

doi: 10.7690/bgzd.2025.09.015

面向机场测试环境下的多传感器紧耦合 SLAM 方法

祝大程^{1,2}, 李文海¹, 孙伟超¹, 李根¹

(1. 海军航空大学, 山东 烟台 264001; 2. 中国人民解放军 92229 部队, 海南 琼海 571400)

摘要: 针对机场测试环境下仅利用激光雷达无法精确定位的问题, 提出一种基于因子图优化的紧耦合多传感器同时定位与地图构建 (simultaneous localization and mapping, SLAM) 方法。利用边特征点和面特征点并结合两步优化策略进行点云特征匹配, 再采用滑动窗口消除全球导航卫星系统 (global navigation satellite system, GNSS) 数据异常值, 并在点云稀疏环境下和机器人方位变化超过 20° 时增量加入 GNSS 因子。在机场辅助路和较为空旷的机场跑道对 LeGO-LOAM、LIO-SAM 方法和该方法进行对比验证, 结果表明, 该方法在机场辅助路环境中的轨迹绝对误差比 LeGO-LOAM、LIO-SAM 方法分别降低了 15.426 和 0.211 m; 加入 GNSS 因子后, 精度提升至厘米级 ($RMSE_{APE}=0.050$ m); 在机场跑道环境中, 该方法的轨迹较为平滑, 无偏移问题, 且精度达到厘米级 ($RMSE_{APE}=0.063$ m)。

关键词: 同时定位与地图构建; 紧耦合; 图优化; 全球导航卫星系统; 激光雷达

中图分类号: TP242.3 **文献标志码:** A

Multi-sensor Tightly Coupled SLAM Method for Airport Test Environment

Zhu Dacheng^{1,2}, Li Wenhai¹, Sun Weichao¹, Li Gen¹

(1. Naval Aviation University, Yantai 264001, China; 2. No. 92229 Unit of PLA, Qionghai 571400, China)

Abstract: Aiming at the problem that accurate positioning cannot be achieved by using only lidar in airport test environment, a tightly coupled multi-sensor simultaneous localization and mapping (SLAM) method based on factor graph optimization is proposed. The edge feature points and the surface feature points are combined with the two-step optimization strategy to match the point cloud features, and then the sliding window is used to eliminate the outliers of the global navigation satellite system (GNSS) data, and the GNSS factor is added incrementally when the point cloud is sparse and the robot azimuth changes more than 20°. The LeGO-LOAM, LIO-SAM and this method are compared and verified in the airport auxiliary road and the relatively empty airport runway. The results show that the absolute error of the trajectory of this method in the airport auxiliary road environment is 15.426 and 0.211 m lower than that of LeGO-LOAM and LIO-SAM respectively. After adding the GNSS factor, the accuracy is improved to centimeter level ($RMSE_{APE}=0.050$ m); in the airport runway environment, the trajectory of this method is relatively smooth, without offset problem, and the accuracy reaches centimeter level ($RMSE_{APE}=0.063$ m).

Keywords: simultaneous localization and mapping; tight coupling; graph optimization; global navigation satellite system; laser radar

0 引言

近年来, 智能导航已逐渐深入到军事巡逻、智慧物流、地质勘察以及智能测试等诸多领域, 尤其在智能测试领域, 使用智能机器人进行自主智能测试将成为我军航空装备智能测试的发展方向。在航空装备智能测试过程中, 智能机器人能够自主到达测试点位完成测试显得至关重要。在该过程中, 如何实现精确定位便成了机器人导航领域需解决的关键问题。同时定位与地图构建 (SLAM) 技术是当前研究的热点与重点^[1]。激光雷达 SLAM 技术在利用激光雷达增量式建图的同时, 可实现移动机器人的自主相对定位, 具有创建地图精度高、受光照影响少、计算成本相对较低、运算速度快等优点^[2], 在智能导航中得到广泛的应用^[3]。机场测试环境更为

复杂, 既存在环境较为空旷、外部环境特征不够明显、激光雷达获取的点云数据稀疏的机场跑道环境, 又存在行道树、机棚等地物的机场辅助路。仅凭这一导航方式难以实现在机场环境下的定位与导航。同时, 激光雷达 SLAM 技术还存在连续匹配定位误差高、易产生漂移等问题, 故想要实现机场测试环境下的精确定位, 多传感器融合便成为智能机器人自主定位的优先选择。

激光雷达与图像传感器的融合是一种较好的融合方法。该方法利用图像高结构化数据提取特征, 可以与激光雷达实现数据互补^[4]。Pierzchala 等^[5]提出了一种通过融合激光雷达、深度相机、IMU 等数据的 SLAM 方法; 由于图像传感器的特征提取优势, 该方法在光线条件相对较好的情况下, 可以获得一

收稿日期: 2024-09-20; 修回日期: 2024-10-21

第一作者: 祝大程 (1993—), 男, 山东人, 硕士。

致性良好的地图。王铨彬等^[6]利用图优化算法提出一种紧耦合双目视觉/惯性/激光雷达 SLAM 方法,利用双目视觉与激光雷达的互补特性提高了视觉增强的激光雷达闭环检测能力,同时进一步提升了多源融合 SLAM 的全局定位与建图精度;但激光雷达与图像传感器的融合方法存在光照条件差、环境较为空旷的情况下定位精度低的问题,不利于在机场测试环境下使用。

相比于图像传感器,激光雷达与全球导航卫星系统(GNSS)融合优化是一种更加主流有效的方法。Schleicher 等^[7]利用扩展卡尔曼滤波算法来融合 GNSS 数据和激光雷达数据实现 SLAM 建图,但该方法主要将 GNSS 数据用于低层次端。Shan 等^[8]基于因子图优化构建了紧耦合激光惯性里程计(LIO-SAM),将各种不同因子加入因子图中进行联合优化,并增量式加入 GNSS 约束,具有不错的建图精度,但该方法中 GNSS 数据只简单作为绝对测量来优化累积误差。目前,已有方法主要针对特征明显的室外环境或室内场景,在环境较为复杂、精度要求高的机场测试环境中仍存在着累积误差大、空旷区域定位效果差等问题^[9]。

针对机场测试环境下移动机器人定位问题,笔者在 LIO-SAM 方法和 LeGO-LOAM 方法的基础上,先将惯性测量单元(inertial measurement unit, IMU)测量数据与激光雷达关键帧数据进行融合,再在 SLAM 后端融合拆分 GNSS 数据进行优化,同时进行 SLAM 建图。主要改进:

1) 根据环境特点,提取边特征点和面特征点,并结合先竖直方向后水平方向的两步优化策略,采用高斯牛顿法迭代求解出相邻关键帧的相对位姿,降低了激光 SLAM 累计误差。

2) 针对环境中存在机棚、行道树遮挡导致 GNSS 信号弱的情况,采用滑动窗口法剔除异常值并进行插值,在点云稀疏环境下或机器人方位变化超过 20°时增量加入 GNSS 因子,形成 GNSS 因子约束。

1 总体设计

笔者定义 W 为世界坐标系, B 为机器人坐标系。为方便计算,假设机器人坐标系与 IMU 坐标系和激光雷达坐标系一致;系统初始状态时,世界坐标系 W 的原点与机器人坐标系 B 的原点相同, z 轴方向与重力方向一致。则移动机器人状态 x 可定义为:

$$x = [R^T \quad p^T \quad v^T]^T. \quad (1)$$

式中: R 为姿态信息的旋转矩阵; p 为位置向量; v 为速度; T 为从机器人坐标系到世界坐标系的变换。

笔者在 LIO-SAM 和 LeGO-LOAM 的基础上,融合了 IMU 预积分因子、雷达里程计因子、GNSS 因子和回环因子,提出了一种基于图优化的紧耦合多传感器 SLAM 方法。系统如图 1 所示,共分为 6 个模块。




图1 系统

1) IMU 预积分。对 2 个雷达关键帧之间 IMU 进行积分,形成预积分约束,对 2 帧之间的位姿信息进行约束,同时推算出关键帧时刻对应位姿。

2) 点云数据预处理。先预设初始位置雷达帧为一个关键帧,当移动机器人的位姿较前一关键帧的改变超过设定的阈值,则将对应的雷达帧设为关键帧,相邻 2 个关键帧之间的雷达帧被舍弃。利用 IMU 积分获得的对应时刻位姿信息来消除激光雷达产生的运动畸变。

3) 点云数据特征提取与匹配。评估局部区域中点的平滑度提取边和面特征点,通过关键帧特征匹配和两步优化策略,采用高斯牛顿法迭代求解出相邻关键帧的相对位姿。

4) GNSS 因子构建。采用滑动窗口法剔除异常值和进行插值,在点云稀疏环境下或机器人方位变化超过 20°时增量加入 GNSS 因子,以此构建 GNSS 因子。

5) 回环优化。采用与 LIO-SAM 相同的方法进行回环检测。若出现回环边,则进行回环优化。

6) 全局地图构建与优化。整合 IMU 预积分因子、雷达里程计因子、GNSS 因子和闭环因子进行联合优化来构建并更新全局地图。

2 各系统因子的构建与优化

2.1 IMU 预积分因子

IMU 的原始测量值,即 IMU 在机器人坐标系下 t 时刻的角速度 $\hat{\omega}_t$ 和加速度 $\hat{a}_t$, 是受缓慢变化的偏置 b_i 和白噪声 n_t 影响的。故:

$$\left. \begin{aligned} \hat{\omega}_t &= \omega_t + b_t^\omega + n_t^\omega \\ \hat{a}_t &= R_t^{WB} (a_t - g) + b_t^a + n_t^a \end{aligned} \right\} \quad (2)$$

式中: R_t^{WB} 为 t 时刻从世界坐标系到机器人坐标系的转移矩阵; g 为在世界坐标系下重力加速度。

假设角速度 $\hat{\omega}_t$ 和加速度 $\hat{a}_t$ 在 $(t, t+\Delta t)$ 期间保持不变, 则机器人在 $t+\Delta t$ 时刻的状态为:

$$\left. \begin{aligned} R_{t+\Delta t} &= R_t^{WB\top} \exp((\hat{\omega}_t - b_t^\omega - n_t^\omega) \Delta t) \\ p_{t+\Delta t} &= p_t + v_t \Delta t + \frac{1}{2} g \Delta t^2 + \frac{1}{2} R_t^{WB\top} (\hat{a}_t - b_t^a - n_t^a) \Delta t^2 \\ v_{t+\Delta t} &= v_t + g \Delta t + R_t^{WB\top} (\hat{a}_t - b_t^a - n_t^a) \Delta t \end{aligned} \right\} \quad (3)$$

然后应用文献[10]中提出的预积分方法, 可得机器人在相邻时间戳的相对运动为:

$$\left. \begin{aligned} \Delta R_{ij} &= R_i^\top R_j \\ \Delta p_{ij} &= R_i^\top (p_j - p_i - v_i \Delta t_{ij} - g \Delta t_{ij}^2 / 2) \\ \Delta v_{ij} &= R_i^\top (v_j - v_i - g \Delta t_{ij}) \end{aligned} \right\} \quad (4)$$

2.2 雷达里程计因子

2.2.1 点云数据预处理

由于受测试设备自身尺寸和算力影响, 实现对每个雷达帧计算较为困难, 故采用关键帧策略。先预设初始位置雷达帧为一个关键帧, 当移动机器人的位姿状态较前一关键帧的位置或旋转角度变化超过 1 m 或 10° 时, 则将对应的雷达帧设为关键帧, 相邻 2 个关键帧之间的雷达帧被舍弃。然后采用上述 IMU 预积分方法获得的机器人在相邻关键帧的相对运动来消除机器人位姿变换引起的激光雷达运动畸变。考虑到地面点对于垂直方向有较好约束, 而非地面点则对水平方向有较好约束, 笔者先对雷达点云区分地面点云和非地面点云, 再对地面点云进行下采样、滤波和分割聚类提取障碍物, 最后进一步对所有点云提取边特征点和面特征点^[11]。

在 SLAM 建图中, 对地面点云进行分割提取可以降低面特征提取的数量, 滤除噪点, 以减少对障碍物聚类的影响, 如图 2 所示。




图 2 激光雷达地面分割技术

2.2.2 点云数据特征提取与匹配

当接收到一个新的点云数据时, 笔者采用评估

局部区域中点的平滑度的方法来提取边和面特征点, 局部区域点 i 的平滑度公式为^[12]:

$$c = \frac{1}{|S| \cdot \|X_{(k,i)}^L\|} \left\| \sum_{j \in S, j \neq i} (X_{(k,i)}^L - X_{(k,j)}^L) \right\| \quad (5)$$

式中: S 为评估区域点的集合; L 为传感器坐标系。在环境中均匀选取特征点, 笔者将激光雷达的扫描面平均分成 3 份, 由于笔者所采用的激光雷达为 16 线束, 再根据线束将这 3 份平均分成 16 小份, 这样就将一帧点云平均分成了 48 子区域, 每个子区域最多提取 2 个边特征点和 4 个面特征点。当点 i 的 c 值大于阈值 (5×10^{-3}), 点 i 为边特征点; 当点 i 的 c 值小于阈值 (5×10^{-3}) 时, 点 i 为面特征点, 如图 3 所示。所有边特征点构成集合为 F_i^e , 面特征点构成集合为 F_i^p 。为确保所取得点的有效性, 笔者规定所选点必须满足以下 4 点要求:

- 1) 数量不超过子区域的最大点数;
- 2) 周围没有被选中的点;
- 3) 局部平面与激光光束所成角度大于 10° ;
- 4) 特征点不能是被其他物体遮挡的点。




图 3 光雷达点云特征点

在激光点云匹配中, 笔者采用基于特征点匹配的方法。对于每个关键帧, 从中提取边或者面特征点, 再利用 KD 树在其邻近域内搜索其最邻近的同属性特征点 (边特征点 2 个、面特征点 4 个)。之后, 构建特征点到面距离或特征点到线距离最小残差方程, 再利用高斯牛顿法迭代求解激光雷达关键帧的相对位姿^[13]。

笔者先提取 n 个最近的关键帧 $\{F_{i-n}, \dots, F_i\}$, 并通过其相应的转换关系 $\{T_{i-n}, \dots, T_i\}$ 将其从机器人坐标系转换到世界坐标系, 由此构成体素地图 M_i , M_i 同样包含边特征体素地图和面特征体素地图。即:

$$M_i = \left\{ \bigcup_{k=0}^n {}_w F_{i-k}^e, \bigcup_{k=0}^n {}_w F_{i-k}^p \right\} \quad (6)$$

当产生新的关键帧 F_{i+1} 时, 通过 IMU 估计的机器人运动 $\tilde{T}_{i+1}$ 来实现从机器人坐标系 (F_{i+1}^e, F_{i+1}^p) 转换成世界坐标系 $({}_w F_{i+1}^e, {}_w F_{i+1}^p)$ 。对于转换后的每个特征

点 k 都能在 M_i 中找到对应的边或者面，一个特征点与跟它相关的边或者面的距离可用式(6)和(7)计算。

$$d_{ek} = \left| (p_{i+1,k}^e - p_{i,u}^e) \times (p_{i+1,k}^e - p_{i,v}^e) \right| / \left| p_{i+1,u}^e - p_{i,v}^e \right|; \quad (7)$$

$$d_{pk} = \frac{\left| \frac{p_{i+1,k}^p - p_{i,u}^p}{(p_{i,u}^p - p_{i,v}^p) \times (p_{i,u}^p - p_{i,w}^p)} \right|}{\left| \frac{p_{i,u}^p - p_{i,v}^p}{(p_{i,u}^p - p_{i,v}^p) \times (p_{i,k}^p - p_{i,w}^p)} \right|}. \quad (8)$$

式中 u 、 v 、 w 为来自 M_i 的对应特征点。对于 ${}_w F_{i+1}^e$ 中的一个边特征 $p_{i+1,k}^e$ 对应 M_i^e 中的 2 个边特征点 $p_{i,u}^e$ 和 $p_{i,v}^e$ 。对于 ${}_w F_{i+1}^p$ 中的一个面特征 $p_{i+1,k}^p$ 对应 M_i^p 中的 3 个面特征点 $p_{i,u}^p$ 、 $p_{i,v}^p$ 和 $p_{i,w}^p$ (3 点不共线)。然后构建特征点到面距离或特征点到线距离最小残差方程：

$$\min \left\{ \sum_{T_{i+1}} d_{ek} + \sum_{p_{i+1,k}^p \in {}_w F_{i+1}^p} d_{pk} \right\}. \quad (9)$$

由于地面的面特征点对于垂直方向有较好约束，而非地面的边特征点和面特征点对水平方向有较好约束，故笔者采用两步优化求解的方式，先利用地面的面特征点估算 Z 方向、横滚角、俯仰角的信息，再利用非地面的边特征点和面特征点估算 X 方向、 Y 方向、方位角的信息，最终联合两步优化

$$T = \begin{bmatrix} \cos\theta \cos\psi & \cos\psi \sin\phi \sin\theta - \cos\phi \sin\psi & \cos\phi \cos\psi \sin\theta + \sin\theta \sin\psi & x_{\text{UTM}_0} \\ \cos\theta \sin\psi & \cos\phi \cos\psi + \sin\phi \sin\psi \sin\theta & -\cos\psi \sin\phi + \cos\phi \sin\theta \sin\psi & y_{\text{UTM}_0} \\ -\sin\theta & \cos\theta \sin\phi & \cos\phi \sin\theta & z_{\text{UTM}_0} \\ 0 & 0 & 0 & 1 \end{bmatrix}. \quad (10)$$

式中： ϕ 、 θ 和 ψ 分别为 UTM 坐标系下的横滚角、俯仰角和偏航角； x_{UTM_0} 、 y_{UTM_0} 和 z_{UTM_0} 分别为机器人在 UTM 坐标系下的初始位置。当新的节点添加到因子图中时，将 GNSS 因子按激光雷达帧时间戳插值出 GNSS 测量值，以达到时间同步。

针对机场环境下点云数据较少，无法进行精确定位的问题，同时为减少计算量，笔者采用增量式加入 GNSS 因子的方法，当移动机器人位姿方位变化超过 20° 或者当前雷达关键帧点云数据小于阈值（笔者定义边特征点小于 200 或面特征点小于 500）时，增量式加入 GNSS 因子，形成 GNSS 因子约束。

2.4 因子图优化

对于具有多个变量的全局函数，使用“二分图”将其分解成 n 个含有部分变量的局部函数的乘积，这种分解被称为因子图^[16]。因子图优化是将优化问题转换为因子图的形式，是求解多传感器定位问题的有效方法。本文中方法的因子图模型如图 4

利用高斯牛顿法迭代求解激光雷达 2 个关键帧的相对位姿，以降低室外环境下 SLAM 的积累误差^[11]。

2.3 GNSS 因子

在机场测试环境下，GNSS 数据具有不发散特性，可以将激光雷达 SLAM 的漂移误差控制在一定范围内，故能有效解决激光雷达 SLAM 的匹配精度漂移问题。而且对于点云数据较少的机场跑道环境，激光雷达无法进行精确定位，需要使用 GNSS 数据进行辅助定位。但在机场辅助路环境下，GNSS 数据易受到行道树、机棚等地物遮挡导致定位精度不稳定，直接使用 GNSS 数据会产生错误解^[14]。

针对此问题，笔者先构建滑动窗口，基于窗口内 GNSS 数据标准差和 GNSS 定位误差剔除误差较大的数据点和虚假高精度数据点。当某时刻测量值被剔除，使用窗口内历史数据拟合出新的观测值。当窗口内状态数量超过阈值时，对旧状态进行边缘化处理，将 GNSS 约束信息转化为先验因子，确保原有的约束关系不变。

将 GNSS 数据从 UTM 坐标系（通用横墨卡托格网系统坐标）转换成机器人的世界坐标系。其转换关系为^[15]：

所示。




图 4 基于因子图优化的多传感器 SLAM 系统框架

图 4 中： x 表示移动机器人状态； f_{IMU} 表示 IMU 预积分因子； f_{lidar} 表示雷达里程计因子； f_{GNSS} 表示 GNSS 因子； f_{loop} 表示回环因子。

因子图优化就是调整各变量的值，使其因子乘积最大。故根据因子图原理和贝叶斯法则可得系统状态的最大后验概率密度 X^* 为：

$$X^* = \arg \max_X P(X|Z) = \arg \max_X P(Z|X)P(X_0) = \arg \max_X \prod_k f_i(x_i). \quad (11)$$

由于因子图中因子通常服从高斯分布：

$$X^* \propto \exp \left\{ -\frac{1}{2} \|r_i(x)\|_{\Sigma_i}^2 \right\}。 \quad (12)$$

对右边函数取负对数，可将问题转化为一个非线性最小二乘问题：

$$X^* = \arg \min_x \left(\sum_k \|r_i(x)\|_{\Sigma_i}^2 \right)。 \quad (13)$$

式中： r 为各因子残差； Σ 为噪声协方差。

为解决上述非线性最小二乘问题，笔者采用 GTSAM 优化库中的 iSAM2 优化算法进行求解，解算出最优位姿信息。

3 试验结果与分析

为验证本文中方法的有效性，采用如图 5 所示的四轮差速移动机器人作为试验平台。该平台搭载 16 线束激光雷达、GNSS 定位终端(北斗定位)、GNSS 天线、IMU 传感器、显示屏、工控电脑(含 Ubuntu18.04 及 ROS 机器人操作系统)以及网络设备，试验各传感器型号及参数信息如表 1 所示。




图 5 试验平台

试验平台采用硬件同步的方式将不同传感器的时间统一到 GNSS 时间系统下。GNSS 模块连续向激光雷达发送 GPRMC 数据和 PPS 同步脉冲信号，PPS 同步脉冲长度为 20~200 ms，GPRMC 数据在同步脉冲上升沿 500 ms 内完成，以此保证数据的采集时间同步。在完成传感器时间同步后，还需要进一步确定传感器之间的空间关系，各传感器安装好后，将各传感器位置坐标写入统一机器人描述格式(unified robot description format, URDF)模型，然后发布到 TF 树中，实现各传感器的空间标定。

表 1 试验各传感器型号及参数信息

设备	型号	参数信息
激光雷达	RS-LiDAR-16	测距：40~150 m
		精度：±2 cm
		视角(垂直)：±15° 视角(水平)：360° 角分辨率(垂直)：2° 角分辨率(水平)：0.1°~0.4° 转速：5~20 Hz
GNSS 定位终端	F-V111	定位模块：北斗星通 UM482 通道：432 ch 频点：BDS B1/B2, GPS L1/L2, GLONASS L1/L2, Galileo E1/E5b RTK 定位精度：平面 1cm±1ppm, 高程 1.5cm±1ppm 定向精度：0.2° 时间精度：20 ns
		测量维度：加速度 3 维，角速度 3 维，角度 3 维
		量程：加速度±6 g, 角速度±2 000 ((°)/s), 角度 XZ 轴±180°、Y 轴±90° 分辨率：加速度计 0.000 75 g, 陀螺仪 0.061 ((°)/s) 误差：XY 轴 0.05°、Z 轴 0.5°
IMU 传感器	HWT605-TTL/232	

为验证本文中方法的有效性，选择在机场辅助路和较为空旷的机场跑道模拟机场环境进行数据获取，试验平台行驶速度为 1 m/s，以 1 Hz 的频率将建图的实时位姿数据保存下来，再通过 Matlab 绘图。机场辅助路存在移动车辆和行人的干扰，路边有行道树，移动轨迹不存在回环；机场跑道环境较为空旷，点云数据稀疏。将本文中方法与主流的 LeGO-LOAM、LIO-SAM 方法进行对比，通过计算各 SLAM 方法的位姿轨迹与真实轨迹的绝对轨迹误差(APE)来评定各 SLAM 方法的定位精度。

在机场辅助路试验的各 SLAM 方法的试验结果及 APE 统计表如图 6 和表 2 所示。试验长度为 560 m。LeGO-LOAM 方法的轨迹明显与实际轨迹偏离较大，且轨迹 APE 的 RMSE 为 16.257 m，而 LIO-SAM 方法的轨迹和本文中方法的轨迹与真实轨迹吻合较好，随着行驶距离增大，轨迹在后半段出现较大误差，但本文中方法的轨迹 APE 的 RMSE 更小，轨迹更加精确，比 LeGO-LOAM 和 LIO-SAM 方法精度提升了 15.426、0.211 m，主要原因是该场景存在行道树和移动的行人、车辆，外部特征不够明显，且不存在回环约束，使 LIO-SAM 方法点云匹配出现退化，加大了点云匹配的积累误差；笔者采用提取边、面特征点，并结合两步优化策略，有效降低 SLAM 积累误差，提高了点云匹配精度。同时，加入 GNSS 因子的本文中方法可以进一步降低 SLAM 积累误差，轨迹 APE 的 RMSE 由 1.220 m 提升到 0.050 m，能有效提升 SLAM 定位精度。




图 6 机场辅助路场景各 SLAM 方法的试验结果

为验证本文中方法在空旷条件下的有效性，笔者还选择在机场跑道进行试验。如图 7 所示，黑线表示移动机器人实际运动轨迹，长度为 600 m。本文中方法与 LIO-SAM 方法均加入 GNSS 因子，各 SLAM 方法的轨迹对比结果和轨迹 APE 统计结果如图 8 和表 2 所示，N/A 表示运行失败。



图 7 机场跑道试验区




图 8 机场跑道场景各 SLAM 方法的试验结果

表 2 各场景 SLAM 轨迹 APE 统计结果对比 m

场景	方法	最小值	最大值	平均值	RMSE
机场 辅助 路	LeGO-LOAM	0.035	19.428	10.441	16.257
	LIO-SAM	0.032	3.756	1.515	0.831
	our-odom	0.054	2.586	1.069	0.620
	our-method	0.005	0.238	0.044	0.050
机场 跑道	LeGO-LOAM	N/A	N/A	N/A	N/A
	LIO-SAM	0.015	25.542	1.563	0.286
	our-odom	N/A	N/A	N/A	N/A
	our-method	0.021	0.372	0.046	0.063

由于机场跑道环境点云稀疏，LeGO-LOAM 方法会导致激光雷达特征匹配发生错误，其轨迹存在明显漂移，且无法通过后续运动进行矫正。LIO-SAM 方法的轨迹存在多次跳变，如图 9 所示，

由于环境点云稀疏，激光雷达定位出现错误，直至 GNSS 数据加入后，轨迹才得到矫正。轨迹 APE 的最大值为 25.542 m，RMSE 为 0.286 m。本文中方法的轨迹较为平滑，轨迹 APE 的 RMSE 为 0.063 m，主要原因是 LIO-SAM 方法只是简单地将 GNSS 因子加入联合优化中用于漂移误差补偿，未考虑 GNSS 数据异常和点云稀疏的结果，而笔者采用滑动窗口消除了 GNSS 数据异常值，并在点云稀疏环境下和机器人姿态变换较大时增量加入 GNSS 位姿约束，有效提高 SLAM 定位精度。




图 9 2 种方法同一位置轨迹对比

4 结论

笔者面向机场环境下智能机器人自主定位要求，融合了 IMU 预积分因子、雷达里程计因子、GNSS 因子和回环因子，提出了一种基于因子图优化的紧耦合多传感器 SLAM 方法。该方法利用边特征点和面特征点并结合两步优化策略进行点云特征匹配，再采用滑动窗口消除 GNSS 数据异常值，并在点云稀疏环境下和机器人方位变化超过 20°时增量加入 GNSS 因子，有效提高机场环境下 SLAM 定位精度。试验结果表明：在机场辅助路环境下，LeGO-LOAM 方法定位精度较差；本文中方法与 LIO-SAM 方法精度同为分米级，但本文中方法精度(RMSE_{APE}=0.620 m)优于 LIO-SAM 方法(RMSE_{APE}=0.831 m)；加入 GNSS 因子后，精度提升至厘米级(RMSE_{APE}=0.050 m)。当在机场跑道环境中，本文中方法的轨迹较为平滑，无偏移问题，且精度达到厘米级(RMSE_{APE}=0.063 m)。本文中方法可适用于机场测试环境下 SLAM 建图要求。

参考文献：

[1] DEBEUNNE C, VIVET D. A review of visualLiD-AR fusion based simultaneous localization and mapping[J]. Sensors, 2020, 20(7): 2068.

[2] LIU R, WANG J, ZHANG B. High definition map for automated driving: overview and analysis[J]. The Journal of Navigation, 2020, 73(2): 324-341.

[3] LLCI V, TOTH C. High definition 3D map creation using GNSS/IMU/LiDAR sensor integration to support autonomous vehicle navigation[J]. Sensors, 2020(3): 899.

- [4] 陆世东, 涂美义, 罗小勇. 基于图优化理论和 GNSS 激光 SLAM 位姿优化算法[J]. 激光与光电子学进展, 2020, 57(8): 216-225.
- [5] PIERZCHAŁA M, GIGUÈRE P, ASTRUP R. Mapping forests using an unmanned ground vehicle with 3D LiDAR and graph-SLAM[J]. Computers and Electronics in Agriculture, 2018, 145: 217-225.
- [6] 王铨彬, 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.
- [7] SCHLEICHER D, BERGASA L M, OCANA M, et al. Realtime hierarchical GPS aided visual SLAM on urban environments[M]. Berlin: Computer aided systems theory, 2009.
- [8] SHAN T, ENGLT 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). Las Vegas, NV, USA: IEEE, 2020: 5135-5142.
- [9] 闫利, 戴集成, 谭骏祥, 等. SLAM 激光点云整体精配准位姿图技术[J]. 测绘学报, 2019, 48(3): 313-321.
- [10] FORSTER C, CARLONE L, DELLAERT F, et al. On-manifold preintegration for real-time visual-inertial odometry[J]. IEEE Transactions on Robotics, 2016, 33(1): 1-21.
- [11] SHAN T, ENGLT B. LeGO-LOAM: Lightweight and ground optimized LiDAR odometry and mapping on variable terrain[C]//Proceedings of 2018 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS). Madrid, Spain: IEEE, 2018: 4758-4765.
- [12] ZHANG J, SINGH S. Low-drift and real-time lidar odometry and mapping[J]. Autonomous Robots, 2017, 41: 401-416.
- [13] MORE J J. The Levenberg-Marquardt algorithm: implementation and theory[M]. Berlin: Numerical analysis, 1978: 105-116.
- [14] 孙喜亮, 关宏灿, 苏艳军, 等. 面向高精度城市测绘的激光紧耦合 SLAM 方法[J]. 测绘学报, 2021, 50(11): 1585-1593.
- [15] MOORE T, STOUCH D. A generalized extended Kalman filter implementation for the robot operating system[C]//Intell: gent Systems and Computing. Switzerland: Springer, 2014: 335-348.
- [16] 黄紫如, 柴洪洲, 向民志, 等. 考虑信息滞后的 AUV 因子图多源信息融合定位算法[J]. 中国惯性技术学报, 2021, 29(5): 625-631.
- *****
- (上接第 49 页)
- ### 参考文献:
- [1] 周玉臣, 林圣琳, 马萍, 等. 武器装备效能评估研究进展[J]. 系统仿真学报, 2020, 32(8): 1413-1424.
- [2] XU S Q, LIN C. Evaluation of the technical status of ship equipment based on the improved TOPSIS method[J]. Journal of Physics: Conference Series, 2022, 2359(1): 012010.
- [3] 于小岚, 熊伟, 韩驰. 基于神经网络的效能评估方法综述[J]. 兵工自动化, 2023, 42(3): 1-8, 43.
- [4] 王凤山, 郭子曜. 基于 BP 神经网络的渡江工程信息控制效能评估[J]. 兵工自动化, 2023, 42(3): 15-20.
- [5] CHO J, LEE J. Development of a new technology product evaluation model for assessing commercialization opportunities using Delphi method and fuzzy AHP approach[J]. Expert Systems with Applications, 2013, 40(13): 5314-5330.
- [6] 吴欣蓬, 屈高敏. 基于 LMBP 神经网络的战斗机综合作战效能评估[J]. 西安航空学院学报, 2016, 34(5): 12-19.
- [7] 麻晓伟, 张琳. 基于 AE-BP 神经网络的地空导弹武器系统作战效能评估[J]. 空天预警研究学报, 2022, 36(6): 425-429.
- [8] 段尊雷, 任光, 李烨. 基于深度信念网络的轮机实操智能评估方法[J]. 大连海事大学学报, 2017, 43(3): 89-94.
- [9] 戚宗锋, 王华兵, 李建勋. 基于深度学习的雷达侦察系统作战能力评估方法[J]. 指挥控制与仿真, 2020, 42(2): 59-64.
- [10] 郝博, 刘力维, 谷继明. 基于麻雀搜索算法优化 BP 神经网络的弹丸射程预测研究[J]. 火炮发射与控制学报, 2024, 45(1): 10-15.