

DOI: 10.19650/j.cnki.cjsi.J2413280

激光雷达 IMU 紧耦合 SLAM 算法研究*

诸葛晶昌, 高宏, 罗其俊, 邢志伟

(中国民航大学电子信息与自动化学院 天津 300300)

摘要:传统激光雷达在 SLAM 过程中存在位姿估计累积误差大的问题且算法轻量化及实时性方面仍有改进空间。提出一种激光雷达和 IMU 紧耦合方式的方法,从点云去畸变、特征提取配准、紧耦合位姿估计 3 方面进行改进,针对激光雷达在高速运动过程中的点云畸变问题,提出一种构建连续时间域的运动矫正方法且考虑计算效率问题使用预拟合平面机制提取特征。应对特征匹配时 KNN 搜索代价大,提出一种追踪机制来降低计算复杂度。增强状态估计精准性,提出基于非线性几何观测器优化的框架。本方案在公共数据集上做了评估,与 LIO-SAM 和 Fast-LIO 相比,在轨迹的 APE 上分别下降 30.52% 和 21.36%,在计算效率上分别提升了 59.9% 和 43.7%。

关键词: 激光雷达; 特征提取; 点云扭曲; 非线性几何观测器

中图分类号: TP391 TH39 **文献标识码:** A **国家标准学科分类代码:** 510.80

Research on tightly coupled SLAM algorithm for LiDAR IMU

Zhuge Jingchang, Gao Hong, Luo Qijun, Xing Zhiwei

(School of Electronic Information and Automation, Civil Aviation University of China, Tianjin 300300, China)

Abstract: Traditional LiDAR systems encounter significant challenges with pose estimation accumulation errors during SLAM and require improvements in algorithm efficiency and real-time performance. This paper introduces a tightly coupled LiDAR-IMU integration method with enhancements in three key areas: Point cloud undistortion, feature extraction and registration, and tightly coupled pose estimation. To mitigate point cloud distortion caused by high-speed motion, a continuous time-domain motion correction method is proposed, along with a pre-fitting plane mechanism for feature extraction to balance accuracy and computational efficiency. To address the high computational cost of KNN search during feature matching, a tracking mechanism is introduced to reduce complexity. For improving state estimation accuracy, the method employs a framework optimized using a nonlinear geometric observer. Evaluation on public datasets demonstrates that the proposed method reduces trajectory APE by 30.52% and 21.36% compared to LIO-SAM and Fast-LIO, respectively. Additionally, computational efficiency improves by 59.9% and 43.7%, making the method highly effective for real-time applications.

Keywords: LiDAR; feature extraction; point cloud distortion; nonlinear geometric observer

0 引言

即时定位与地图构建(simultaneous location and mapping, SLAM)是机器人感知、识别和规划的基础研究。在现有传感器中,三维激光雷达可以提供精确的环境感知信息,惯性测量单元(inertial measurement unit, IMU)通过高频测量为机器人提供位姿信息,因此两者融合的方式被广泛部署于此类任务中。现阶段随着深度学习的快

速发展,在该类任务中有超越传统激光雷达和 IMU 里程计(LiDAR inertial odometry, LIO)的趋势,但深度学习不同数据集泛化能力差且需要大功率图像处理器(graphics processing unit, GPU)的算力加持,同时在机器人任务中 LIO 是基础功能,为了保证功能的稳健性,降低系统的时空复杂度势在必行。激光雷达算法通过解决非线性最小二乘问题来对齐点云,从而将对应的点或平面上的误差最小化。为了找到对应点/面关系。文献[1-2]提出的迭代最近点算法(iterative closest point, ICP)或文献[3]提

出的基于广义迭代最近点算法 (generalized iterative closest point, GICP) 递归匹配结果, 直到对齐收敛到全局最小值。面对大量点的对应关系时, 收敛时间会加大, 因此基于特征的方式被提出, Zhang 等^[4]提出的基于激光雷达算法 (LiDAR odometry and mapping in real-time, LOAM) 是基于局部曲率提取特征后分 2 步进行处理。LOAM 在一定程度上依赖良好的初始位置和姿态估计。面对特征点分布稀疏或不均匀的环境中, LOAM 的性能会下降。陈文浩等^[5]提出的基于地面特征的 SLAM 算法 (lightweight and ground-optimized LiDAR odometry and mapping on variable terrain, LeGo-LOAM) 由于扫描到扫描的匹配方式受视野小的限制匹配数据少, 由此文献[6-8]引入了关键帧的概念, 它预先设定几个扫描结果构建子地图, 在本地映射中执行 K 邻近算法 (K-nearest neighbor classification, KNN) 搜索来保证足够的匹配。Ye 等^[9]提出的 SLAM 算法 (tightly coupled 3D LiDAR inertial odometry and mapping, LIO-Mapping) 加入旋转约束优化将激光雷达位姿对准全局地图。Zhou 等^[10]引入了平面调整机制, 用于优化 SLAM 过程中的点云映射解决平面物体的“双面问题”。Zhou 等^[11]提出的 SLAM 算法 (LiDAR slam with planes, lines, and cylinders, PLC-LiSlam) 利用了平面、线条和圆柱体这 3 种几何特征来提高 SLAM 的精确性和鲁棒性。田赢等^[12]提出的特征提取简化算法因聚类算法不稳定, 不能保证每次都能获得很好的聚类效果。

即使采用并行处理的方式, 面对特征提取需要使用 KNN 搜索, 进而需要构建耗时的树形数据结构 (K-dimensional tree, KD 树)。为提高计算效率, 大多数情况下没有必要进行严格的 KNN 搜索且三维点云在平面分割上也有广泛研究。文献[13]提出的区域增长平面分割方法和文献[14]基于三维霍夫变换的连续平面检测方法都是两大主流, 但对于实时性要求高的 LIO 而言, 计算量也是繁重的。

激光雷达里程计方法根据融合其他传感器的方式分两类。松耦合方法有文献[15]提出的扩展 LOAM 算法 (LiDAR odometry for consistent operation in uncertain settings, Locus), 文献[16]提出激光雷达-惯性可观测感知导航算法 (LiDAR-inertial observability-aware navigator, Lion), 文献[17]提出分布式激光雷达 SLAM 算法 (distributed lidar odometry and mapping, D-Loam)。IMU 会通过先验来对激光雷达的扫描进行增强, 但由于松耦合方式, 里程计和映射的数据同步和一致性管理可能会更加复杂, 尤其是在处理高动态或复杂环境时导致定位结果不太准确。紧耦合的方式有基于因子图 SLAM 算法 (LiDAR inertial odometry via smoothing and mapping, LIO-SAM), 文献[18]提出基于扩展卡尔曼滤波器的 SLAM 算

法 (fast-LiDAR inertial odometry, Fast-LIO), 文献[19]提出基于多状态约束卡尔曼滤波器紧耦合 SLAM 算法 (multi-state constraint kalman filter LiDAR inertial odometry, MSCKF-LIO)。紧耦合方式通常采用文献[20]提出的基于图优化方式或卡尔曼滤波器基本框架及其变体。但图优化的结果对初始估计比较敏感, 尤其是高度非线性的环境中, 且随着状态节点和观测数量的增加, 对于实时性的要求难以保证。卡尔曼滤波器的性能又高度依赖于过程和测量噪声的准确模型, 且滤波器是递归的不可进行全局优化, 无法对之前的数据进行全面分析。与几何观测器相比较而言, 即使是最理想的设置下, 上述两个方法具有最小的收敛保证。当传感器数据融合不一致会导致定位误差且当高速运动扫描位置不正确产生地图变形。

融合 IMU 可以帮助纠正高速运动引起的点云失真。LIO-SAM 使用 IMU 数据通过预积分技术来矫正点的位置, 补偿运动引起的畸变, 通过图优化方式精确估计出每个时刻的位姿信息。Fast-LIO 和文献[21]提出 Fast-LIO2, 用 IMU 测量值的前向传播对点云时间戳采用反向传播步骤完成完整点云的相对转换。但以上方法都是离散时间内完成的, 会导致部分精度的损失。Dellenbach 等^[22]提出的基于连续时间的 ICP 算法的虽然仅使用两个姿态参数化的连续时间来定义运动轨迹, 但面对高速动态运动时轨迹建模方面仍存在不足和计算成本高的问题。

为此, 本文将把重点放在对一套抗扭曲, 精度高, 低复杂度的实时系统的研究上。提出一种从粗到精的方法来对每次扫描进行矫正。首先通过 IMU 的测量计算出一组离散的位姿信息, 再推导出一组具有恒定冲击加速度和角加速度的运动解析方程来平滑轨迹。仅通过对时间戳参数化可以更容易进行并行处理。在 LIO 系统配准过程中, 采用更加主动的平面预拟合的方式, 消除冗余的 KNN 搜索和平面匹配且利用 IMU 和激光雷达的扫描特性对本地地图进行增量式更新, 再加入夹层设计来减少误匹配现象。运动矫正和配准过程可以并行执行, 为了保证多传感器快速的位姿估计收敛, 采用新的非线性几何观测器, 以最小的计算复杂度生成精确的机器人位姿估计。最后, 该方案通过数据集和大量实验进行验证。

1 系统概述

本文通过独特的架构完成机器人的状态估计和几何地图构建, 该架构包含 2 个组件:

1) 快速扫描匹配器: 该匹配器通过预拟合平面和追踪机制工作, 能够将经过运动矫正的密集点云精确地匹配到机器人地图上。此方法的核心在于保证点云的最大

保真度,确保地图的准确性和实时性。

2) 非线性几何观测器:利用第 1 个组件输出的位姿信息和 IMU 的位姿信息来更新系统状态。该观测器的设计确保了估计的全局收敛性,即在全局范围内能够达到稳定和一致的状态估计。得到初步位姿估计后,系统将此信息用于初始化后续的运动矫正、扫描匹配和状态更新的迭代过程,从而提高整体系统的效率和准确性。

本系统的总体框架如图 1 所示。




图 1 总体框架

Fig. 1 Overall framework

对于每次扫描的激光雷达输入,先补偿运动失真,提取平面特征点并快速计算点对平面的残差。之后在迭代卡尔曼滤波后输出位姿信息,将激光雷达输出的位姿信息与 IMU 紧密融合,并将融合后的位姿信息更新到新的局部地图中。为了提升测量的准确性,利用非线性几何观测器对激光雷达和 IMU 位姿估计修正后得出更加准确估计值。

2 算法描述

2.1 基于数学模型的运动补偿机制

假设激光雷达扫描从 t_k 时开始,扫描点云记作 P_k ,完成 1 次激光雷达扫描会由 $p_k^n \in R^3$ 个点构成,其中采样时间间隔为 $\Delta t_k^n, n = 1, 2, 3, \dots, N, N$ 代表扫描总的点数。世界坐标系记作 W ,移动平台坐标系以质点为原点,符合右手定则, z 轴向上, x 轴向前, y 轴向左,记作 O ,激光雷达坐标系记作 L ,IMU 坐标系记作 B ,移动平台状态矢量记作 x_k

$$x_k = [p_k^w, q_k^w, v_k^w, b_k^a, b_k^\omega]^T \quad (1)$$

$p^w \in R^3$ 为移动平台位置, $q^w \in S^3$ 为用 4 元数表示的方向向量, $v^w \in R^3$ 为移动平台速度, $b^a \in R^3$ 为加速度偏差, $b^\omega \in R^3$ 为陀螺仪偏差。IMU 提供的 $\hat{a}, \hat{\omega}$ 如下表示

$$\hat{a}_i = (a_i - g) + b_i^a + n_i^a \quad (2)$$

$$\hat{\omega}_i = \omega_i + b_i^\omega + n_i^\omega \quad (3)$$

索引值 $i = 1, \dots, M, M$ 为在 $[t_{k-1} \sim t_k]$ 时间段内的测量次数,IMU 测量值 a_i 和 ω_i 包含了偏差 b_i 和噪声 n_i , g 为旋转重力矢量。

该机制要解决的问题是给定一个积累点云 P_k 和在

激光雷达采样间隔内的 IMU 测量值 a_i 和 ω_i ,估计移动平台去扭曲状态矢量 $\hat{x}_i^w$ 。本方案采用机械式激光雷达和 9 轴 IMU,采样频率分别为 10 和 200 Hz。首先,通过已知的外参标定对采集到的激光雷达和 IMU 数据转换到移动平台坐标系下,为了减少点云损失,将采用 1 m^3 的体素块对扫描点云进行预处理,滤掉移动平台自身点云。机械式激光雷达在一帧数据采集时间内由于高速运动会产生扭曲点云,如图 2 所示,这种高速运动并不能简单的假设为恒定速度直线运动,因此在 1 帧数据周期内,不能够很准确的追踪到某一时刻的位置信息。基于上述思考,现拟用一个精确的连续冲击和角加速度模型来得出相对准确的转移矩阵来矫正偏斜。其目的在于减少由 IMU 离散采样频率和 IMU 与激光雷达追踪点之间的时间偏移所带来的误差。该机制先通过 IMU 积分对运动轨迹进行粗略预估,随后通过求解一组连续时间方程来细化预估,示意如图 2 所示。




图 2 去扭曲

Fig. 2 Diagram of distortion removal

令 t_k 为接受点云 P_k 的时间起点且在时间段内进行进行了 N 次点云积累。令以 $t_k + \Delta t_k^n$ 为时间戳的点 $p_k^n \in P^k$,为了预估每个点在 W 中的位置,先通过如下公式在 $[t_{k-1}, t_k + \Delta t_k^N]$ 内整合 IMU 粗估计结果。

$$\begin{aligned} \hat{p}_i &= \hat{p}_{i-1} + \hat{v}_{i-1} \Delta t_i + \frac{1}{2} \hat{R}(\hat{q}_{i-1}) \hat{a}_{i-1} \Delta t_i^2 + \frac{1}{6} \hat{J}_i \Delta t_i^3 \\ \hat{v}_i &= \hat{v}_{i-1} + \hat{R}(\hat{q}_{i-1}) \hat{a}_{i-1} \Delta t_i \end{aligned} \quad (4)$$

$$\hat{q}_i = \hat{q}_{i-1} + \frac{1}{2} (\hat{q}_{i-1} \otimes \hat{\omega}_{i-1}) \Delta t_i + \frac{1}{4} (\hat{q}_{i-1} \otimes \hat{\alpha}_i) \Delta t_i^2$$

其中, $i = 1, \dots, M, M$ 为 IMU 在 2 次扫描中的次数, $\hat{J}_i = \frac{1}{\Delta t_i} (\hat{R}(\hat{q}_i) \hat{a}_i - \hat{R}(\hat{q}_{i-1}) \hat{a}_{i-1})$, $\hat{\alpha}_i = \frac{1}{\Delta t_i} (\hat{\omega}_i - \hat{\omega}_{i-1})$ 为估计的线冲击加速度和角加速度,数据集 $\hat{T}_i^w$ 为 $\hat{p}_i$ 和 $\hat{q}_i$ 间的齐次变换矩阵,定义了扫描段内的粗略的离散时间轨迹。之后通过连续时间恢复从最近的前一变换到每一个点 p_k^n 的去扭曲变换,如下式:

$$\hat{p}^*(t) = \hat{p}_{i-1} + \hat{v}_{i-1} t + \frac{1}{2} \hat{R}(\hat{q}_{i-1}) \hat{a}_{i-1} t^2 + \frac{1}{6} \hat{J}_i t^3 \quad (5)$$

$$\hat{q}^*(t) = \hat{q}_{i-1} + \frac{1}{2} (\hat{q}_{i-1} \otimes \hat{\omega}_{i-1}) t + \frac{1}{4} (\hat{q}_{i-1} \otimes \hat{\alpha}_i) t^2$$

其中, $i-1$ 和 i 时刻分别对应最近的先前和后续的 IMU 测量, t 为 p_k^n 和最近的先前 IMU 之间的时间段, 由式 (5) 得知, 预测方程仅有一个参数 t , 因此可针对任意时间查询变换来构造连续时间轨迹, 由此来输出去扭曲的点云 $\hat{p}_k^w$ 。

2.2 预拟合平面和追踪机制

该机制的核心方法由 5 部分构成: 预拟合平面 (pre-fit plane, PFP), 迭代主成分分析 (principal component analysis, PCA), 增量式主成分分析 (interactive principal component analysis, iPCA), 追踪和夹层结构。

预拟合平面: 如图 3 所示, 每个扫描出的曲面是构成出三维场景的基本要素, 其分割出的曲面是该场景的全局几何特征面, 称为核心平面, 见图 3(b)。




Fig. 3 Fit the schematic diagram of the plane

该核心平面作为局部地图是独立存储维护, 无需 KNN。预拟合过程首先对输入的去扭曲的点云进行特征提取, 一般选用迭代算法 (random sample consensus, RANSAC) 对点云的曲面进行迭代提取, 完成曲面提取后会与下次输入的点云依据点到平面的距离将点云区分为 3 种, 分别为内联点, 半内联点, 离群点。内联点数据保留, 半内联点数据舍弃, 离群点再次送入迭代主成分分析过程。迭代结束的条件是不能再提取平面或离群点过少。

iPCA: 由于激光雷达和 IMU 的数据都会带有噪声。即使在现实生活中的平面提取的点与对应的平面之间也会存在偏移, 当平面存在不均匀分布时, 点到面的偏移问题会更加凸显。由 KNN 算法可知, 该算法会依据 K 个最近邻的点拟合平面, 该平面由局部空间确定, 当遇到平面分布不均匀时, 局部平面无法表征全局几何结构, 出现明显的退化问题, 会给配准工作带来偏差, 而基于核心平面的结构是全局空间拟合得来, 在配准精度上会避免上述局部空间拟合所带来的精度损失且迭代配准过程收敛更快。匹配过程如图 4 所示。

增量拟合: 因此相邻激光雷达几何结构类似, 一般是相似的, 为了节约计算成本, 避免重复 RANSAC 迭代, 采用增量式方法对核心平面进行迭代。首先通过式 (5) 获取 p_k^b , 接下来对每个激光雷达扫描点 P_k 提取核心平面




图 4 KNN 退化说明及 iPCA 迭代提取平面
Fig. 4 Explanation of KNN degradation and iterative extraction of plane using iPCA

$f_{L_{k-1}}$ 并通过如下方式获得初始核心平面猜想。

$$f_{init} = f_{L_k} = (\Delta T^{-1})^T f_{L_{k-1}} \quad (6)$$

$$\Delta T = \begin{bmatrix} R_B^L R_{B_k}^{B_{k-1}} (R_B^L)^T R_{B_k}^L p_k^B + t_B^L - R_{L_k}^{L_{k-1}} t_B^L \\ \mathbf{0}_{1 \times 3} \mathbf{1} \end{bmatrix} \quad (7)$$

R_B^L 和 t_B^L 是激光雷达和 IMU 的外参标定结果, 当 f_{init} 通过了内联层检查被接受后, 会开始 iPCA 迭代拟合出一个平面之后开始对点云中的点开始进行 RANSAC 迭代。

基于核心平面的追踪机制: 在进行 iPCA 之后, 将内联点 $\hat{p}$ 放到一个集合中, 记作 N 。将离群点 $\check{p}$ 放到另一个集合中, 记作 S 。对于每一个内联点 $\hat{p}$ 都可匹配到一个对应的核心平面, 记作 F , 在全局地图中, F 被用作为滑动窗口其中包含多个 f 子平面。残差计算被视为点到面的距离计算:

$$e_N(\hat{p}) = \begin{cases} 0, & \min_{f \in F} \{ |f \cdot \hat{p}| \} \geq \varepsilon \\ \min_{f \in F} \{ |f \cdot \hat{p}| \}, & \text{其他} \end{cases} \quad (8)$$

对于 S 中的 $\check{p}$ 而言, 会被重新送回 iPCA 进行迭代, 将采用局部地图构建用 KNN 拟合平面, 残差是基于 $\check{p}$ 与局部拟合平面的距离。

$$e_S(\check{p}) = |f_{KNN} \cdot \check{p}| \quad (9)$$

之后采用增量扩展卡尔曼滤波器 (iterated extended Kalman filter, IEKF) 来求解最优变换。

$$\min_{T_k} \left\{ \sum_{\hat{p} \in N} e_N(\hat{p}) + \sum_{\check{p} \in S} e_S(\check{p}) \right\} \quad (10)$$

为下一次激光雷达扫描做准备, 将所有新拟合的平面 f_{L_k} 转到 W 下且将 f_w 加入到滑动窗口 F 。

夹层结构:在实际运行过程中,面临坡度变化的地形时,会出现拟合平面相交的情况发生,如果只单纯依赖点到面的距离来约束,会发生虚假匹配。如图 5 所示。




图 5 夹层结构

Fig. 5 Schematic diagram of sandwich structure

由于地形坡度变化影响,假设算法第 1 次扫描没有将斜坡拟合了平面加入到滑动窗口,那么斜坡中的点会很容易通过式(8)的检测,导致错误匹配。因此,在平面匹配前将点分为内联点,半内联点,离群点,半内联点的范围设置为 ε 且舍弃半内联点。算法实现流程图如图 6 所示。




图 6 预拟合平面和追踪机制框架

Fig. 6 Pre fitting plane and tracking mechanism framework

2.3 非线性几何观测器优化机制

通过预拟合平面和追踪机制将获得一个较为精确的激光雷达的旋转矩阵 T_L^w , 再与 IMU 测量结果通过非线性几何观测器进行全局收敛后获得更加精确的状态估计矢量 $\mathbf{x}_k$ 。现已验证非线性几何观测器可以通过最小的计算损失获得全局收敛的结果,利用压缩理论证明四元数状态估计指数收敛于四元数真值附近区域。观测器的状态估计修正形式如下。

$$\begin{aligned} \hat{\mathbf{q}}_i \hat{\mathbf{q}}_i + \Delta t_k^+ \gamma_1 \hat{\mathbf{q}}_i \otimes \begin{bmatrix} 1 - |\mathbf{q}_e^\circ| \\ \text{sgn}(\mathbf{q}_e^\circ) \vec{\mathbf{q}}_e \end{bmatrix} \\ \hat{\mathbf{b}}_i^\omega \leftarrow \hat{\mathbf{b}}_i^\omega - \Delta t_k^+ \gamma_2 \mathbf{q}_e^\circ \vec{\mathbf{q}}_e \\ \hat{\mathbf{p}}_i \leftarrow \hat{\mathbf{p}}_i + \Delta t_k^+ \gamma_3 \mathbf{p}_e \\ \hat{\mathbf{v}}_i \leftarrow \hat{\mathbf{v}}_i + \Delta t_k^+ \gamma_4 \mathbf{p}_e \\ \hat{\mathbf{b}}_i^a \leftarrow \hat{\mathbf{b}}_i^a - \Delta t_k^+ \gamma_5 \hat{\mathbf{R}}(\hat{\mathbf{q}}_i)^\top \mathbf{p}_e \end{aligned} \quad (11)$$

其中 $\gamma \in \{1, \dots, 5\}$ 是位姿常量, Δt_k^+ 是 IMU 在激光雷达中矫正的时间间隔, $\mathbf{q}_e = (\mathbf{q}_e^\circ, \vec{\mathbf{q}}_e) = \hat{\mathbf{q}}_i^* \otimes \hat{\mathbf{q}}_i$, $\mathbf{p}_e = \hat{\mathbf{p}}_k$

$-\hat{\mathbf{p}}_i$ 。可见,状态更新与平移更新是解耦状态且观测器的状态估计是非线性估计,可以保证位置估计足够精度。

3 实验验证

实验设备:工控机安装 ubuntu20 系统,cpu 为 i7-12700H,内存 64 G。实验平台构建如图 7 所示。本文算法验证分仿真验证和数据集验证两阶段,仿真验证阶段主要验证预拟合平面机制效率问题,通过与基于 KNN 的拟合机制对比验证前文论述方法先进性。数据集验证阶段实验分运动补偿机制的定性分析,系统精度的定量分析两部分验证。




图 7 实验平台

Fig. 7 Experimental platform

3.1 预拟合平面机制仿真

本文预拟合平面机制将与基于 KNN 的拟合机制做对比实验,考虑现实环境中的数据存在点云扭曲,IMU 测量误差等,为了模拟拟合平面和匹配机制,现选用带有高斯噪声的两个点云平面相距 1 m 作为 2 次激光雷达扫描的输入,将从拟合平面迭代次数与匹配耗时两方面做出对比,结果如图 8 所示。从图 8(a)可以看出本 PFP 对于噪声的鲁棒性更强。随着噪声强度增加,PFP 的收敛迭代次数以较低的速率增长。KNN 的不确定性会增加导致迭代次数增多,出现迭代次数增多的原因与理论部分相一致,是因为拟合平面距离中心平面有偏差,对优化产生误导。图 8(b)是对 KNN 和 PFP 两者在匹配总耗时上做出对比,KNN 由于迭代次数的增加导致计算残差上会带来大量耗时,且两者的计算效率相差很大。随着噪声增加,KNN 需要开销更多时间去完成不必要的搜索与迭代,而 PFP 主要是在维护局部地图时进行 iPCA 的收敛,一旦确定核心平面,在完成残差计算时就不会受干扰。

3.2 运动补偿机制定性分析

在追踪误差估计实验中,本方案为了验证所提方法对激光雷达的点云扭曲去除效果,将追踪和数据存储方案保持一致后进行对比试验。在数据集的选取上,采用了一个动态数据集测试,进行定性分析如图 9 所示。可以看出通过连续时间方程补偿后构建的点云地图在门窗的边缘处更加清晰。




图 8 拟合平面效率对比

Fig. 8 Comparison chart of fitting plane efficiency




图 9 运动补偿对比

Fig. 9 Comparison chart of motion compensation

3.3 实时性分析

评估数据集的系统运行时间(ms),一般分为残差计算、增量建图、IEKF 迭代、非线性优化 4 部分。因此,对于每个数据集,测试上述 4 个模块的时间成本,以及处理扫描的总时间。如表 1 所示,采用学校飞机坪采集的真实数据(APRON)本文方法处理 1 次扫描时间需要 10~15 ms,而 2 次扫描的时间间隔为 50 ms,这就意味着,该系统可以进行实时运行。

表 1 单次扫描耗时比较

Table 1 Comparison of time consumption for a single scan					
(ms)					
数据集、指标	残差计算	增量建图	IEKF	非线性优化	总耗时
APRON1	1.25	1.28	3.24	4.25	10.02
APRON2	1.35	1.87	4.51	5.06	12.79

3.4 系统精度评估

本文方法在 3 个不同的数据集和校内停机坪实测中进行评估,3 个不同数据集包括牛津大学机器人研究所公开的新建学院数据集(newer college dataset,NCD),密歇根大学北校区收集的大规模数据集(north campus long-term vision and LiDAR,NCLT),香港城市移动性研究的数据集(urban localization in Hong Kong,ULHK)。将其与 LIO-SAM、FAST-LIO 这 2 种算法进行比较。具体将从追踪误差、计算效率 2 个方面进行比较。为追求各算法性能最优,FAST-LIO 将关闭在线外参估计。LIO 的准确性用绝对位姿误差来评估,LIO 的效率由每次扫描匹配的平均运行时间来评估。实测数据以北斗导航定位模块采集的轨迹图作为真值。本文方法在位姿误差和效率方面进行评估,绝对位姿误差和耗时数值越小性能越好,具体见表 2、3。精度方面,通过绝对百分比误差(absolute percentage error,APE)来衡量。在所选的 NCD、NCLT、ULHK、实地场景下,本文方法与 Fast-LIO 相比,在 APE 上分别下降了 24.97%,19.32%,20.33%,20.83%,平均下降了 21.36%。效率方面,分别提升了 49.53%,43.98%,47.2%,34.4%,平均提升了 43.77%。

表 2 各算法 APE 比较

Table 2 Comparison of APE among various algorithms			
(m)			
数据集\算法	LIO-SAM	Fast-LIO	本文
NCD_1	0.105	0.089	0.059
NCD_2	0.205	0.198	0.153
NCD_3	0.362	0.317	0.302
NCD_4	0.297	0.21	0.189
NCLT_1	1.853	1.732	1.412
NCLT_2	1.655	1.487	1.187
ULHK_1	1.765	1.185	0.975
ULHK_2	1.986	2.044	1.575
APRON1	1.468	1.264	0.940
APRON2	0.394	0.241	0.202

所选数据集的真值轨迹(虚线)与本文所提方法获得的轨迹对比如图 10 所示。选用数据集是 NCD_1、NCD_2、NCD_3、NCD_4、APRON1、APRON2。通过结果看出,当运动遇到突然转向时虽然误差会加大,但可迅速的将误差矫正后缩小。整个系统可以完成位姿的精准估计。

不同算法的绝对百分比误差如图 11 所示。可以看出,虽几个算法整体的位姿估计偏差相差较小,但本文方法的偏差控制是最好的,与真值贴合度更好。对绝对百分比误差分析,本文算法与 LIO-SAM 相比,特征提取阶

表 3 各算法耗时比较

Table 3 Comparison of time efficiency across different algorithms (ms)

数据集\算法	LIO-SAM	Fast-LIO	本文
NCD_1	43.664	33.481	17.51
NCD_2	42.051	32.098	16.88
NCD_3	40.898	31.945	15.03
NCD_4	46.533	39.573	19.61
NCLT_1	23.135	20.165	11.45
NCLT_2	24.861	17.467	9.65
ULHK_1	17.682	13.584	6.56
ULHK_2	20.563	19.433	11.13
APRON1	18.545	15.472	10.02
APRON2	21.68	19.254	12.79




图 10 各数据集绝对百分比误差结果

Fig. 10 Absolute percentage error results for each dataset

段选用了更加合理的预拟合平面和追踪机制来加速计算,与 Fast-LIO 相比,在后端数据处理时,选用了收敛速度更快,精度更高的非线性几何观测器,保证了位姿估计的精准度。LIO-SAM 的 APE 中位数为 0.071, Fast-LIO 的 APE 中位数为 0.136,本文方法的 APE 中位数为 0.045。相较于另外 2 种算法误差控制的更低,波动相对小。




图 11 不同算法的绝对百分比误差估计

Fig. 11 Absolute pose error estimation for different algorithms

4 结 论

本文提出了一种实时进行位姿状态估计和地图构建的 LIO (LiDAR inertial odometry) 算法。该算法通过构建连续时间的粗到精处理流程,对初始点云进行逐点运动校正。这种运动校正方法适合并行处理,并已嵌入到 LIO 架构中。通过仿真实验,验证了 PFP 平面拟合在计算效率方面的优势。对于输入中带有高斯噪声的点云,拟合平面阶段的迭代收敛效率提高了 2 倍。仿真结果表明,KNN 的弱鲁棒性可以通过加入 iPCA 来迭代和维护滑动窗口,以此减少误匹配情况发生,通过夹层设计消除错误的点到平面的配准,从而进一步节省计算成本,最终,通过非线性观测器来保证强收敛性。位姿估计的精准度和计算耗时,与 LIO-SAM 和 Fast-LIO 相比,本文方法在轨迹的 APE 上分别下降 30.52% 和 21.36%,总体系统在计算耗时上分别减少 59.9% 和 43.7%

参考文献

[1] 王明明,龚芮,孙晓云,等. 一种面向复杂环境的自适应激光里程计设计[J]. 电子测量技术,2023,46(10): 16-23.

WANG M M, GONG R, SUN X Y, et al. Design of an adaptive laser odometer for complex environment [J]. Electronic Measurement Technology, 2023, 46 (10): 16-23.

[2] 龚国强,田演,夏鑫宇. 基于位姿参数估计的多视角点云配准方法[J]. 电子测量与仪器学报,2024,38(6): 241-252.

GONG G Q, TIAN Y, XIA X Y. Multi-view point cloud registration method based on pose parameter-

- stimulation [J]. Journal of Electronic Measurement and Instrumentation, 2024, 38(6): 241-252.
- [3] 徐晓苏, 高佳誉, 周帅, 等. 基于改进 GICP 配准的激光-惯性 SLAM 算法[J]. 中国惯性技术学报, 2023, 31(8): 814-822.
- XU X S, GAO J Y, ZHOU SH, et al. Laser-inertial SLAM algorithm based on improved GICP registration[J]. Chinese Journal of Inertial Technology, 2023, 31(8): 814-822.
- [4] ZHANG J, SINGH S J. LOAM: LiDAR odometry and mapping in real-time[J]. Robotics: Science and Systems, 2014.
- [5] 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.
- CHEN W H, LIU H X, YANG L T, et al. Research on improved LeGO LOAM algorithm based on IMU tight coupling[J]. Computer Application Research, 2021, 38(4): 1013-1016.
- [6] SHAN T X, ENLOT B, MEYERS D, et al. LIO-SAM: Tightly-coupled LiDAR inertial odometry via smoothing and mapping[J]. 2020 IEEE/RSJ International Conference on Intelligent Robots and Systems, 2020: 5135-5142.
- [7] LI K L, LI M, HANEBECK U D. Towards high-performance solid-state-LiDAR-inertial odometry and mapping[C]. International Conference on Robotics and Automation, 2021.
- [8] QIN CH, YE H Y, PRANATA C E, et al. LINS: A LiDAR-inertial state estimator for robust and efficient navigation[J]. 2020 IEEE International Conference on Robotics and Automation, 2020: 8899-8906.
- [9] YE H Y, CHEN Y Y, LIU M. Tightly coupled 3D LiDAR inertial odometry and mapping[J]. 2019 International Conference on Robotics and Automation, 2019: 3144-3150.
- [10] ZHOU L, KOPPEL D, KAESSE M. LiDAR SLAM with plane adjustment for indoor environment[J]. IEEE Robotics and Automation Letters, 2021, 6(4): 7073-7080.
- [11] ZHOU L P, HUANG G Q, MAO Y N, et al. PLC-LiSLAM: LiDAR SLAM with planes, lines, and cylinders[J]. IEEE Robotics and Automation Letters, 2022, 7(3): 7163-7170.
- [12] 田赢, 陈裕汉, 吴学群, 等. 点云特征提取精简方法研究[J]. 软件导刊, 2023, 22(12): 223-231.
- TIAN Y, CHEN Y H, WU X Q, et al. Research on simplification methods for point cloud feature extraction[J]. Software Guide, 2023, 22(12): 223-231.
- [13] WU H, ZHANG X, SHI W ZH, et al. An accurate and robust region-growing algorithm for plane segmentation of TLS point clouds using a multiscale tensor voting method[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2019, 12(10): 4160-4168.
- [14] 宋征玺, 吴洪, 王雪, 等. 基于三维霍夫变换的环形光场三维重建[J]. 西北工业大学学报, 2021, 39(1): 135-140.
- SONG ZH X, WU Q, WANG X, et al. 3D reconstruction of circular light field based on 3D hough transform [J]. Journal of Northwestern Polytechnical University, 2021, 39(1): 135-140.
- [15] PALIERI M, MORRELL B, THAKUR A, et al. LOCUS: A multi-sensor LiDAR-centric solution for high-precision odometry and 3D mapping in real-time [C]. International Conference on IEEE Robotics and Automation Letters, 2021.
- [16] TAGLIABUE A, TORDESILLAS J, CAI X, et al. LION: LiDAR-inertial observability-aware navigator for vision-denied environments[J]. Experimental Robotics, 2021: 380-390.
- [17] CHEN K, LOPEZ B T, AGHA-MOHAMMADI A A, et al. Direct LiDAR odometry: Fast localization with dense point clouds[J]. Robotics and Machine Learning Daily News, 2022: 31.
- [18] XU W, ZHANG F. FAST-LIO: A fast, robust LiDAR-inertial odometry package by tightly-coupled iterated kalman filter[J]. IEEE Robotics and Automation Letters, 2021, 6(2): 3317-3324.
- [19] 吕攀, 辛越, 张恒, 等. 基于 MSCKF 的 IMU 与激光雷达紧耦合定位方法[J]. 仪器仪表学报, 2020, 41(8): 13-20.
- LYU P, XIN Y, ZHANG H, et al. A close coupling localization method of IMU and LiDAR based on MSCKF[J]. Chinese Journal of Scientific Instrument, 2020, 41(8): 13-20.
- [20] 赵壮, 马国梁. 自适应滤波协同图优化导航方法研究[J]. 仪器仪表学报, 2023, 44(7): 271-281.
- ZHAO ZH, MA G L. Research on adaptive filtering collaborative graph optimization navigation method[J].

Chinese Journal of Scientific Instrument, 2023, 44(7): 271-281.

[21] XU W, CAI Y X, HE D J, et al. FAST-LIO2: Fast direct LiDAR-inertial odometry[J]. IEEE Transactions on Robotics; A Publication of the IEEE Robotics and Automation Society, 2022(4): 2053-2073.

[22] DELLENBACH P, DESCHAUD J E, JACQUET B, et al. CT-ICP: Real-time elastic LiDAR odometry with loop closure[J]. 2022 IEEE International Conference on Robotics and Automation, 2022:5580-5586.

作者简介



诸葛晶昌(通信作者),2003 年于天津大学获得学士学位,2006 年于天津科技大学获得硕士学位,2009 年于天津大学获得博士学位,现为中国民航大学电子信息与自动化学院副教授,主要研究方向为机场智能与自动化。

E-mail:12315414@qq.com

Zhuge Jingchang(Corresponding author) received his B. Sc. degree in 2003 from Tianjin University, received his M. Sc. degree in 2006 from Tianjin University of Science and Technology, received his Ph. D. degree in 2009 from Tianjin University. Now he is an associate professor in Civil Aviation University of China. His main research interests include Airport Intelligence and Automation.



高宏,2019 年于安徽工业大学获得学士学位,现为中国民航大学在读硕士研究生,主要研究方向为机场智能与自动化。

E-mail:377071214@qq.com

Gao Hong received his B. Sc. degree in 2019 from Anhui University of Technology and is currently a master's student at Civil Aviation University of China. His main research interests include Airport Intelligence and Automation.