

DOI:10.19651/j.cnki.emt.2210278

# 基于图优化的激光惯导紧耦合 SLAM 研究<sup>\*</sup>

郑川川<sup>1,4</sup> 柯福阳<sup>2,4</sup> 汤琴琴<sup>3</sup>

(1.南京信息工程大学自动化学院 南京 210000; 2.南京信息工程大学遥感与测绘学院 南京 210000;  
3.无锡学院轨道交通学院 无锡 214000; 4.南京信息工程大学无锡研究院 无锡 214000)

**摘要:**现有的激光惯导里程计大多采用滤波的松耦合融合方法,在大场景建图中会存在一定的运动估计漂移,导致定位与建图精度降低。针对这一问题提出了一种基于图优化的激光惯导紧耦合里程计与建图方法。在前端依次进行点云畸变补偿、点云聚类分割、地面与特征提取。在后端采用图优化方法融合 IMU 预积分、激光里程计和回环检测信息完成地图构建。最后利用 Kitti 数据集和自采集数据对 LOAM、LeGO-LOAM 和本文方法在里程计精度和回环检测效果上进行了对比分析。实验结果表明本文方法在定位与建图精度上相比于 LOAM 和 LeGO-LOAM 分别提高了 45% 和 35% 以上,有着更优的鲁棒性。

**关键词:**激光惯导;图优化;紧耦合;定位与建图

中图分类号: TP391.9 文献标识码: A 国家标准学科分类代码: 510.99

## Tightly coupled SLAM for laser inertial navigation based on graph optimization

Zheng Chuanchuan<sup>1,4</sup> Ke Fuyang<sup>2,4</sup> Tang Qinjin<sup>3</sup>

(1. School of Automation, Nanjing University of Information Engineering, Nanjing 210000, China;  
2. School of Remote Sensing and Surveying and Mapping, Nanjing University of Information Engineering,  
Nanjing 210000, China; 3. School of Rail Transit, Wuxi University, Wuxi 214000, China;  
4. Nanjing University of Information Engineering, Wuxi Research Institute, Wuxi 214000, China)

**Abstract:** Most of the existing laser inertial navigation odometers adopt the filtering loose coupling fusion method, and there will be a certain motion estimation drift in large scene mapping, which will lead to the reduction of positioning and mapping accuracy. Aiming at this problem, a close-coupled odometer and mapping method of laser inertial navigation system based on graph optimization is proposed. At the front end, point cloud distortion compensation, point cloud clustering segmentation, ground and feature extraction are carried out in turn. At the back end, the map optimization method is used to integrate IMU pre-integration, laser odometer and loop detection information to complete the map construction. Finally, Kitti data set and self-collected data are used to compare and analyze LOAM, LeGO-LOAM and the method of this paper in odometer accuracy and loop detection effect. Experimental results show that compared with LOAM and LeGO-LOAM, the positioning and mapping accuracy of this method is improved by 45% and 35% respectively, and it has better robustness.

**Keywords:** laser inertial navigation; graph optimization; tight coupling; localization and mapping

## 0 引言

同时定位与地图构建(simultaneous localization and mapping, SLAM)技术是移动机器人实现自主导航的关键。其中基于三维 Lidar 的 SLAM 技术可以为移动机器人提供

更加丰富的 3D 环境信息<sup>[1]</sup>,相比于视觉 SLAM 抗干扰能力强、不受光线影响、测距精度高,更能满足机器人环境感知和智能发展的需求。但仅依靠单一激光传感器进行状态估计,在大场景建图中随着距离和时间的增加会产生一定的累计误差导致较大的漂移,影响定位和建图的精度。目

收稿日期:2022-06-10

\* 基金项目:第十六批次江苏省“六大人才高峰”高层次人才项目(XYDXX-045)、2020 年无锡市科技发展资金(N20201011)、南京信息工程大学无锡校区研究生创新实践项目(WXCX202020)资助

前多传感器融合的三维激光 SLAM 技术,已经成为一个热门方向。通过多传感器融合技术可以将各自的优势组合起来实现高精度的三维建图与导航功能<sup>[2]</sup>。

近年来国内外学者在多传感器融合和三维激光 SLAM 领域作了大量研究,取得了一定程度上的进步。2014 年 Zhang 等<sup>[3]</sup>提出了一种低漂移和实时性的激光雷达里程计(lidar odometer and mapping,LOAM),是目前比较流行的几大激光建图方法,但该方法也存在一定局限性,在特征丰富的场景中由于没有闭环检测功能其优化效率会降低。2018 年 Shan 等<sup>[4]</sup>提出了一种轻量级地面优化的激光里程计(lightweight and ground optimized lidar odometry and mapping, LeGO-LOAM),在特征提取前做了分割和聚类,并对水平和航向分别做了优化,但它是一种松耦合的惯性激光里程计在大环境中其建图精度会有一定下降。2019 年 Ye 等<sup>[5]</sup>提出了一种融合 IMU 数据和 Lidar 数据的紧耦合建图算法(lidar inertial odometry mapping,LIOM),相比于松耦合方法在建图精度上会有明显提升,但它是一种基于滑动窗口的优化方法,随着建图距离的不断增加需要优化的窗口参数也不断增加,导致累计误差越来越大。2020 年 Shan 等<sup>[6]</sup>提出了一种平滑和映射的激光雷达惯性里程计(lidar inertial odometry via smoothing and mapping,LIO-SAM),将各种不同相对和绝对测量因子加入到系统中,选择性的引入关键帧与地图进行匹配,提高了系统实时性能,但该方法会随着各种因子的不断加入,系统运算量会大大增加。2021 年文献[7]提出了一种融合滤波与图优化的 SLAM 系统,在前端用滤波的方法对惯性测量单元(inertial measurement unit,IMU)和激光里程计做粗配准,在后端用图优化方法结合地面约束因子对位姿进行优化,这样做虽然在建图精度上有了提高,但非常消耗资源和内存,对计算机性能要求较高。

目前激光 SLAM 主要存在前端点云数据在松耦合的方式下处理不充分、特征匹配准确度不高、回环检测效果差、以及后端建图精度不高,会有一定的漂移和高程误差等问题。针对以上问题本文在 LeGO-LOAM 算法的基础上结合现有技术的优点,主要对前端激光里程计、后端数据融合方式和建图方法做了改进,具体为以下 3 个方面:

- 1) 在数据处理阶段,将 IMU 信息做了状态变量定义,不仅只作用于前端对激光点云做畸变补偿,预积分信息还用于后端优化与建图,改善了点云重影现象,同时也提高了数据利用率。
- 2) 采用欧式空间和角度阈值相结合的方法对点云信息完成聚类与分割,提高了点云匹配效率和精度。
- 3) 利用图优化紧耦合的方式对 IMU 信息、激光里程计信息和回环检测信息做了融合,减少了运动漂移,提高了高程估计和建图精度。

## 1 系统框架与流程

基于图优化的激光惯导紧耦合里程计框架如图 1 所示。

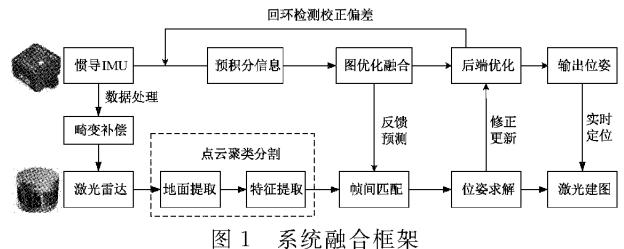


图 1 系统融合框架

结合系统框架,流程分为如下部分:

- 1) 畸变补偿:利用高频的惯导 IMU 数据对激光雷达的每帧点云进行校正补偿,抵消激光点云产生的运动畸变。
- 2) 点云聚类分割:本算法的分割是对非地面点云进行分割匹配聚类,将低于设定阈值的聚类进行剔除。
- 3) 特征点提取:在聚类完成后,将其点云信息以线特征点和表面特征点的形式进行提取。
- 4) 帧间匹配:地面特征采用点与平面匹配方式、线特征采用点与直线匹配方式、表面特征采用点与平面特征匹配。
- 5) 位姿求解:基于 LeGO-LOAM 算法的基础上,利用两部 L-M 算法对帧间匹配过后的地面特征、非地面线性特征和表面特征点进行分步骤位姿解算。
- 6) 图优化融合:采用图优化紧耦合融合方式对来自激光雷达的特征匹配信息、IMU 的预积分信息和回环检测信息进行融合。
- 7) 激光建图:利用融合后高频的激光里程计信息结合精准的位姿信息进行三维建图。

## 2 关键技术研究

### 2.1 IMU 状态估计

移动载体搭载 IMU<sup>[8]</sup>通过加速度计和陀螺仪可以获得原始加速度测量值  $a_t$  和角速度测量值  $w_t$ ,但这些值中包含了大量的噪声,直接用来进行位姿估计和点云补偿会有很大的误差。在考虑到 IMU 的两种主要误差来源:零偏不稳定性和噪声 bias 和测量噪声<sup>[9]</sup>之后定义 IMU 的状态为:

$$X_t = [p_t \ v_t \ q_t \ \hat{a}_t \ \hat{w}_t \ g^n] \quad (1)$$

其中,  $p_t$  表示当前时刻无人车的位置;  $v_t$  表示当前时刻的速度;  $q_t$  表示当前的四元数;  $\hat{a}_t$  表示考虑两种误差后的加速度真值;  $\hat{w}_t$  表示考虑两种误差后的角速度真值;  $g^n$  为地球重力矢量,  $g^n = [0 \ 0 -g]^T$  其中  $g$  为重力加速度。 $t-1$  时刻到  $t$  时刻 IMU 的状态更新方程为:

$$\begin{bmatrix} p_t \\ v_t \\ q_t \\ \hat{a}_t \\ \hat{w}_t \end{bmatrix} = \begin{bmatrix} v_{t-1} T + \frac{1}{4} T^2 [\mathbf{C}_{b(t-1)}^n \cdot \widehat{a_{(t-1)}} + \mathbf{C}_{bt}^n \cdot \hat{a}_t] + \frac{1}{2} T^2 g^n \\ v_{t-1} + T \left[ \frac{1}{2} [\mathbf{C}_{b(t-1)}^n \cdot \widehat{a_{(t-1)}} + \mathbf{C}_{bt}^n \cdot \hat{a}_t] + g^n \right] \\ q_{t-1} \otimes \frac{1}{2} T [\widehat{w_{(t-1)}} + \hat{w}_t] \\ \mathbf{C}_b^n (a_t - g^n) - a_{bt} \\ w_t - w_{bt} \end{bmatrix} \quad (2)$$

为了减少误差对数据取中值处理,其中  $T$  为  $t-1$  时刻

到  $t$  时刻的计算周期;  $C_b^n$  为从导航坐标系( $n$ )到载体坐标系( $b$ )的捷联惯导旋转矩阵;  $a_{bu}$  表示考虑两种误差后的加速度偏移;  $w_{bu}$  表示考虑两种误差后的角速度偏移。在得到 IMU 状态方程后,可以获得任何时刻的状态量和相邻两帧之间的预积分信息,通过对状态量残差求雅可比和协方差矩阵得到两关键帧之间的相对位姿关系,为下文的畸变补偿和数据融合做铺垫。

## 2.2 畸变补偿

由于激光雷达的机械旋转方式加上搭载 Lidar 载体的动态工作场景,将不可避免的发生颠簸和抖动现象,导致一次扫描过程中前后帧点云发生运动畸变。因此需要对关键帧点云做运动补偿,假设一帧扫面点云中雷达的初始位姿为  $\mathbf{T}_0 = \begin{bmatrix} R_0 & t_0 \\ 0 & 1 \end{bmatrix}$ , 第  $i$  个激光点采集时雷达的位姿为

$$\mathbf{T}_i = \begin{bmatrix} R_i & t_i \\ 0 & 1 \end{bmatrix}, \text{ 第 } i \text{ 个激光点的坐标为 } P_i = [p_{ix} \quad p_{iy} \quad p_{iz}],$$

则第  $i$  个激光点畸变补偿后的坐标为  $\bar{P}_i = \mathbf{T}_0^{-1} \mathbf{T}_i P_i$ , 以 1 帧点云起始时刻的雷达位姿为基准坐标系,此时雷达的初始位姿  $\mathbf{T}_0$  为单位矩阵,则  $\bar{P}_i = \mathbf{T}_i P_i$ ,  $\mathbf{T}_i$  则变成了  $0 \sim i$  时刻的相对旋转量和平移量。假设理想情况下搭载激光雷达和 IMU 的平台保持匀速运动,则  $i$  时刻的位姿为  $R_i = w\Delta t, t_i = v\Delta t$ , 此时畸变补偿问题就是求不同  $i$  时刻的位姿变化关系,求载体不同  $i$  时刻的角速度和速度信息,通过 IMU 状态更新方程便可求解。

## 2.3 地面提取与点云聚类

激光雷达的扫描过程如图 2 所示,假设其发出的两束相邻射线打在地面上的两个点为  $A(a_x, a_y, a_z)$  和  $B(b_x, b_y, b_z)$ ,  $A, B$  两点的高度差为  $h_{AB} = |a_z - b_z|$ , 水平距离  $d_{AB} = \sqrt{(a_x - b_x)^2 + (a_y - b_y)^2}$ , 高度差  $h_{AB}$  和水平距离  $d_{AB}$  构建的三角形夹角  $\alpha = \arctan2(h_{AB}, d_{AB})$ , 根据实地地形给出一个角度阈值,若  $\alpha$  小于该阈值则表明  $A, B$  点可能属于地面点,将其放入过渡点云集  $G$  中做下一步判别。因为在一些特殊环境下,如场景中有一些大平台它们的表面也很平滑,就会出现图 2 中  $A'$  和  $B'$  的情况,此时仅用该方法就会误把这两点当成地面点处理。进一步的本文利用激光雷达和搭载它的载体之间的垂直高度作为先验信息,进一步辅助判断地面点。在得到激光雷达距离地面的垂直高度  $h_z$  之后,将它和点集  $G$  中的点云高度作差得到  $d = h_z - G_{(i,h)}$ , 若  $d < 0.5 \text{ cm}$ , 则点云  $G$  为真正的地面点。

为了得到更好的聚类效果,本文对庞大的三维点云数量集做了下采样处理,同时采用了体素网格直通滤波的方法对雷达采样时存在的噪声点云做了去除。现有的聚类方法大多采用二维的检索方式难以达到高效实时的聚类效果。本次采用 3D 欧式空间<sup>[10]</sup>的方法首先在整个点云上构造三维的 kd Tree<sup>[11]</sup> 数据结构来进行点云检索,在点云搜索的过程中给出合理的聚类半径阈值,然后将半径阈值内的所有邻点聚类成一个点云簇。在得到的点云簇中引入了

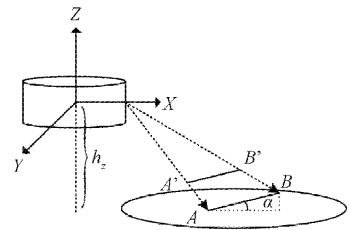


图 2 激光扫描场景

最小聚类点数阈值  $Q_{min}$  和最大聚类点数阈值  $Q_{max}$ 。将点云分割结果分为了以下 3 类,如表 1 所示。

表 1 点云聚类分类

类别	第一类	第二类	第三类
点云数量 $Q$	$Q \leq Q_{min}$	$Q_{min} < Q < Q_{max}$	$Q \geq Q_{max}$

对第一类进行剔除。由于点云数量极少可能为(马路边的路灯,树干的树枝和树叶)等,这些对建图和定位没有影响,剔除后可以提高系统的运算速率和后端的匹配精度。对第二类进行保留,对第三类进行二次判别,因为聚类半径阈值的不同,这类点云数量较大的点云簇中可能包含多类点云,为了将这些深度距离差异点云分离出来,组合使用角度阈值的方法对这些点云进一步分割聚类。分割原理如图 3 所示。

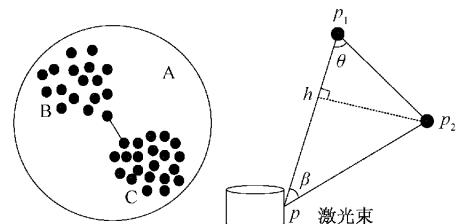


图 3 点云聚类分割

$p_1h$  和  $p_2h$  为激光雷达发射的两个连续激光束,将较长激光束  $p_1p_2$  和  $p_1p_2$  连线的夹角记为  $\theta$ ,  $p_1p_1$  和  $p_1p_2$  的夹角记为  $\beta$ , 其中  $p_1p_1$ 、 $p_1p_2$  的距离和  $\beta$  的角度可以由激光雷达自身特性给出。由图 3 可以推导出  $\theta$ :

$$\begin{aligned} p_1h &= pp_1 - pp_2 \cos\beta \\ p_2h &= pp_2 \sin\beta \\ \theta &= \arctan2\left(\frac{p_2h}{p_1h}\right) \end{aligned} \quad (3)$$

根据几何关系可以得出,点云  $p_1$  和  $p_2$  的深度距离越大则  $\theta$  的值越小。给定一个角度阈值,如果  $\theta$  小于该角度阈值,则判断  $p_1$  点云和  $p_2$  点云不来自同一个类,则可以将 B 类和 C 类从 A 类中分离出来,更细致更完善的完成聚类。

## 2.4 特征提取

为了提高匹配精度和减少运算量,本文从地面点和分割聚类后的点云中提取线特征和面特征,而不是从原始点

云中提取。采用曲率提取方式,根据曲面的平滑度来区分。原理示意如图 4 曲率等于其曲率圆半径的倒数<sup>[12]</sup>,当点云构成的线段比较弯曲时,此时形成的曲率圆也比较小,半径倒数就比较大,曲率就比较大。相反,如果是点云构成的一个相对平面,此时构成的曲率圆就比较大,半径的倒数就比较小,即曲率也比较小。对此给出了点云特征曲率计算公式:

$$c = \frac{1}{|S| \cdot \|P_{(k,i)}^L\|} \left\| \sum_{j \in S, j \neq i} (P_{(k,i)}^L - P_{(k,j)}^L) \right\| \quad (4)$$

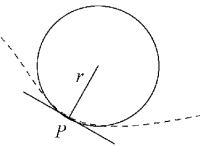


图 4 曲率圆

其中,  $S$  为一帧点云的领域大小,  $i, j$  为第  $k$  帧点云中满足领域  $S$  的两个点, 记为  $P_{(k,i)}^L$  和  $P_{(k,j)}^L$ ,  $L$  为传感器坐标系。为了从各帧点云中均匀的选取特征点, 根据所采用的激光雷达的扫描原理将 360° 的扫描面平均分成 3 份, 由于所采用的激光雷达为 16 线, 再根据线数将这三等份平均分成 16 小份, 这样就将一帧点云平均分成了 48 小份, 且保证了线与线之间的点云互不影响。进一步的为了提高特征提取算法的有效性和实时性, 规定对每个小份提取 2 个线特征点和 4 个平面特征点。选取条件为:  $C$  值大于阈值的点则作为线特征点,  $C$  值小于阈值的点则作为面特征点。所有线特征点构成集合  $F_l$ , 面特征点构成集合  $F_p$ 。

## 2.5 帧间匹配与位姿求解

在得到线特征点  $F_l$  和面特征  $F_p$  之后, 通过执行点到线和点到平面的扫描匹配来找到前后两帧之间的转换关系<sup>[13]</sup>。在这里给出了特征点到线的距离残差公式  $d_e$  和面的距离残差公式  $d_\delta$ 。

$$d_e = \frac{|(\bar{P}_{(k+1,i)}^L - P_{(k,j)}^L) \times (\bar{P}_{(k+1,i)}^L - P_{(k,l)}^L)|}{|P_{(k,j)}^L - P_{(k,l)}^L|} \quad (5)$$

$$d_\delta = \frac{|((P_{(k,j)}^L - P_{(k,l)}^L) \times (P_{(k,j)}^L - P_{(k,m)}^L))|}{|(P_{(k,j)}^L - P_{(k,l)}^L) \times (P_{(k,j)}^L - P_{(k,m)}^L)|} \quad (6)$$

其中, 若第  $k+1$  帧的点云  $i \in$  线特征点集合  $F_l$ , 记为  $\bar{P}_{(k+1,i)}^L$ , 然后计算点  $i$  到其最近领域第  $k$  帧两个点  $j, l$  构成直线的距离, 把  $j, l$  记为  $P_{(k,j)}^L$  和  $P_{(k,l)}^L$ 。考虑到对每一小部分只提取了两个线特征点, 这里要求  $j, l$  来自于不同的激光束。若点云  $i \in$  面特征点集合  $F_p$ , 则计算点  $i$  到其最近领域三个点  $j, l, m$  构成平面的距离, 把  $m$  记为  $P_{(k,m)}^L$ 。这里点  $j$  是点  $i$  的一个最近领域点, 点  $l, m$  是点  $j$  最近领域的两个点, 但要满足其中一个点与点  $j$  来自于同一激光束, 一个点来自点  $j$  的前后激光束, 这样保证了三点不共线, 点  $j, l, m$  构成了一个平面。这里所提到的线特征只来源于分割聚类后的点云簇中(不包括地面点云), 面特

征只来源于地面点云簇, 这极大提高了匹配速度和精度。

构建联合损失函数, 采用 Levenberg-Marquardt<sup>[14]</sup> 方法来寻找前后帧之间的最小六自由度位姿变换  $T_K^L$ , 将位姿变量  $[t_x, t_y, t_z, \theta_{roll}, \theta_{pitch}, \theta_{yaw}]$  分为两组  $[t_x, t_y, \theta_{yaw}]$  和  $[t_z, \theta_{roll}, \theta_{pitch}]$ , 通过线特征匹配关系来约束水平方向的变量  $[t_x, t_y, \theta_{yaw}]$  并对其进行 L-M 法位姿解算, 通过地面特征匹配关系来约束垂直方向的变量  $[t_z, \theta_{roll}, \theta_{pitch}]$  并对其进行 L-M 法位姿解算, 通过两步 L-M 法解算出位姿。

## 2.6 基于图优化的融合与建图

传统的数据融合优化方案大多采用滤波的方法如 KF, EKF<sup>[15]</sup>, 这些方案只有一次迭代和一次线性化, 会有一定的线性误差。本次采用基于因子图优化的融合, 将滤波方法中的惯性解算变成了 IMU 预积分, 然后将其和激光雷达里程计得出的相对位姿, 回环检测作为图因子加入到融合框架当中。一个简单的数据融合模型如图 5 所示。

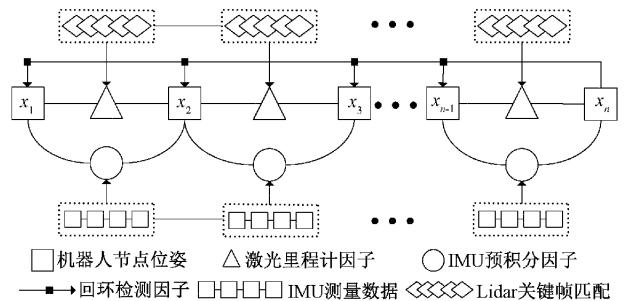


图 5 图优化融合

为了提高算法的实时性, 减小内存消耗, 只将一帧点云中的线特征  $F_l$  和面特征  $F_p$  作为关键帧加入图形中, 并运用上述的匹配方法找到机器人相邻位姿之间的初始变换关系  $T_K^L$ , 将其作为激光雷达里程计因子用来关联因子图中机器人下一节点  $x_n$ 。将 IMU 测量信息转换为预积分因子, 在前端辅助激光点云进行畸变补偿, 在后端与激光里程计因子一起联合优化机器人位姿, 在小场景中可以得到比较稳定的状态估计和建图效果, 但在长时间建图过程中, 会有一定的重影和漂移现象。为此在图模型中加入了回环检测因子利用文献[16] SegMatch 的匹配方法来检测回环。当一个新的机器人位姿  $x_n$  加入到因子图中时, 回环检测的目的是在以前的地图中找到与新加入位姿相似的状态, 如果有则进行回环匹配。具体过程为提取当前位姿  $x_n$  下的关键帧点云簇, 然后和周围机器人位姿  $x_1, x_2, x_3$  等下的关键帧点云簇通过随机森林的方法判别两两点云簇之间的相似度, 选取相似度最大的两位姿关键帧进行详细的分割匹配, 判断的依据为计算关键帧中基于线特征和面特征的特征向量的绝对值之差, 若该差值小于给定的阈值则匹配成功, 视为闭环。

通过 IMU 预积分因子、激光里程计因子、回环检测因子对机器人的位姿进行联合估计与优化, 输出节点之间的转换关系  $T_K^W$  用来映射关键帧点云之间的匹配, 随着一帧

帧新点云的加入,最终匹配拼接成完整的三维点云地图。

### 3 实验结果与分析

#### 3.1 实验平台设计

实验数据采集平台无人车如图 6 所示,由实验团队自行组建。控制底盘采用松灵机器人公司出产的 MR1000,在此基础上设计安装了 RS-16 线 3DLidar、维特 HWT605-6 轴 IMU、厦门四信 F-V111-RTK 和配置为 CPU-Inter i7/16 G 运行内存/250 G SSD 的工控电脑。工控机操作系统为 Linux ubuntu 18.04,对应的 ROS 机器人操作系统为 Melodic。

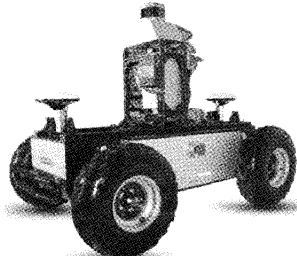


图 6 无人车平台

#### 3.2 Kitti 数据集测评

##### 1) 里程计精度评定

使用 Kitti 数据集进行激光里程计精度测定,这里参考了文献[17]的比较方法和数据。选取了 00、04、06、07 四组公开 Kitti 数据集,分别用 LOAM、LeGO-LOAM、文献[17]和本文 4 种方案,利用 EVO 测评工具对其进行了测评,并用 APE(绝对位姿误差)来评判激光里程计的精度。为了减少偶然误差,提高数据的真实性,每组数据都是在重复运行 8 次的平均值。具体的实验结果如表 2 所示。

表 2 各方案在 Kitti00、04、06、07 数据集上的 APE 对比

方案 \ 数据集	Kitti 00	Kitti 04	Kitti 06	Kitti 07
LOAM	25.6	2.0	19.0	5.1
LeGO-LOAM	20.0	1.6	13.1	2.8
文献[17]	15.9	1.9	5.1	1.6
本文	6.3	1.2	4.0	1.3

本文方案在 4 种数据集上的 APE 误差曲线如图 7 所示。结合表 2 和图 7 可以看出本文方案比其余方案在里程计精度测评中有着更优的表现,本文方案相比于文献[15]在 4 个数据集上的 APE 误差平均提高了 34.38%;相比于 LeGO-LOAM 平均提高了 54.13%;相比于 LOAM 平均提高了 67.21%,与各数据集的 GPS 真值相比有着较小的 APE 误差。

##### 2) 建图效果评定

为了验证融合了 IMU 预积分因子、激光里程计因子和

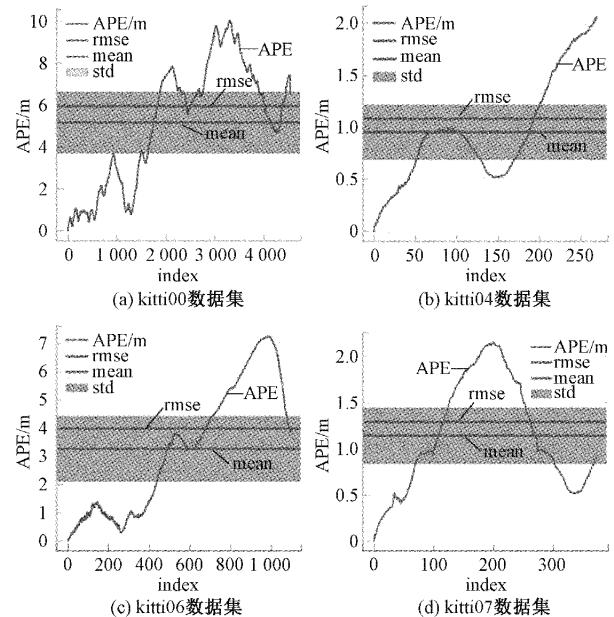


图 7 本文方案 APE 误差曲线

回环检测因子的图优化建图效果,选取了轨迹相对复杂和轨迹相对长的 Kitti 00 和 Kitti 09 数据集,两数据集轨迹都是闭环的,为验证回环检测提供了基础。图 8 是本文方案在两数据集上建立的 3D 点云图。图 9 是 LOAM、LeGO-LOAM 和本文方案在 00 和 09 数据集建图轨迹与真值轨迹的对比,其中黑色虚线代表 GNSS 真值轨迹,图中标记的本文、LeGO-LOAM 和 LOAM 分别代表本文方案、LeGO-LOAM 方案和 LOAM 方案的轨迹。从图 9 中可以看出,在两种数据集上本文方案和真值轨迹最为贴近,LeGO-LOAM 次之,由于没有回环检测功能 LOAM 建图的轨迹与真值轨迹的偏差最大。

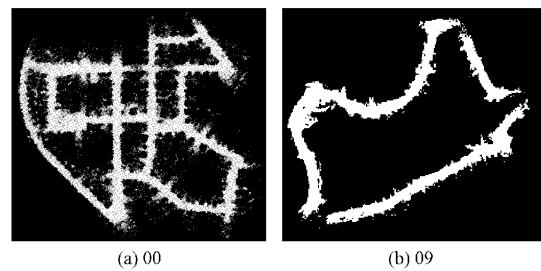


图 8 本文方案建图

进一步的为了比较后端图优化中加入了回环检测因子的效果,单独提取了 LeGO-LOAM 方案和本文方案在 00 和 09 数据集的里程计轨迹情况,如图 10 和 11 所示。从上一小节 Kitti 数据集的测试结果可以看出 LOAM 算法由于没有回环检测模块,其定位精度最差,此次实验不对 LOAM 算法进行比较。图 10 和 11 中底部的箭头是数据采集的起始点位置,回环检测的意义在于机器人能够识别曾经到达过的场景,使当前地图与曾今的地图信息做匹配,

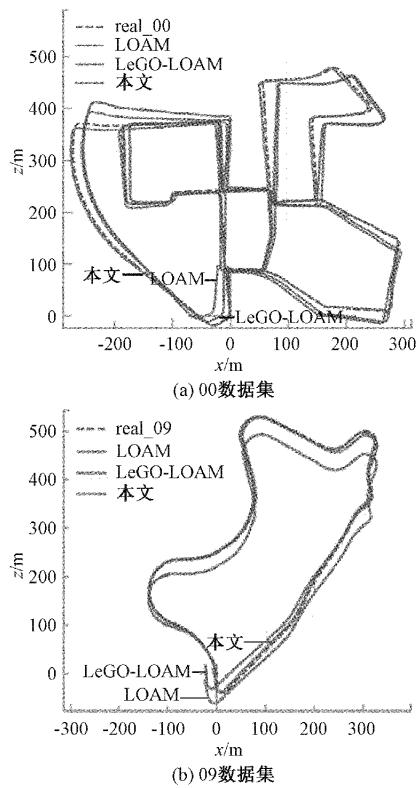


图 9 不同方案建图轨迹比较

达到地图闭环的能力。从图 11 可以看出本文方案在两数据集的起始点处几乎闭环，在大场景的 00 和 09 数据集中其回环检测效果明显优于 LeGO-LOAM。在整体建图效果上从图 10 和 11 上方的箭头处可以看出本文方案的回环检测功能还优化了整体轨迹，经过同一段较长路径时有着较高的匹配精度，显著的减少了累计误差。整体来看本文的回环检测功能无论从首尾闭环还是经过相同较长路段都有很好的匹配精度和闭合效果，且都优于 LeGO-LOAM。

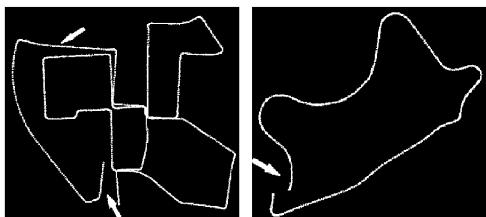


图 10 LeGO-LOAM 里程计轨迹

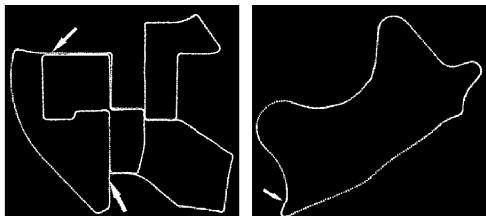


图 11 本文方案里程计轨迹

### 3.3 实测数据集测评

#### 1) 地面分割与特征提取

用自组建的无人车对南信大无锡研究院一楼展厅进行了数据采集与建图，展厅内环境复杂，有很多展览板，展示屏，实验器材，适合用来进行线特征和面特征的提取。图 12(a)为用本文方案构建的展厅三维图，无人车走了一个闭环路线，三维点云图线条清晰。接下来单独做了地面分割和特征提取的实验，图 12(b)和(c)为从不同角度看到的效果，图中点状部分代表线特征及边缘特征、圈状部分代表地表特征、横条线状部分代表表面特征提取结果。

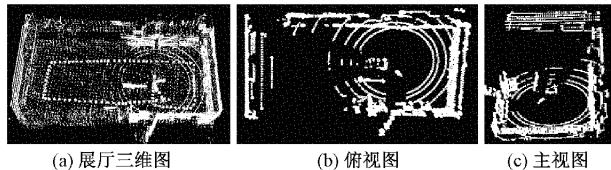


图 12 特征提取

#### 2) 室外复杂环境建图

为了验证本文激光惯导紧耦合 SLAM 系统在实际室外复杂环境的建图效果，利用自己搭建的无人车采集平台对一个工业园区进行了室外路径测试。园区内路况环境复杂，建筑物、行人、车辆、树木、花坛众多，为实验创造了一个很好的室外复杂环境。图 13 为各算法对工业园区三维重建效果的俯视图。无人车平台从左下方出发以 1.5 m/s 的平均速度对工业园区内部顺时针绕行一圈然后回到起点的位置，行驶轨迹为一个闭环。图 13(a)为 LOAM 算法三维重建效果；图 13(b)为 LeGO-LOAM 算法三维重建效果；图 13(c)为本文方案三维重建效果；图 13(d)为本文方案建图的里程计轨迹。从图 13 中可知 LOAM 算法在建图过程中出现了比较明显的偏移和重影现象，点云数量繁多杂乱，构建的轮廓不清晰。LeGO-LOAM 算法相比于 LOAM 有着较好的建图精度，但其仍然存在聚类分割效果不佳、点云量过大、一些非必要点云存在和重建的三维轮廓不清晰等问题。本文方案相比于 LOAM 和 LeGO-LOAM：三维重建效果轮廓清晰、无重影和偏移现象，构建的三维点云地图精度更高鲁棒性更强。

图 14 为各方案对工业园区三维重建效果的主视图，所测试的工业园区路段基本保持水平，偶有路段有颠簸现象，但坡度不会超过 5°。从图 14 可以看出，LOAM 算法三维重建的主视图出现了较大的偏差。在 Z 轴方向出现了较大的偏移，XY 轴出现了轻微漂移，地图重影现象严重。LeGO-LOAM 算法相比于 LOAM 算法在前端增添了地面分割，利用 IMU 信息在水平和航向方向做了优化，一定程度上改善了建图的高程误差。但在后端回环优化中没有有效融合 IMU 预积分信息，点云地图在 Z 轴方向仍有一定的偏移和重影现象。我们的方案通过线特征匹配关系来约束水平方向的变量  $[t_x, t_y, \theta_{yaw}]$  通过地面特征匹配关系来

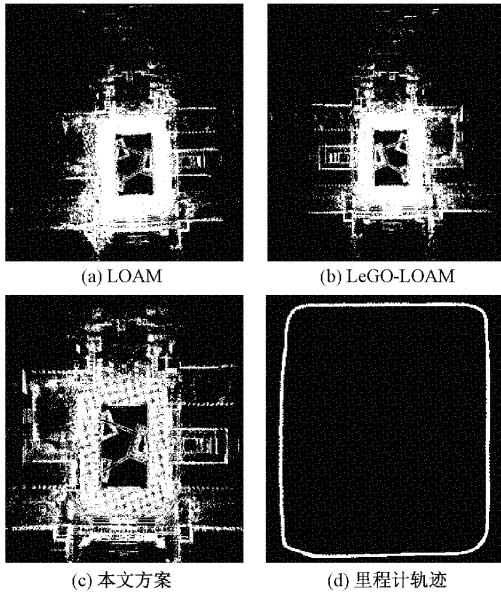


图 13 不同方案三维建图俯视图对比

约束垂直方向的变量  $[t_z, \theta_{roll}, \theta_{pitch}]$ , 并将 IMU 预积分因子加入到了后端的图优化当中, 从地图重建结果上看, 有效抑制了高程误差和点云重影现象。

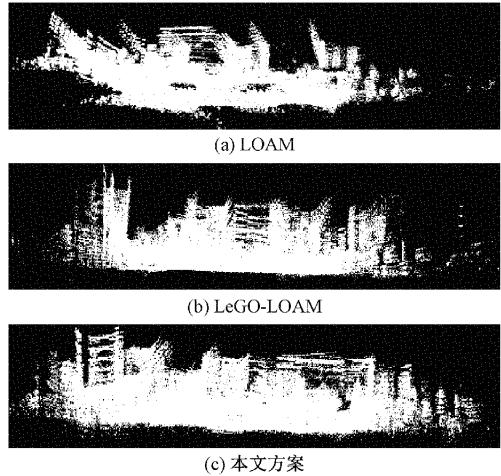


图 14 各方案三维建图主视图对比

表 3 展示了 LOAM、LeGO-LOAM 和本文方案在园区路测数据上的水平和垂直方向上的位姿累计误差。同样的为了减少偶然误差, 表中数据也是各种方案重复运行 8 次的平均值。采用标记的方法保证无人车起点位置和终点位置重合, 无人车保持相同的轨迹路线走一个回环回到起点位置。位姿误差的评价指标是: 终点位姿坐标减去起点位姿坐标。其中  $[x, y, yaw]$  评价水平方向位姿偏差,  $[z, roll, pitch]$  评价垂直方向位姿偏差。从表中数据可以看出本文方案在  $z$  轴上的高程误差和水平方向  $xy$  轴的偏移误差均可以达到厘米级, 其精度高于 LOAM 和 LeGO-LOAM 的分米级。在整体位置误差上本文方案相比于 LeGO-LOAM 提高了 37.36%, 相比于 LOAM 提高了

48.12% 在姿态角方面相比于其他算法也保持着较小的误差, 其精度控制在 1° 左右; LeGO-LOAM 保持在 3° 左右; LOAM 保持在 5° 左右; 整体上看本文方案有着较高的鲁棒性和建图精度。

表 3 不同方案水平和垂直方向的累计误差

方案	水平方向			垂直方向		
	$x/m$	$y/m$	$yaw/(^{\circ})$	$z/m$	$roll/(^{\circ})$	$pitch/(^{\circ})$
LOAM	0.328	0.426	4.560	0.645	4.250	5.520
LeGO-LOAM	0.126	0.134	2.828	0.215	2.520	3.215
本文方案	0.095	0.086	0.712	0.095	0.828	1.120

#### 4 结 论

针对传统激光惯导建图方案出现的轨迹漂移、定位精度低和鲁棒性不足问题。本文给出了一基于图优化的激光惯导紧耦合里程计与建图方法。在 LeGO-LOAM 算法的基础上依次执行点云畸变补偿、点云聚类分割、特征点提取、帧间匹配、初步位姿求解。最后引入了回环检测模块, 通过图优化的紧耦合融合方式将 IMU 因子、初步里程计因子和回环检测因子做了融合建图。通过自采集的数据以及来自 Kitti 里程计基准的数据集在多种环境类型中进行了大量实验测试, 实验证明本文方法对运动轨迹漂移和点云重影现象有很好的抑制作用, 在大场景建图中相比于 LOAM 和 LeGO-LOAM 有着较好的里程计和定位精度。后期实验中发现无人车在车速较高的状态下, 其系统实时性和鲁棒性会有所下降, 本方案适合于园区巡逻勘测之类低速的平台, 后期还应该进一步完善其系统性能, 达到工程化需求。

#### 参考文献

- [1] 蔡英凤, 陆子恒, 李伟承, 等. 基于多传感器融合的紧耦合 SLAM 系统[J]. 汽车工程, 2022, 44(3): 350-361.
- [2] 周治国, 曹江微, 邱顺帆. 3D 激光雷达 SLAM 算法综述[J]. 仪器仪表学报, 2021, 42(9): 13-27.
- [3] ZHANG J, SINGH S. LOAM: Lidar odometry and mapping in real-time [C]. Robotics: Science and Systems, 2014, 2(9): 1-9.
- [4] 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), IEEE, 2018: 4758-4765.
- [5] YE H, CHEN Y, LIU M. Tightly coupled 3d lidar inertial odometry and mapping[C]. 2019 International Conference on Robotics and Automation (ICRA), IEEE, 2019: 3144-3150.

- [6] 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.
- [7] 华智,宋吉来,杜振军,等.基于滤波与图优化的定位与建图系统[J].电子测量技术,2022,45(4):99-106.
- [8] FROSI M, MATTEUCCI M. ART-SLAM: Accurate real-time 6DoF LiDAR SLAM[J]. IEEE Robotics and Automation Letters, 2022: 2692-2699.
- [9] 朱朔凌,毛建旭,王耀南,等.基于惯性导航角度补偿的室内激光 SLAM 方法[J].电子测量与仪器学报,2019, 33(3):1-7.
- [10] 宗长富,文龙,何磊.基于欧几里得聚类算法的三维激光雷达障碍物检测技术[J].吉林大学学报(工学版), 2020,50(1):107-113.
- [11] 赵浚壹,马峻,陈寿宏,等.场景导向的 kd-tree 点云滤波算法[J].激光杂志,2021,42(11):74-78.
- [12] 张玉存,李亚彬,付献斌.基于曲率约束的点云分割去噪方法[J].计量学报,2020,41(10):1218-1225.
- [13] 王珊,王春阳.基于特征点匹配的三维点云配准算法[J].国外电子测量技术,2020,39(12):23-28.
- [14] 陈文浩,刘辉席,杨林涛,等.基于 IMU 紧耦合的 LeGO-LOAM 改进算法研究[J].计算机应用研究, 2021,38(4):1013-1016.
- [15] LI M, MOURIKIS A I. High-precision, consistent EKF-based visual-inertial odometry [J]. The International Journal of Robotics Research, 2013, 32(6): 690-711.
- [16] LIU X, ZHANG L, QIN S, et al. Optimized LOAM using ground plane constraints and segmatch-based loop detection[J]. Sensors, 2019, 19(24): 5419.
- [17] 庞帆,危双丰,师现杰,等.激光雷达惯导耦合的里程计与建图方法[J].计算机应用研究,2021,38(7):2188-2193,2199.

### 作者简介

郑川川,硕士研究生,主要研究方向为机器人三维激光建图与自动导航。

E-mail:2430438195@qq.com

柯福阳(通信作者),博士,教授,主要研究方向为三维激光工业测量与控制、SLAM 无人驾驶特定场景应用。

E-mail:ke.fuyang@qq.com

汤琴琴,硕士,高级工程师,主要研究方向为机电一体化控制与智能感知。

E-mail:tangqinqin4628@163.com