve of each axis in loop detection

_drive_0018 的 KITTI 数据集上进行测试。图 8 是两种算法分别在 x 、 y 、 z 轴的位移变化曲线,其中在 x 轴和 y 轴的定位误差比较接近。但在 z 轴方向上,本文算法更接近真实位移,误差值明显小于 LIO-SAM 算法。这是由于两者都未使用回环功能,而本文算法通过提取准确、稳定的地面点构建地面约束,有效地限制了高度方向的漂移。

图 9 是 LIO-SAM 算法与本文算法生成轨迹的绝对位姿误差。通常情况下,键入 `evo_ape` 命令计算的是位姿的平移分量,结果显示 LIO-SAM 算法 APE 最大值接近 9,而本文算法的 APE 明显更小。根据表 1 的数据可知,相对于 LIO-SAM 算法,本文算法的标准差明显更小,说明数据的稳定性较好,且其他各类误差值均更小,在该数据集的定位性能更优。图 10(a)为本文算法在 KITTI 数据集生成的点云图,图 10(b)为 LIO-SAM 算法与本文算法的轨迹对比图。

表 1 KITTI 数据集误差分析表						
Table 1 KITTI dataset error analysis table						
	Max	Mean	Median	Min	RMSE	Std
LIO-SAM	8.837 336	3.284 803	2.991 117	2.182 962	3.456 996	1.077 447
本文算法	4.942 571	2.823 560	2.844 005	2.058 918	2.867 466	0.499 875

5 结 论

为了解决在斜坡、特征退化以及 GNSS 信号丢失等复杂环境下连续精确的定位问题,本文提出了基于地面约束的多传感器融合方案,用于提高 SLAM 算法的整体性能。为减小初始状态的定位误差,提出了不同系统状态下的关键帧选取策略。通过在起始位置增加关键帧的数量,避免了因子图优化后产生的定位跳变,从而得到连




图 8 KITTI 数据集各轴位移变化曲线

Fig. 8 Displacement curve of each axis of KITTI data set




图 9 KITTI 数据集的 APE 比较图

Fig. 9 APE comparison diagram of KITTI dataset

源消耗。同时,针对误差累积所导致回环检测失效,本文利用该关键帧策略,有效地增大当前帧的子关键帧集合,提高了回环检测算法的鲁棒性。针对 IMU 在长时间运行后高度方向上漂移过大的问题,本文根据提取的地面点构建地面约束,并引入因子图中进行优化。通过地面法向量与 z 轴夹角以及特征点的比例两个因素,判断是否引入地面约束。当机器人在水平地面移动时,将相邻关键帧 z 轴方向的位移建模为零均值的高斯分布。本文利用开发的移动机器人实验平台,完成了校园不同场景的数据采集,验证本文算法的有效性,并在 KITTI 数据集与 LIO-SAM 算法进行了对比测试,通过误差分析表明本文算法具有更优的定位精度。

参考文献

[1] KUBELKA V, REINSTEIN M, SVOBODA T. Tracked robot odometry for obstacle traversal in sensory deprived environment [J]. IEEE/ASME Transactions on Mechatronics, 2019, 24(6) : 2745-2755.


[2] CHEN Y, HUANG S, FITCH R. Active SLAM for mobile robots with area coverage and obstacle avoidance [J]. IEEE/ASME Transactions on Mechatronics, 2020, 25(3) : 1182-1192.

[3] XIA Q, LIU S, GUO M, et al. Multi-UAV trajectory planning using gradient-based sequence minimal optimization [J]. Robotics and Autonomous Systems, 2021, 137: 103728.

[4] PIAO J C, KIM S D. Adaptive monocular visual-inertial SLAM for real-time augmented reality applications in mobile devices [J]. Sensors, 2017, 17(11) : 2567.


[5] LI P, QIN T, HU B, et al. Monocular visual-inertial

续准确的位姿输出。完成初始化后,关键帧选取的位姿阈值会切换到另一种状态,以平衡关键帧过多引起的资



(a) 本文算法在KITTI数据集生成的点云图

(a) The point cloud map generated by the algorithm in the KITTI dataset is proposed in this paper



(b) LIO-SAM算法与本文算法的轨迹对比

(b) The trajectory comparison diagram between the LIO-SAM algorithm and the algorithm proposed in this paper

图 10 本文算法生成的点云图与轨迹对比

Fig. 10 The point cloud image and trajectory comparison image generated by the algorithm in this paper

state estimation for mobile augmented reality [C]. 2017 IEEE International Symposium on Mixed and Augmented Reality (ISMAR). IEEE, 2017: 11-21.

- [6] HOGG T, FREITAS JR R A. Acoustic communication for medical nanorobots [J]. Nano Communication Networks, 2012, 3(2): 83-102.
- [7] MA Q, KOBAYASHI E, SUENAGA H, et al. Autonomous surgical robot with camera-based markerless navigation for oral and maxillofacial surgery [J]. IEEE/ASME Transactions on Mechatronics, 2020, 25(2): 1084-1094.
- [8] 马争光, 赵永国, 刘成业, 等. 激光和视觉融合 SLAM 方法研究综述 [J]. 计算机测量与控制, 2019, 27(3): 1-6.

MA ZH G, ZHAO Y G, LIU CH Y, et al. Survey of SLAM with laser-camera fusion sensor [J]. Computer Measurement and Control, 2019, 27(3): 1-6.

- [9] DAVISON A J, REID I D, MOLTON N D, et al. MonoSLAM: Real-time single camera SLAM [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2007, 29(6): 1052-1067.
- [10] ZHOU Y, YAN F, ZHOU Z. Handling pure camera rotation in semi-dense monocular SLAM [J]. Visual Computer, 2019, 35(1): 123-32.
- [11] JI S, QIN Z, SHAN J, et al. Panoramic SLAM from a multiple fisheye camera rig [J]. ISPRS Journal of Photogrammetry and Remote Sensing, 2019, 159.
- [12] HU G, HUANG S, ZHAO L, et al. A robust RGB-D SLAM algorithm [J]. 2012 IEEE/RSJ International Conference on Intelligent Robots and Systems, 2012: 1714-1719.
- [13] MURPHY K, RUSSELL S. Rao-Blackwellised Particle Filtering for Dynamic Bayesian Networks [M]. Sequential Monte Carlo Methods in Practice. Springer, New York, NY, 2001.
- [14] MONTEMERLO M, THRUN S. Simultaneous localization and mapping with unknown data association using FastSLAM [C]. 2003 IEEE International Conference on Robotics and Automation (Cat. No. 03CH37422). IEEE, 2003, 2: 1985-1991.
- [15] MONTEMERLO M, THRUN S, KOLLER D, et al. FastSLAM 2.0: An improved particle filtering algorithm for simultaneous localization and mapping that provably converges [C]. IJCAI, 2003: 1151-1156.
- [16] 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.
- [17] JI Z, SINGH S. LOAM: Lidar odometry and mapping in real-time [C]. Robotics: Science and Systems Conference, 2014.
- [18] SHAN T, ENLOT 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). IEEE, 2019.
- [19] OPROMOLLA R, FASANO G, RUFINO G, et al. LIDAR-inertial integration for UAV localization and mapping in complex environments [C]. 2016 International Conference on Unmanned Aircraft Systems (ICUAS). IEEE, 2016: 649-656.
- [20] GENEVA P, ECKENHOFF K, YANG Y, et al. Lips: Lidar-inertial 3D plane SLAM [C]. 2018 IEEE/RSJ

- International Conference on Intelligent Robots and Systems (IROS). IEEE, 2018: 123-130.
- [21] GRAETER J, WILCZYNSKI A, LAUER M. Limo: Lidar-monocular visual odometry [C]. 2018 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS). IEEE, 2018: 7872-7879.
- [22] CHEN M, YANG S, YI X, et al. Real-time 3D mapping using a 2D laser scanner and IMU-aided visual SLAM[C]. 2017 IEEE International Conference on Real-time Computing and Robotics (RCAR). IEEE, 2017: 297-302.
- [23] XU Y, OU Y, XU T. SLAM of robot based on the fusion of vision and LIDAR [C]. 2018 IEEE International Conference on Cyborg and Bionic Systems (CBS). IEEE, 2018: 121-126.
- [24] CHAN S H, WU P T, FU L C. Robust 2D indoor localization through laser SLAM and visual SLAM fusion[C]. 2018 IEEE International Conference on Systems, Man, and Cybernetics (SMC). IEEE, 2018: 1263-1268.
- [25] GEIGER A, LENZ P, URTASUN R. Are we ready for autonomous driving? The kitti vision benchmark suite[C]. 2012 IEEE Conference on Computer Vision and Pattern Recognition. IEEE, 2012: 3354-3361.
- [26] KAESSE M, JOHANSSON H, ROBERTS R, et al. iSAM2: Incremental smoothing and mapping using the Bayes tree [J]. The International Journal of Robotics Research, 2012, 31(2): 216-235.
- [27] ZHENG F, LIU Y H. Visual-odometric localization and mapping for ground vehicles using SE (2)-XYZ constraints [C]. 2019 International Conference on Robotics and Automation (ICRA). IEEE, 2019: 3556-3562.
- [28] QUAN M, PIAO S, TAN M, et al. Tightly-coupled monocular visual-odometric SLAM using wheels and a mems gyroscope [J]. IEEE Access, 2019, 7: 97374-97389.

作者简介



邓鹏 (通信作者), 分别在 2005 年和 2008 年于内蒙古科技大学获得学士学位和硕士学位, 现为荆楚理工学院高级实验师, 主要研究方向为机器人工程、机电控制。

E-mail: dengpeng@jcut.edu.cn

Deng Peng (Correspondence author)

received his B. Sc. degree and M. Sc. degree from Inner Mongolia University of Science and Technology in 2005 and 2008 respectively. Now he is a senior experimenter in Jingchu University of Technology. His main research interests include robot engineering and electromechanical control.



罗静, 2012 年于湖北科技学院获得学士学位, 2015 年于武汉大学获得硕士学位, 2020 年于华中师范大学获得博士学位, 现为荆楚理工学院讲师, 主要研究方向为机器人工程、混沌控制、电机控制。

E-mail: luojing@jcut.edu.cn

Luo Jing received his B. Sc. degree from Hubei University of Science and Technology in 2012, M. Sc. degree from Wuhan University in 2015 and Ph. D. degree from Central China Normal University in 2020, respectively. Now he is a lecturer in Jingchu University of Technology. His main research interests include robot engineering, chaos control and motor control.