

DOI:10.19651/j.cnki.emt.2313585

一种改进回环的多传感器融合 SLAM 算法

马哲伟 周福强

(北京信息科技大学现代测控技术教育部重点实验室 北京 100192)

摘要: 针对无人车在室外大场景环境建图时,单一传感器的激光里程计推算位姿不准确且易随着累计漂移而产生精度下降的问题,本文提出了一种激光雷达与惯性单元 IMU 融合的激光惯性 SLAM 系统。系统前端由 IMU 信息进行点云去畸变处理,通过激光雷达里程计输出位姿。后端优化通过因子图实现,由前端里程计因子,IMU 预积分因子,回环检测因子联合优化。同时,基于全局描述符 Scan-Context 提出了一种改进的回环检测方法,能够有效提升回环检测的准确率。在公开数据集与无人车实验的实验结果表明,相比于经典的激光算法 A-LOAM,LeGO-LOAM,所提出的方法轨迹精度大约提升了 40% 左右,对于回环检测的效率提升了约 25%,有效的提高了 SLAM 系统的性能。

关键词: 无人车;激光 SLAM;多传感器融合;回环检测

中图分类号: TP2 文献标识码: A 国家标准学科分类代码: 510.1050

An improved loopback multi-sensor fusion SLAM algorithm

Ma Zhewei Zhou Fuqiang

(Key Laboratory of Modern Measurement & Control Technology Ministry of Education, Beijing Information Science & Technology University, Beijing 100192, China)

Abstract: A laser inertial SLAM system based on the fusion of lidar and inertial unit (IMU) is proposed to address the issue of inaccurate pose estimation using a single sensor laser odometer when unmanned vehicles are mapping in outdoor large scene environments, and the accuracy may decrease with accumulated drift. The front-end of the system is assisted by IMU information to remove distortion from the point cloud, and through point cloud registration, it forms a LiDAR odometer. The back-end optimization is realized by factor graph, which is jointly optimized by the front-end odometer factor, IMU pre Integrating factor and loopback detection factor. At the same time, this article proposes an improved fast loop detection method based on the global descriptor (Scan Context), which can effectively improve the accuracy and accuracy of loop detection while ensuring real-time performance. The results of publicly available datasets and unmanned vehicle experiments show that compared to the classic laser algorithms A-LOAM and LeGO-LOAM, the trajectory accuracy of the proposed method in this paper has been improved by about 40%, and the efficiency of loop detection has been improved by about 25%, effectively improving the performance of the SLAM system.

Keywords: unmanned vehicle; laser SLAM; multi-sensor fusion; loop detection

0 引言

同步定位与建图算法 (simultaneous localization and mapping, SLAM)^[1] 广泛应用于无人车、自动驾驶领域,在机器人和军事领域也有广泛应用。其利用高精度传感器,为无人车在未知环境中进行地图构建,为其他功能提供先决条件,如自主避障、路径规划等。近年来,随着自动驾驶的技术的不断发展,关于 SLAM 算法的热度也是不断上升,定位与建图效果也随之不断优化。

SLAM 通过传感器获取的数据进行地图构建。常用

的传感器包括相机、激光雷达 (Lidar) 以及惯性测量单元 (inertial measurement unit, IMU)。目前典型的 SLAM 方案主要是基于视觉和激光雷达的。基于视觉 SLAM 的算法包括 ORB-SLAM^[2-3] 系列,其利用摄像头作为主要的传感器,也可结合 IMU 惯性单元,其特点是摄像头成本低且易于安装,但其缺点也很明显,在阴暗环境下难以发挥其作用。基于激光 SLAM 的算法主要包括 LOAM (lidar odometry and mapping in real-time)^[4] 系列,激光雷达凭借其高精度且不受光照影响的特点,能够精准获取环境中 3D 信息。其缺点是在室外开阔环境中,会缺失一部分点。

由 Zhang 等^[4]在 2014 年提出的 LOAM 算法用于激光雷达定位与三维建图,采用了基于曲率的点面特征匹配,是建图效果较好的一种算法,但由于其没有融合 IMU 信息,在高速旋转的情况下容易导致系统失效。2018 年,Shan 等^[5]在 LOAM 算法的基础上,提出 LeGO-LOAM (lightweight and group-optimized lidar odometry and mapping on variable terrain),采用松耦合的方式对 IMU 信息进行了融合,同时结合广度优先遍历算法进行了地面点的去除,同时增加了回环检测模块;但由于其采用松耦合的方式,导致对传感器的利用不够充分。2019 年,Liu 等实现了一种紧耦合的激光惯性系统,简称 LIO-Mapping^[6],但该算法比较耗时。2020 年,Shan 等^[7]提出了 LIO-SAM (lightweight and group-optimized lidar odometry and mapping on variable terrain),该算法紧耦合了 IMU 信息、GPS 信息,同时采用基于邻域搜索的回环检测算法,在大场景建图有着不俗的效果,但其在长走廊或隧道等缺乏单个或多个自由度信息时,容易导致算法失效^[8]。2022 年,Wang 等^[9]提出了一种基于图优化的紧耦合双目视觉/惯性/激光雷达 SLAM 方法(S-VILSLAM),基于滑动窗口实现了多源数据联合非线性优化,相比于视觉里程计和激光里程计其性能都有所提升。

针对回环检测,2016 年,Shan 等提出的基于邻域搜索的回环检测,其实现起来相对容易,但在大场景的建图中,随着累计漂移的增加,容易出现回环失败的情况。2018 年,Kim 等^[10]提出了一种扫描上下文的 Scan-Context^[10]算法,该算法不依赖直方图和先验信息,来实现回环帧的搜索和匹配,但其仅保留点云的最大高度,丢失了大量的信息。2020 年,Wang 等^[11]提出了一种 Lidar-Iris^[11]算法,该算法针对 Scan-Context 的不足进行了改进,解决其只利用最大高度的问题,其性能远高于 Scan-Context。2022 年,徐晓芬等^[12]在 Scan-Context 和 Lidar-Iris 的基础上,通过残差项加权的特征匹配,实现了一种快速回环检测方法,有效提升了回环检测的速度和精度。2023 年,周治国等^[13]提出了一种基于强度扫描上下文的回环检测方法,其充分利用了点云的几何信息和强度信息,提升了回环检测的性能。

针对于室外场景下激光 SLAM 建图精度不足的问题,本文基于激光雷达与 IMU 融合提出了一种算法优化方案。研究内容包括:

1)以 LOAM 算法为基础,融合 IMU 信息,对原始点云数据进行去畸变处理,对激光雷达里程计进行初始化,后端使用因子图优化,对里程计约束、IMU 约束以及回环检测约束进行联合优化,提升了后端建图的精度。

2)提出了一种改进的回环检测方法,针对传统的基于邻域搜索的回环检测算法存在回环失败的情况,本文在 Scan-Context 的基础上,结合词袋模型提出了一种回环检测方案,大大提升了系统回环检测的效果和精度。

3)在移动机器人平台上进行了实验部署,实验表明,在

室外大场景建图中,本算法能够保持较高的建图精度。对于轨迹的优化及精度较 A-LOAM (adaptive robustness analysis based on LOAM algorithm)、LeGO-LOAM 等经典激光算法有很大提升。

1 多传感器融合 SLAM 系统设计

1.1 系统概述

LOAM 算法为激光雷达定位与建图的经典算法之一。其前端采用一个高频率低精度的激光雷达里程计来简单估计位姿,采用一个低频率高精度的后端来进行位姿优化和地图构建。本文在原始 LOAM 的基础上进行了改进,主要包括以下几个部分:1)前端数据预处理部分:主要包括点云去畸变、边缘点与面点的提取、点云匹配和 IMU 预积分等部分。2)后端状态估计部分:利用前端提供的各种约束信息以及回环检测约束,使用因子图优化求解最佳位姿估计。3)回环检测部分:基于 Scan-Context 与词袋模型结合的回环检测模块。系统整体框架如图 1 所示。

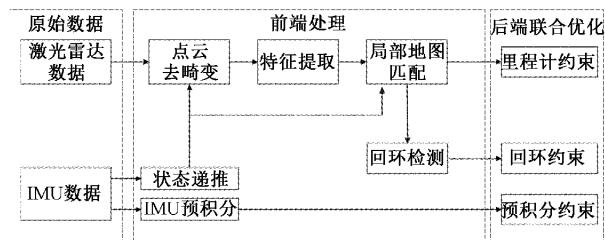


图 1 系统流程图

1.2 前端处理

前端处理包括激光雷达数据和 IMU 数据的预处理。对于激光雷达的数据,通过 IMU 数据进行点云的去畸变处理、特征提取与点云匹配,构成激光雷达里程计。对于 IMU 数据处理,通过状态递推对激光里程计进行运动补偿,以及为后端优化提供一个良好的初始估计和 IMU 预积分的约束。

1) 激光雷达里程计

(1) 点云去畸变处理

从激光雷达获取的原始点云数据是过去一个周期内的数据,而非某个时刻的数据。但数据仅有一个时间戳,因此在过去这一周期的点云数据便会因为激光雷达的运动而导致这一帧的原点不在同一位置,这就产生了运动畸变。此时就需要对点云数据进行运动补偿。运动补偿的目的就是把所有的点云数据补偿到某一时刻,最常见的补偿到开始时刻:

$$P_{\text{start}} = T_{\text{start_current}} \times P_{\text{current}} \quad (1)$$

其中, P_{start} 和 P_{current} 分别为起始位置与当前点的位置, $T_{\text{start_current}}$ 前点位置到起始位置的变换矩阵。在 LOAM 中, 使用匀速模型假设, 使用上一帧里程计的结果来当作前两帧之间的运动, 同时也假设当前帧也是匀速运动, 以此来估计出每个点相对于起始时刻的位姿。本算法采用 IMU 提供的

帧间位姿信息来求解变换矩阵 $T_{\text{start_current}}$ 。

(2) 特征匹配

对于去畸变的点云数据,通过提取特征,点云配准形成激光雷达里程计。对于特征提取,采用 LOAM 中的点面特征来描述。通过计算一个点在空间中曲率(curvature)来判断其是边缘点还是面点。如式(2)所示,通过曲率来描述局部表面的平滑程度,假设有某一点 i, S 存在一个点集, $X_{(k,i)}$ 表示当前点的坐标, $X_{(k,j)}$ 表示近邻点的坐标:

$$c = \frac{1}{|S| \cdot \|X_{(k,i)}\|} \left| \sum_{j \in S, j \neq i} (X_{(k,i)} - X_{(k,j)}) \right| \quad (2)$$

若 c 值大于给定阈值,则代表当前点与周围点的差距过大,曲率较高,则为边缘点,反之则为面点。

当提取到足够的特征点后,需要寻求特征点之间的匹配关系。本文算法采用匹配效率更高的点-线、点-面特征匹配,大大减少了计算量。

2) IMU 数据预处理

IMU 可以提供当前时刻的运动状态信息,包括角速度和加速度,通过这些信息可以推算出系统的位置、速度、姿态等状态。

连续两个关键帧的状态传递方程如下:

$$\begin{cases} P_{b_{k+1}}^w = P_{b_k}^w + v_{b_k}^w \Delta t_k + \int_{t \in [t_k, t_{k+1}]} [R_t^w (\hat{a}_t - b_{a_t}) - g^w] dt \\ (R_t^w (\hat{a}_t - b_{a_t}) - g^w) dt^2 \\ v_{b_{k+1}}^w = v_{b_k}^w + \int_{t \in [t_k, t_{k+1}]} (R_t^w (\hat{a}_t - b_{a_t}) - g^w) dt \\ q_{b_{k+1}}^w = q_{b_k}^w \otimes \int_{t \in [t_k, t_{k+1}]} \frac{1}{2} \Omega(\omega_t - b_{\omega_t} - n_\omega) q_t^{b_k} dt \end{cases} \quad (3)$$

$$\Omega(\omega) = \begin{bmatrix} -[\omega]_x & \omega \\ -\omega^T & 0 \end{bmatrix}, [\omega]_x = \begin{bmatrix} 0 & -\omega_z & \omega_y \\ \omega_z & 0 & -\omega_x \\ -\omega_y & \omega_x & 0 \end{bmatrix}$$

其中, $P_{b_k}^w$ 关键帧 b_k 在世界坐标系下的位置, $v_{b_k}^w$ 关键帧 b_k 在世界坐标系下的速度, $q_{b_k}^w$ 键帧 b_k 在世界坐标系下的姿态, R_t^w 表示当前时刻到世界坐标系的位姿变换,为当前时刻的角速度测量值, b_i 表示零偏, n_ω 表示噪声值。

从上述公式可以看出,当 k 时刻的状态发生变化时,通过 IMU 积分得到的 $k+1$ 时刻的状态也发生改变,而在基于因子图的后端中,对一些状态量的调整是必然的,因此就需要通过预积分理论对这一问题进行解决。参考式(3),等号两边同时乘上 $P_w^{b_k}$ 可得到式(4)。

$$\begin{cases} R_w^{b_k} P_{b_{k+1}}^w = R_w^{b_k} \left(P_{b_k}^w + v_{b_k}^w \Delta t_k - \frac{1}{2} g^w \Delta t_k^2 \right) + \alpha_{b_{k+1}}^{b_k} \\ R_w^{b_k} v_{b_{k+1}}^w = R_w^{b_k} (v_{b_k}^w - g^w \Delta t_k) + \beta_{b_{k+1}}^{b_k} \\ q_{b_k}^{b_k} \otimes q_{b_{k+1}}^w = \gamma_{b_{k+1}}^{b_k} \end{cases} \quad (4)$$

$$\text{其中, } \alpha_{b_{k+1}}^{b_k} = \iint_{t \in [t_k, t_{k+1}]} [R_t^{b_k} (\hat{a}_t - b_{a_t})] dt^2$$

$$\beta_{b_{k+1}}^{b_k} = \int_{t \in [t_k, t_{k+1}]} [R_t^{b_k} (\hat{a}_t - b_{a_t})]$$

上面 3 个即预积分变量,可以发现,这 3 个预积分变量都与 k 或者 $k+1$ 时刻的状态量无关,因此当 k 时刻的状态发生变化时,将不需要对 IMU 的数据进行重新积分。从上述公式可知,IMU 预积分约束着相邻两帧的状态量。在 SLAM 问题中,IMU 预积分约束通常同其他约束一起构建一个优化问题,其建模如图 2 所示。

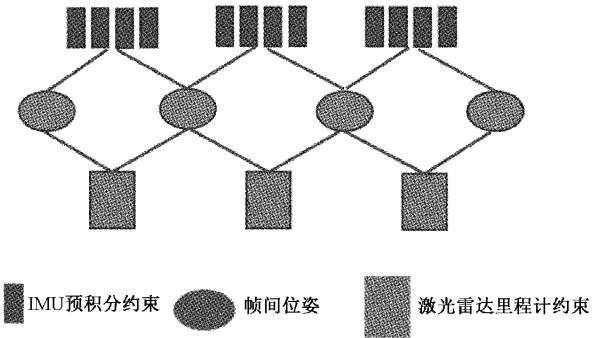


图 2 IMU 预积分建模

如图 2,矩形代表 IMU 预积分约束,椭圆代表帧间位姿,宽矩形代表激光雷达里程计的帧间约束。由于 IMU 的频率较高,可将一个周期内的 IMU 预积分数据整合到一起,作为 IMU 的帧间约束。

1.3 后端优化

在取得前端获取的数据时,后端优化模块会使用因子图优化^[14]的方式对系统前端所提供的约束进行状态估计和位姿优化。因子图是一个将具有全局变量的全局函数因子分解,得到几个函数的乘积,并以此为基础得到一个双向图。其内部使用一种基于概率的贝叶斯树,使得每次给因子图增加一个约束时,会根据贝叶斯树的连接关系,调整和当前节点关系比较密切的节点,最后得出最佳估计。

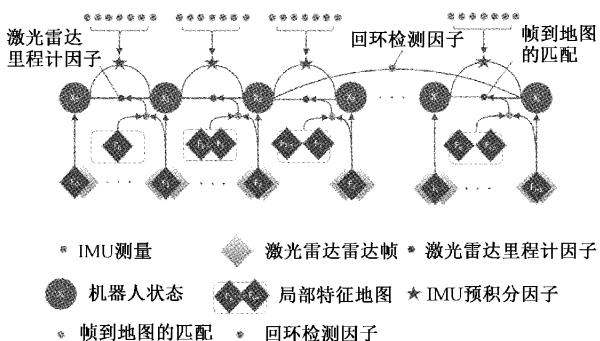
记世界坐标系为 W ,机器人坐标系为 B 。机器人 x 的状态为:

$$x = [R^T, p^T, v^T, b^T]^T \quad (5)$$

其中, R 是旋转矩阵, p 是位置向量(origin 到机器人位置的向量), v 是速度, b 是 IMU 偏移。对一个机器人的状态估计问题是一个最大后验问题(MAP)(等价于求解非线性最小二乘)。本文引入 3 种因子:

- 1) IMU 预积分因子
- 2) 激光雷达里程计因子
- 3) 回环检测因子

当机器人位姿变化超过阈值,添加新的机器人状态 x 到因子图中,使用 iSAM2^[15] 进行优化。后端系统建模如图 3 所示。



1) IMU 因子与激光雷达里程计因子

IMU 是多传感器融合 SLAM 算法常用的传感器, 其利用自身的陀螺仪和加速度计, 可以精确的估计段时刻内的位姿, 对于激光雷达来说是一个很好的补充。

相对于激光雷达, IMU 是一个高频传感器, 其采样频率通常为 100~1 000 Hz, 远高于激光雷达。如果将一个周期内的 IMU 数据全部进行预积分, 计算量是非常大的, 会很大程度的影响计算速度, 因此本文考虑更好的做法是相隔 Δt 时间再提取 IMU 数据。对于提取的 IMU 数据, 在经过前端处理后, 得到的预积分约束加入因子图中进行联合优化。

基于状态估计的后端可以对 IMU 信息和激光雷达的信息进行联合优化。但在某些特殊情况下, IMU 数据会存在偏差, 因此, 本文设置了失效检测来避免这一情况。假设我们当前接收的最新的激光雷达里程计计算出来的位姿 T_i^w 和 IMU 推算的帧间位姿 $T_i^{w'}$, 只有当 T_i^w 与 $T_i^{w'}$ 之间的相对误差保持在一定范围内时, 才将预积分约束加入后端因子图中, 大大的提高了系统的鲁棒性。

2) 回环检测因子

传统的回环检测使用基于迭代最近点 (iterative closest point, ICP) 匹配耗时长, 严重影响 SLAM 系统的实时性。故本文在 Scan-Context 的基础上进行创新, 提出一种快速的回环检测方法, 在保证系统实时性的同时, 有效的降低了里程计的累计漂移误差。其算法步骤如下:

(1) 提取描述子

采用圆环分区的方式, 将三维空间的点云信息转换为二维空间的矩阵。对于某一帧点云信息, 以激光雷达为原点极坐标系, 设置最大搜索距离为 d_{max} , 以最大搜索范围 d_{max} 为半径, 将半径为 d_{max} 的圆划分为 N_r 个圆环, N_s 个扇区, 这样就构成了一个 $N_r \times N_s$ 的二维矩阵, 并将当前点云在每个区域内最大高度作为矩阵的值。如图 4 所示, 矩阵中的颜色表示特征点的最大高度。

(2) 获取候选的回环帧

在最优帧的选取采用词袋模型^[16-17]的思路。词袋模型主要是由字典与单词构成, 字典对应所有候选的回环帧, 单词则来自于每一帧中的描述符。由于采用的是 Scan-

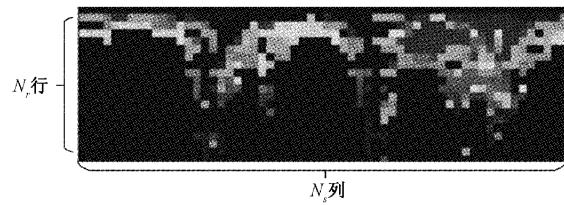


图 4 Scan-Context 描述子

context 描述子, 将单帧的点云分成了 $N_r \times N_s$ 块, 同时由于环向量的旋转不变性, 即同时位置无论激光雷达怎么旋转, 其环行数都不会改变, 因此本文将环向量作为基本单位, 构建单词向量。由于环向量是稀疏的, 需要对其进行稀疏编码, 采用 L_0 范数来表示稀疏特征。则描述子计算方式如下:

$$k_i = \frac{\|N_i\|_0}{N_s} \quad (6)$$

其中, $\|N_i\|_0$ 圆环 N_i 零元素的数目, N_s 环数, k_i 表示圆环 N_i 的单词描述子。这样一个单词向量就可以表示为:

$$\mathbf{K} = [k_1, k_2, k_3 \dots k_{N_r}]^\top \quad (7)$$

由于单词 \mathbf{K} 是一个 $N_r \times 1$ 的矩阵, 故可以采用 KD-Tree 的结构, 来计算两个单词的相似度, 选取合格的回环帧。

(3) 回环帧选取

基于两帧间的位姿变换作为判断标准, 以剔除空间上距离较远的回环帧。记 \mathbf{T}_p^w 为当前点云到世界坐标系的位姿变换, \mathbf{T}_L^w 为候选的回环帧到世界坐标系的位姿变换, 则当前帧与回环帧之间的位姿变换计算如下:

$$\mathbf{T}_L^p = (\mathbf{T}_p^w)^{-1} \cdot \mathbf{T}_L^w \quad (8)$$

设置阈值 d_{thre} , 其根据实际地图的大小进行设置。其次计算两帧之间的欧式距离 d , 选取位姿 \mathbf{T}_L^p 中的平移量 t , 则:

$$d = \sqrt{t_x^2 + t_y^2 + t_z^2} \quad (9)$$

其中, t_x, t_y, t_z 为分别为当前帧与回环帧在 x 轴、 y 轴和 z 轴的平移分量, 若满足 $d < d_{thre}$ 的即为选取的回环帧。

(4) 求解位姿

对于提取到的当前点云 P 与点云 Q , 由基于点面特征的特征匹配, 根据边缘点到最近一帧中边缘点所构成的线的距离和面点到最近一帧中面点所构成的面的距离构建目标函数, 如式(9)所示, 通过 L-M 求解。并以四元数的形式加入到后端因子图中进行联合优化, 更新位姿。

$$\begin{aligned} Loss = & \sum distance(point, map) = \\ & \sum_i distance(surPoint_i, map) + \\ & \sum_i distance(cornerPoint_i, map) \end{aligned} \quad (10)$$

其中, $distance(surPoint_i, map)$ 为当前的点线距离残差, $distance(cornerPoint_i, map)$ 为当前点的点面距

离残差。

2 实验结果及分析

实验采用公开数据集与无人车室外实验来对本文所提算法的性能和回环的效果进行测试。同时与经典激光算法 A-LOAM、LeGO-LOAM 进行对比分析,得出结论。公开数据集采用 KITTI 数据集的 00、07 等带回环的序列,且由于其提供 GPS 获取的真实轨迹,对于算法性能测试具有真实性与可靠性。无人车室外实验采用装配有 32 线速腾激光雷达与 IMU 的无人车,在校园环境下进行数据采集与建图。

2.1 公开数据集下的实验验证

首先,在 00 序列下测试算法的轨迹误差。KITTI 数据集的 00 序列全长 3 682 m,帧数为 4 544 帧,时长 471 s。由于其行驶轨迹较长,且带有多个回环,能够较好的验证算法的性能。图 5 为本文算法在 00 序列上的轨迹与真实轨迹的对比,图 6、7 分别为本文算法与真实轨迹的绝对误差和相对误差。可以看出,与 KITTI 数据集的真实轨迹相比,本文算法的平均绝对误差保持 2.1 m 左右,相对误差保持在 1.2% 左右,从图 6、7 可以看出,在初始的一段时间内,轨迹误差能够保持在一定范围,随着累计漂移的增加,误差随之增大,但可以看出,在 250 s 与 300 s 时刻,由于系统检测到回环,对轨迹进行优化,使得误差相对减小,能够证明本文所提出的算法在大规模的场景下依旧能够保持一定的轨迹一致性与较好的建图精度。

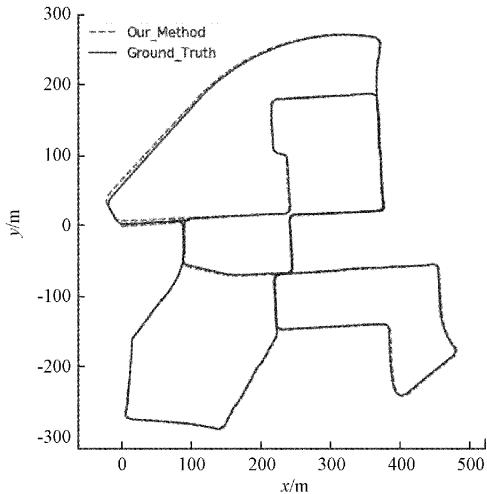


图 5 00 序列轨迹对比图

此外,为验证本文算法相较于传统激光算法的优越性,本文在 07 序列与 park 数据集上分别与经典的激光算法 A-LOAM、LeGO-LOAM 进行轨迹对比和误差分析。图 8(a)、(b) 分别为本算法在不同数据集上的轨迹对比。在图 8(a) 中,证明本文方法在 KITTI 数据集上的良好表现与回环检测的有效性。在图 8(b) 中,由于 LeGO-LOAM

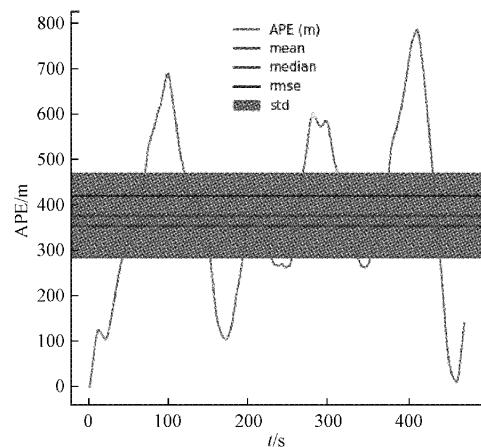


图 6 00 序列绝对轨迹误差

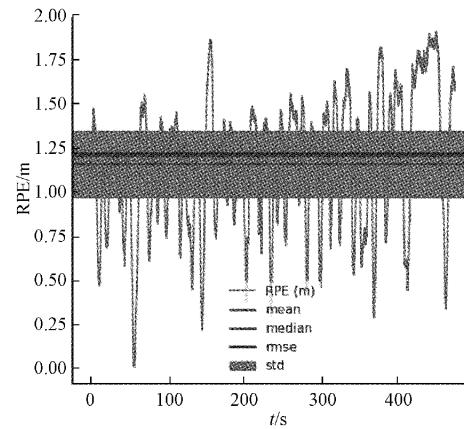


图 7 00 序列相对轨迹误差

算法采用的基于邻域搜索的回环检测,以至于在起始阶段并不存在回环的情况下,导致系统出现误匹配的情况发生,本文算法有效的避免了这一情况;同样,由于 A-LOAM 算法没有回环检测模块,导致系统随着累计误差的不断增大,轨迹漂移越来越严重;同时,算法紧耦合了 IMU,对短时间的位姿进行实施优化和调整,从而使得本文算法与真实轨迹的误差相对较小。

从表 1 中的数据可以看出,除在 KITTI 数据集表现良好的 A-LOAM 算法之外,本文算法在数据集的误差均小于表中的方法。相对于 A-LOAM 算法,本文算法的绝对轨迹精度提升了 34% (均方根值);相对于 LeGO-LOAM 算法,本文算法的绝对轨迹精度提升了 47% (均方根值)。

2.2 无人机实验验证

无人机实验采用装配有 32 线激光雷达与六轴 IMU 的无人机在校园环境下进行建图,实验设备如图 9 所示。

本文选取校园环境下绕行建筑一周进行建图分析,建图效果如图 10 所示。图 11(a) 为单一传感器激光算法,在行驶距离较远时刻出现了角度漂移,本算法在融合 IMU 之后,如图 11(b) 所示,建图的角度修正比较准确,能

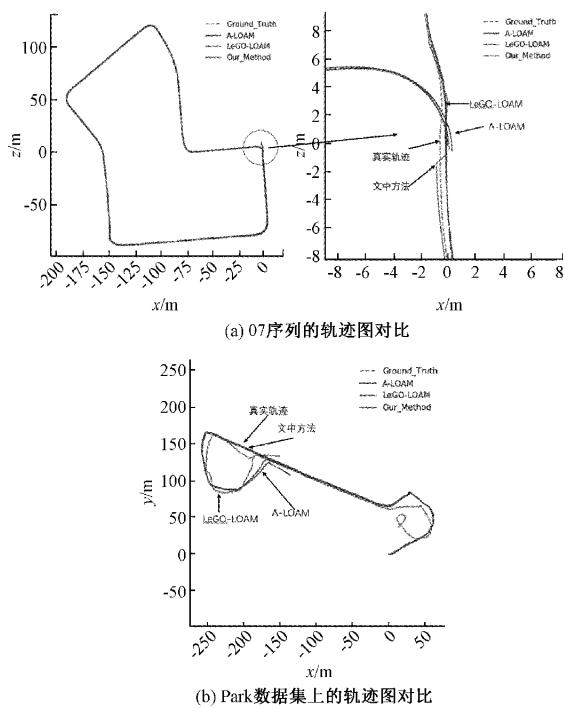


图 8 算法在不同数据集上的轨迹对比

够准确的反应车辆的角度变化。图 11(c)为无人车的行驶轨迹在卫星地图上的投影,验证了本算法的准确性与实用性。

2.3 回环检测实验

1) 回环检测实验说明

SLAM 回环检测的性能常用准确率(Precision)和召回率(Recall)这两个参数来评估。如表 2 所示,准确率是指所检测到的回环中真实回环的个数,召回率是指系统中真实回环被检测到的概率。计算公式如下:

$$Precision = \frac{TP}{TP + FP} \quad (11)$$

$$Recall = \frac{TP}{TP + FN} \quad (12)$$

2) 回环检测实验结果与分析

回环检测实验采用自制数据集与公开数据集相结合来测试回环检测的性能,并与 LeGO-LOAM 的回环结果相比。回环检测基于 Scan-Context 进行改进,具有旋转不变性,能更准确的筛选出候选的回环帧。如表 3 所示,算法相对于 LeGO-LOAM 算法,回环检测的准确率平均提高了约 22%,召回率平均提高了约 27%。

表 1 数据集下本文方法与主流方法的误差对比

方法	A-LOAM	LeGO-LOAM	本文方法
07 序列 APE/m	最大值	1.083 204	1.396 858
	平均值	0.597 785	0.734 234
	中间值	0.608 939	0.673 880
	最小值	0.182 744	0.214 429
	均方根	0.647 947	0.779 729
	标准差	0.249 976	0.262 446
Park 数据 APE/m	最大值	8.021 685	43.30 205
	平均值	2.426 941	13.34 816
	中间值	1.812 980	9.143 857
	最小值	0.664 493	1.958 496
	均方根	2.985 111	17.33 641
	标准差	1.738 058	11.06 392
07 序 RPE/%	最大值	1.719 573	4.870 851
	平均值	0.894 658	1.798 714
	中间值	0.998 276	1.989 908
	最小值	0.001 316	0.002 504
	均方根	1.000 792	2.017 944
	标准差	0.448 522	0.914 727
Park 数据 RPE/%	最大值	0.413 225	3.315 914
	平均值	0.064 156	0.500 869
	中间值	0.054 131	0.441 876
	最小值	0.001 604	0.000 552
	均方根	0.078 607	0.568 180
	标准差	0.045 421	0.268 251

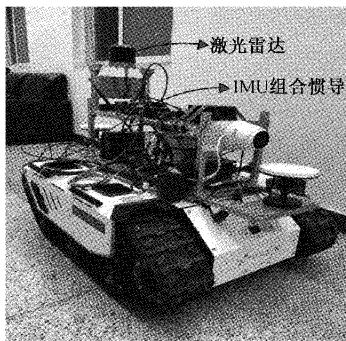


图 9 实验设备

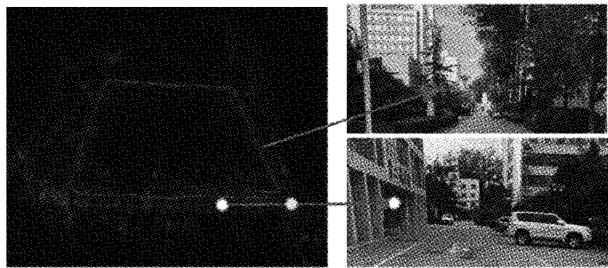


图 10 校园环境建图

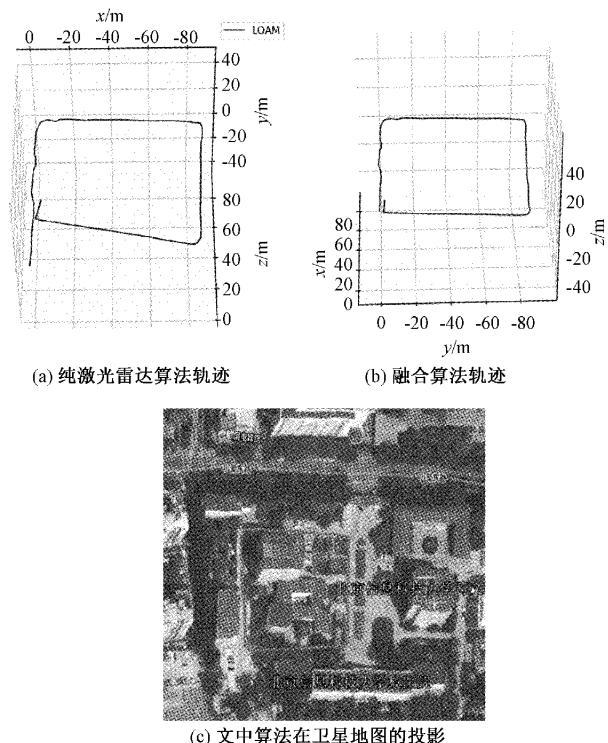


图 11 校园环境轨迹对比

表 2 回环检测参数评估

算法/真实	有回环	无回环
有回环	TP	FP
无回环	FN	TN

表 3 回环检测结果对比

数据集	LeGO-LOAM		本文方法	
	准确率	召回率	准确率	召回率
Park	0/2	0/1	1/1	1/1
00 序列	5/5	5/7	6/6	6/7
自制数据集 1	1/1	1/1	1/1	1/1
自制数据集 2	1/1	1/2	2/2	2/2

3 结 论

针对传统激光 SLAM 算法在室外大场景建图时,易随着累计漂移的增加而导致系统精度降低的问题,提出了一种带回环的紧耦合 IMU 的激光 SLAM 算法。系统前端由 IMU 提供的位姿信息进行点云去畸变,后端采用因子图的方式融合 IMU 预积分约束联合优化位姿。回环检测基于 Scan-Context 描述子进行改进,结合词袋模型,大大提高了回环检测的效率。经实验验证,所提出的方法对于轨迹的优化提升了 40% 左右,对回环的优化提升了 25% 左右。本研究基于 LOAM 算法,在长隧道或长走廊环境中,容易导致系统失效。在未来工作中,针对于融合视觉传感器的 SALM 研究,可进一步提高融合 SLAM 系统的稳定性。

参考文献

- [1] 余联想,郑明魁,欧文君,等.多传感器融合的移动机器人室外激光 SLAM 算法优化与系统实现[J].电子测量与仪器学报,2023,37(2):48-55,DOI:10.13382/j.jemi.B2205747.
- [2] MUR-ARTAL R, TARDÓSJUAN D. ORB-SLAM2: An open-source SLAM system for monocular, stereo, and RGB-D cameras [J]. IEEE Transactions on Robotics,33(5):1255-1262.
- [3] CAMPOS C, ELVIRA R, RODRÍGUEZ J J G, et al. Orb-slam3:An accurate open-source library for visual, visual-inertial, and multimap slam [J]. IEEE Transactions on Robotics,2021,37(6):1874-1890.
- [4] ZHANG J, SINGH S. Low-drift and real-time lidar odometry and mapping [J]. Autonomous Robots,2017,41(2):401-416.
- [5] SHAN T, 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), Spain, October 01-05, 2018: 4758-4765.
- [6] 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.

- [7] SHAN T, 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), IEEE, 2020: 5135-5142.
- [8] 李荣华,祁宇峰,谢辉,等.面向未知环境的紧耦合激光 SLAM 方法[J/OL].红外与激光工程:1-11[2023-04-17].<http://kns.cnki.net/kcms/detail/12.1261.TN.20230324.1346.002.html>.
- [9] 王铉彬,李星星,廖健驰,等.基于图优化的紧耦合双目视觉/惯性/激光雷达 SLAM 方法[J].测绘学报,2022,51(8):1744-1756.
- [10] KIM G, KIM A. Scan context: Egocentric spatial descriptor for place recognition within 3d point cloud map[C]. 2018 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS), Spain, October 01-05, 2018: 4802-4809.
- [11] WANG Y, SUN Z, XU C Z, et al. Lidar iris for loop-closure detection [C]. 2020 IEEE/RSJ International Conference on Intelligent Robots and Systems(IROS). USA, October 25-29, 2020: 5769-5775.
- [12] 徐晓苏,李诺,姚逸卿.基于快速回环检测的室外环境下激光雷达 SLAM 算法[J].中国惯性技术学报,2022, 30 (6): 716-722, DOI: 10.13695/j.cnki.12-1222/o3. 2022.06.003.
- [13] 周治国,邸顺帆.基于强度扫描上下文回环检测的激光雷达 SLAM 算法[J].中国惯性技术学报,2022, 30(6): 738-745, DOI: 10.13695/j.cnki.12-1222/o3. 2022.06.006.
- [14] 姚祖威,刘宇,郭俊启,等.基于因子图的自主导航多源异构信息融合算法[J].电子测量技术,2021,44(1): 130-134,DOI:10.19651/j.cnki.emt.2005641.
- [15] 郑川川,柯福阳,汤琴琴.基于图优化的激光惯导紧耦合 SLAM 研究[J].电子测量技术,2023,46(1):35-42, DOI:10.19651/j.cnki.emt.2210278.
- [16] 刘焕钊,蒋林,郭宇飞,等.基于三维点云转换视觉图像的回环检测算法[J].组合机床与自动化加工技术,2023, 590 (4): 91-95, 99, DOI: 10.13462/j.cnki.mmtamt.2023.04.021.
- [17] 赵哲.基于回环检测的激光 SLAM 算法研究及其移动机器人应用[D].武汉:华中师范大学,2022.

作者简介

马哲伟,硕士研究生,主要研究方向为机电系统智能感知与控制。

E-mail:1256603559@qq.com

周福强(通信作者),研究员,主要研究方向为机电系统智能感知与控制。

E-mail:fuqiangzhou@126.com