

DOI: 10.19650/j.cnki.cjsi.J2514415

多传感器信息约束下基于因子图优化的 无人车紧耦合 SLAM 方法*

班喜程¹, 马继瑞¹, 尤波¹, 孙明晓¹, 史涛²

(1. 哈尔滨理工大学自动化学院 哈尔滨 150080; 2. 山东百盟信息技术有限公司 威海 264200)

摘要:多传感器融合同时定位与建图(SLAM)能够解决单一传感器的局限性,但现有方案仍受单目尺度不确定、惯性测量单元(IMU)初始化精度低及局部地图精度不足等问题制约,故提出一种基于因子图优化的多源信息紧耦合的SLAM方法,涉及3D激光雷达(LiDAR)、IMU、相机这3种异构传感器。在初始化阶段,通过激光雷达点云估计图像特征点深度信息,采用邻域筛选并结合统计优化的方法剔除异常点,从而显著提升深度估值精度,融合视觉、激光雷达与IMU信息联合求解IMU偏置量和重力方向,降低建图的垂直漂移;在局部优化阶段,采用因子图优化动态维护滑窗内的关键帧和局部地图,视觉局部地图通过共视投影匹配方法优化关键帧间的约束关系,有效剔除冗余地图点并提升地图精度与鲁棒性;在全局优化阶段,通过回环检测算法在因子图中添加回环因子,并采用增量式优化的方案对全局因子图进行优化,保证实时性的同时有效抑制累积误差。所提方法在KITTI、M2UD极端天气及真实校园场景这3类数据集上进行验证,该方法在定位精度上显著优于主流对比算法。与精度较高的LIO-SAM相比,在KITTI标准序列中绝对轨迹误差平均降低53.1%,在M2UD雨雪场景下误差降低66%,在校园场景中误差降低20.3%。建图结果在俯视与侧视角下均显示出更高的结构一致性和几何精度,充分证明了该方法在定位精度和地图一致性方面具有显著优势。

关键词: SLAM; 因子图优化; 滑窗优化; 联合初始化; 共视投影匹配

中图分类号: TH85 TH242 **文献标识码:** A **国家标准学科分类代码:** 510.80

Tightly-coupled SLAM method for unmanned ground vehicles based on factor graph optimization with multi-sensor information constraints

Ban Xicheng¹, Ma Jirui¹, You Bo¹, Sun Mingxiao¹, Shi Tao²

(1. School of Automation, Harbin University of Science and Technology, Harbin 150080, China;

2. Shandong Bim Information Technology Co., Ltd., Weihai 264200, China)

Abstract: Multi-sensor simultaneous localization and mapping (SLAM) mitigates single-sensor limitations, yet current methods still face challenges such as monocular scale ambiguity, inaccurate inertial measurement unit (IMU) initialization, and limited local mapping precision. This paper proposes a tightly-coupled, factor graph-based SLAM approach that fuses data from three heterogeneous sensors: a 3D light detection and ranging (LiDAR), an IMU, and a camera. For initialization, LiDAR data provides depth for visual features, and outliers are removed through neighborhood selection and statistical optimization to improve accuracy. Visual, LiDAR, and IMU data are then fused to jointly estimate IMU biases and gravity direction, reducing vertical map drift. For local optimization, factor graphs dynamically maintain keyframes and local maps within sliding windows. Visual constraints are refined through co-visibility projection matching, efficiently purging redundant map points while boosting accuracy and robustness. Global optimization incorporates loop-closure factors detected via specialized algorithms and applies incremental optimization to the factor graph, suppressing cumulative error without compromising real-time performance. The proposed method is evaluated on KITTI, M2UD extreme weather, and real-campus datasets. It reduces the absolute trajectory error by 53.1% on KITTI, 66% in M2UD rain/snow scenarios, and 20.3% in campus environments compared to LIO-SAM. The resulting maps exhibit higher structural consistency and geometric accuracy in both overhead and side views.

收稿日期: 2025-08-25 Received Date: 2025-08-25

* 基金项目: 黑龙江省自然科学基金(YQ2024E047)、黑龙江省优秀青年教师基础研究支持计划(YQJH2024067)项目资助

Keywords: SLAM; factor graph optimization; sliding window optimization; joint initialization; covisibility projection matching

0 引 言

同时定位与建图 (simultaneous localization and mapping, SLAM) 是无人车实现自主导航的核心技术,是无人系统领域的研究热点^[1]。SLAM 旨在使无人车在未知环境中同步完成自身定位与环境建图。经过长期发展,基于单一传感器(如相机^[2-3]或激光雷达(light detection and ranging, LiDAR)^[4])的 SLAM 技术已取得显著进展。但在结构稀疏或纹理缺失等复杂环境下仍面临精度和鲁棒性不足的问题。为此,多传感器融合策略逐渐成为研究重点,通过整合不同异构传感器的互补信息,提升系统在恶劣环境下的定位稳定性与建图精度。目前主流的多传感器融合方法主要分为两类:基于滤波和基于优化的方法^[5]。

基于滤波的方案在多传感器融合中占据重要地位。Lin 等^[6]通过基于迭代误差状态卡尔曼滤波(iterated error state Kalman filter, IESKF)的激光惯性里程计(LiDAR inertial odometry, LIO)建图,视觉惯性里程计(visual-inertial odometry, VIO)渲染纹理,实现了鲁棒的状态估计与彩色建图,其续作文献^[7]引入了相机光度校准和曝光时间在线估计,进一步提升精度与鲁棒性。诸葛晶昌等^[8]采用基于迭代扩展卡尔曼滤波与非线性几何观测器的混合状态估计框架,通过连续时间运动补偿、预拟合平面特征的方法,显著提升了轨迹精度与计算效率。Xu 等^[9]通过 IESKF 对激光惯性进行紧耦合优化,直接将原始点云与由增量多维树(k-dimensional tree, kd-tree)维护的地图配准,提升了系统的鲁棒性和精度。Zheng 等^[10-11]引入视觉传感器,构建激光-惯性-视觉里程计,通过最小化光度残差融合纹理信息,有效应对单一传感器退化场景。李春磊等^[12]通过 LIO 与 VIO 两个子系统,基于 IESKF 融合几何和光度误差,实现了高精度的实时定位与彩色建图。

基于优化的方案也是多传感器融合的关键研究方向。Wen 等^[13]通过非线性优化融合多传感器数据,采用视觉惯性辅助处理激光雷达退化问题,并引入神经网络应对光照干扰,在隧道等具有自相似结构与光照挑战的场景中实现鲁棒定位与建图。Shan 等^[14]提出一种激光-视觉-惯性 SLAM 系统,包含 VIO 与 LIO 双子系统,前者校正点云畸变并提供位姿先验,后者精细建图,实现鲁棒的实时定位与建图。孙明晓等^[15]提出基于深度图的高效动态障碍物移除激光 SLAM 算法,并基于扫描上下文的点云描述符实现高效回环检测,降低轨迹漂移。Luo 等^[16]通过集成 SuperPoint 特征提取与 LightGlue 匹配等深度学习模型,显著提升了在弱光、动态光照等复杂场景

下的定位鲁棒性和精度。叶俊强等^[17]针对传统方法在低纹理场景的不足,融合特征增强与稀疏直接法,提升系统的鲁棒性与精度。Cheng 等^[18]基于小而精的迭代最近点^[19]框架,通过前后端两级处理和视觉辅助,在不依赖惯性测量单元(inertial measurement unit, IMU)的情况下,实现了鲁棒且精确的定位。王禹等^[20]提出一种通过地面优化和闭环检测相结合来抑制 Z 轴漂移的 SLAM 系统,有效提高定位与建图精度。

当前的多传感器融合的 SLAM 方案仍存在单目视觉尺度不确定性、IMU 初始化精度低以及滑窗内局部地图精度不足的问题,针对这些问题,本研究提出了一种多传感器信息约束下基于因子图优化的无人车紧耦合 SLAM 算法。利用激光点云为视觉特征点提供深度信息,融合视觉、激光雷达与 IMU 信息联合求解 IMU 偏置量和重力方向偏差,通过共视投影匹配消除视觉特征点漂移,增强地图点精度与鲁棒性,同时融合 3 种传感器约束,在滑窗内优化位姿与地图点,保障实时性的同时提升定位精度。

1 基于因子图优化的多源异构传感器信息紧耦合 SLAM 系统

1.1 系统框架

本研究提出一种基于因子图优化的多源异构信息紧耦合无人车 SLAM 系统,涉及多线 LiDAR、IMU、相机这 3 种传感器,系统框架如图 1 所示,系统包括 3 个核心模块:数据处理与系统初始化模块、位姿跟踪与局部建图模块、回环检测与全局建图模块。

数据处理与系统初始化模块:使用点云为视觉特征点估计深度信息,结合邻域筛选与统计优化抑制异常点,提升深度估计精度;联合视觉、点云与 IMU 进行初始化,精确求解世界坐标系与重力方向的偏差和 IMU 的偏置量等关键参数,实现多源数据一致性融合。

位姿跟踪与局部建图模块:使用共视投影匹配剔除视觉局部地图特征点的“重影”现象,提升地图点精度,提高位姿跟踪鲁棒性;设计滑动窗口优化方案,融合视觉重投影、激光几何约束与 IMU 预积分因子,在窗口内持续优化关键帧位姿与地图点,保障位姿跟踪实时性的同时提高局部的定位精度。

回环检测与全局建图模块:使用融合时空协同约束与几何结构感知的回环检测方法,为后续图优化提供高置信闭环因子。全局优化采用增量平滑与建图(incremental smoothing and mapping 2, iSAM2)算法,利用贝叶斯树数据结构实现增量式优化,最终生成全局一致的高精度地图。

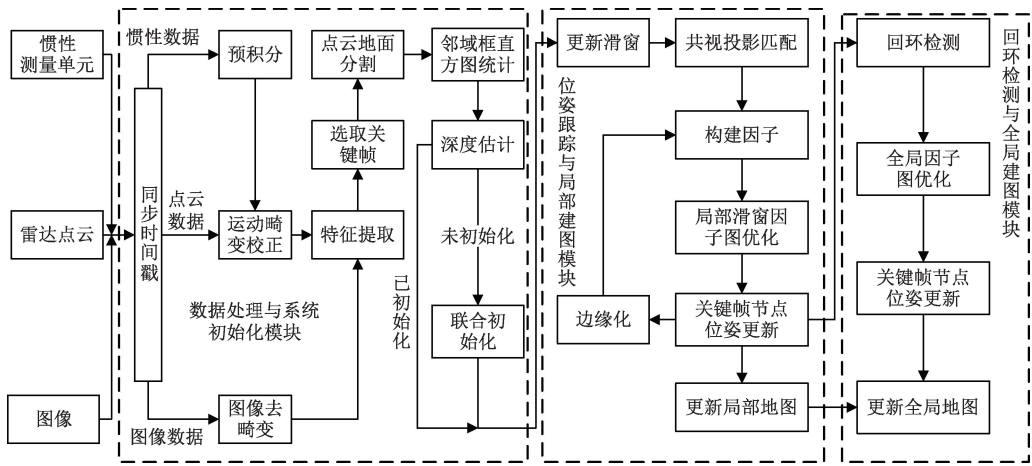


图1 系统总框图

Fig. 1 Algorithm framework diagram

1.2 数据处理与系统初始化模块

1) 使用点云数据估计图像特征点的深度

激光雷达点云的地面分割采用一种基于扇形分区与几何约束的融合策略。将点云进行有序化分割,利用有序点云中同一列的相邻行的点所在的激光束,计算地面的倾斜角 β 。设置地面分割的倾斜角阈值为 β_s ,高度阈值为 h_s ,将倾斜角或高度差小于阈值的点标记为地面点,将地面点与非地面点分离。阈值的取值由道路情况决定,以沥青路面为例,其表面平整,倾斜角阈值通常设为 $4^\circ \sim 6^\circ$,高度阈值设置为 $1 \sim 3$ cm即可实现准确分割。地面点标记的判断表达式为:

$$\phi(p_i) = \begin{cases} 0, & \beta_i < \beta_s \text{ 或 } z_i - z_{\min} < h_s \\ 1, & \text{其他} \end{cases} \quad (1)$$

其中,0为地面点,1为非地面点, p_i 是第 i 个雷达点, β_i 是第 i 个雷达点所在激光束和它上一行激光束与地面构成的倾斜角, z_{\min} 是当前帧雷达点云中所有雷达点的最小高度值, z_i 是第 i 个雷达点的高度值。

对激光雷达点云进行地面分割后,将去除地面点的点云投影到图像平面上,然后为每个特征点构建邻域框,邻域框中需包含多条激光雷达扫描线的点云数据,如图2所示,为保证统计鲁棒性,邻域框设置为正方形,覆盖至少3条且少于6条激光雷达扫描线(即3~5条)。该设置既避免邻域过小导致点云样本不足,又防止邻域过大引入噪声干扰与跨结构混合,从而提升深度估计与匹配的可靠性。假设邻域框内包含 n 个激光雷达点,计算其深度均值 μ 和方差 σ ,并通过统计直方图筛选均值 μ 的2倍方差 σ 范围内的激光雷达点数量 n_μ ,若满足 $n_\mu \geq \tau$ (τ 为阈值,阈值至少为75%),则认为该邻域框内的激光雷达点深度值近似服从高斯分布,取这 n_μ 个点的深度均值为特征点的深度值。




图2 投影点云与图像特征点邻域框

Fig. 2 Projected point cloud and feature point boxes

为提高深度估值精度,进一步对特征点的深度估值进行共视优化。将初始化关键帧队列中的所有关键帧对特征点观测得到的三维坐标投影至当前帧坐标系下,重新计算其在当前帧坐标系下的深度估值。随后,计算这些投影后的各深度估值与当前帧的初始深度估值之间的差异,偏差阈值为上一帧特征点深度估值的5%。若差异大于设定的偏差阈值,则剔除该视觉特征点;否则,取当前帧的初始深度估值与所有共视关键帧投影后深度估值的平均值作为最终深度值。

2) 多传感器联合初始化

IMU的噪声特性对系统状态估计具有重要影响。具体而言,陀螺仪的白噪声与偏置随机游走对姿态漂移较为敏感,主要反映在系统姿态的中长期航向误差上;而加速度计的白噪声则主要影响速度与位置估计的短期稳定性,尤其在动态场景下对加速度峰值响应更为敏感。准确的传感器噪声标定与偏置初始化,可有效抑制垂直方向的漂移,并提升轨迹精度。

在初始化中,激光雷达为视觉特征点提供深度基准,直接生成具备尺度的地图点,无需将尺度作为优化变量。因此,待优化的变量为各关键帧的位置 p 、姿态 q 、速度 v 、IMU的加速度偏置量 b_a 和陀螺仪偏置量 b_w ,以及世界坐标系 Z 轴与重力方向的偏差矩阵。将所有待优化的变量

写成向量 χ , 形式为:

$$\begin{cases} \chi = [\mathbf{x}_1, \dots, \mathbf{x}_k, \dots, \mathbf{x}_{10}, \mathbf{R}_{\omega_g}] \\ \mathbf{x}_k = [\mathbf{p}_k^m, \mathbf{q}_k^m, \mathbf{v}_k^m, \mathbf{b}_{a_k}, \mathbf{b}_{\omega_k}] \end{cases}, \quad k \in [1, 10] \quad (2)$$

其中, \mathbf{x}_k 表示第 k 关键帧对应的所有待优化状态量, 上角标 m 表示在地图坐标系下; 初始化在收集 10 个关键帧后启动。为规避多变量联合优化难收敛、耗时长的问题, 将该过程分解为两步: 视觉激光雷达联合最大后验估计和纯惯性最大后验估计。

(1) 视觉激光雷达联合最大后验估计

通过视觉激光雷达联合最大后验估计优化关键帧的位姿, 建立用于初始化的因子图, 建立视觉重投影约束作为因子信息, 位姿初值由激光雷达 ICP 匹配得到, 设视觉激光雷达联合最大后验估计变量表示为:

$$\chi_{cl} = \{\mathbf{p}_1, \dots, \mathbf{p}_k, \mathbf{q}_1, \dots, \mathbf{q}_k\}, \quad k \in [1, 10] \quad (3)$$

视觉激光雷达联合最大后验估计的目标函数为最小化各类残差项加权平方和, 即:

$$\min_{\chi_{cl}} \left\{ \sum_{k \in [1, 10]} r_{c_{k-1, k}}^2 + \sum_{k \in [1, 10]} r_{l_{k-1, k}}^2 \right\} \quad (4)$$

其中, $r_{c_{k-1, k}}$ 表示相邻关键帧的视觉重投影残差, $r_{l_{k-1, k}}$ 表示相邻关键帧的激光雷达残差, 残差表达式为:

$$\begin{cases} r_{c_{k-1, k}} = \mathbf{P}_i^{C_k} - \hat{\mathbf{P}}_i^{C_k} \\ r_{l_{k-1, k}} = \sum_p^c \frac{\| (\mathbf{l}_p^k - \mathbf{l}_a^{k-1}) \times (\mathbf{l}_p^k - \mathbf{l}_b^{k-1}) \|}{\| \mathbf{l}_a^{k-1} - \mathbf{l}_b^{k-1} \|} + \sum_p^p \frac{\| \mathbf{n} \cdot \mathbf{p}_i^k \|}{\| \mathbf{n} \|} \end{cases} \quad (5)$$

其中, \mathbf{P} 为局部地图中一地图点, 它的索引编号为 i , 其在第 k 关键帧的归一化平面上的投影坐标为 $\mathbf{P}_i^{C_k}$, 在第 k 关键帧的观测坐标为 $\hat{\mathbf{P}}_i^{C_k}$; \mathbf{l}_p^k 是第 k 关键帧的角点在 $k-1$ 关键帧的激光雷达坐标系下坐标表示, \mathbf{l}_a^{k-1} 和 \mathbf{l}_b^{k-1} 是 $k-1$ 关键帧中与 \mathbf{l}_p^k 匹配的两个角点的坐标, \sum^c 表示第 k 帧所有角点残差的累加和, $\| \cdot \|$ 表示取模值运算。 \mathbf{p}_i^k 是第 k 帧的面点在 $k-1$ 关键帧的激光雷达坐标系下坐标表示, \mathbf{n} 是 $k-1$ 关键帧中与 \mathbf{p}_i^k 匹配的平面的法向量, \sum^p 表示第 k 帧所有面点残差的累加和。

(2) 纯惯性最大后验估计

通过固定视觉激光雷达联合最大后验估计优化后的轨迹, 进行纯惯性最大后验估计, 估计出各关键帧的 IMU 零偏、速度以及重力方向。则纯惯性最大后验估计的待优化变量可表示为:

$$\chi_b = \{\mathbf{R}_{\omega_g}, \mathbf{b}, \bar{\mathbf{v}}_{0, k}\} \quad (6)$$

其中, $\mathbf{b} = (\mathbf{b}^a, \mathbf{b}^\omega)$ 是加速度计和陀螺仪的零偏; $\bar{\mathbf{v}}_{0, k}$ 是 IMU 坐标系下滑窗内所有关键帧速度的集合; \mathbf{R}_{ω_g} 是重力方向, 世界坐标系下的重力向量可表示为 $\mathbf{g} = \mathbf{R}_{\omega_g} \mathbf{g}_l$,

$\mathbf{g}_l = (0, 0, G)^\top$, G 为重力加速度的值。纯惯性优化的目标函数为最小化各类残差项加权平方和:

$$\min_{\chi_b} \left\{ \sum_{i \in [1, 10]} r_{\Gamma_{i-1, i}}^2 \right\} \quad (7)$$

其中, $r_{\Gamma_{i-1, i}}$ 表示 IMU 预积分残差, 包括旋转残差 $r_{\Delta \mathbf{R}_{ij}}$ 、速度残差 $r_{\Delta \mathbf{v}_{ij}}$ 和位置残差 $r_{\Delta \mathbf{p}_{ij}}$, 残差表达式为:

$$\begin{cases} r_{\Delta \mathbf{R}_{ij}} = \log [(\Delta \tilde{\mathbf{R}}_{ij})^\top \Delta \mathbf{R}_{ij}] = \\ \log \left[\left[\Delta \tilde{\mathbf{R}}_{ij} \text{Exp} \left(\frac{\partial \Delta \tilde{\mathbf{R}}_{ij}}{\partial \mathbf{b}^g} \delta \mathbf{b}_i^g \right) \right]^\top \mathbf{R}_{\omega_i}^\top \mathbf{R}_{\omega_j} \right] \\ r_{\Delta \mathbf{v}_{ij}} = \Delta \mathbf{v}_{ij} - \Delta \tilde{\mathbf{v}}_{ij} = \\ \mathbf{R}_{\omega_i}^\top (\mathbf{v}_{\omega_j} - \mathbf{v}_{\omega_i} - \mathbf{R}_{\omega_g} \mathbf{g}_l \Delta t_{ij}) - \\ \left[\Delta \tilde{\mathbf{v}}_{ij} + \frac{\partial \Delta \tilde{\mathbf{v}}_{ij}}{\partial \mathbf{b}^g} \delta \mathbf{b}_i^g + \frac{\partial \Delta \tilde{\mathbf{v}}_{ij}}{\partial \mathbf{b}^a} \delta \mathbf{b}_i^a \right] \\ r_{\Delta \mathbf{p}_{ij}} = \Delta \mathbf{p}_{ij} - \Delta \tilde{\mathbf{p}}_{ij} = \\ \mathbf{R}_{\omega_i}^\top \left(\mathbf{p}_{\omega_j} - \mathbf{p}_{\omega_i} - \mathbf{v}_{\omega_i} \Delta t_{ij} - \frac{1}{2} \mathbf{R}_{\omega_g} \mathbf{g}_l \Delta t_{ij}^2 \right) - \\ \left[\Delta \tilde{\mathbf{p}}_{ij} + \frac{\partial \Delta \tilde{\mathbf{p}}_{ij}}{\partial \mathbf{b}^g} \delta \mathbf{b}_i^g + \frac{\partial \Delta \tilde{\mathbf{p}}_{ij}}{\partial \mathbf{b}^a} \delta \mathbf{b}_i^a \right] \end{cases} \quad (8)$$

其中, $\Delta \tilde{\mathbf{R}}_{ij}$ 、 $\Delta \tilde{\mathbf{v}}_{ij}$ 和 $\Delta \tilde{\mathbf{p}}_{ij}$ 分别表示旋转、速度和位置更新零偏的 IMU 预积分量, $\Delta \mathbf{R}_{ij}$ 、 $\Delta \mathbf{v}_{ij}$ 和 $\Delta \mathbf{p}_{ij}$ 分别表示旋转、速度和位置从第 i 时刻到第 j 时刻的观测变化量, \mathbf{R}_{ω_j} 、 \mathbf{v}_{ω_j} 和 \mathbf{p}_{ω_j} 分别表示第 j 时刻旋转、速度和位置量, \mathbf{R}_{ω_i} 、 \mathbf{v}_{ω_i} 和 \mathbf{p}_{ω_i} 分别表示第 i 时刻旋转、速度和位置量, $\delta \mathbf{b}_i^g$ 、 $\delta \mathbf{b}_i^a$ 分别表示陀螺仪和加速度计的零偏更新量, $\Delta \tilde{\mathbf{R}}_{ij}$ 、 $\Delta \tilde{\mathbf{v}}_{ij}$ 和 $\Delta \tilde{\mathbf{p}}_{ij}$ 分别表示旋转、速度和位置未更新零偏的 IMU 预积分量, Δt_{ij} 表示时间差。

纯惯性最大后验估计后, 通过重力方向将地图坐标系的 z 轴与重力方向对齐。使用优化后的惯性参数重新计算 IMU 的预积分, 以减少后续估计中的线性累积误差。通过激光雷达视觉惯性联合最大后验估计对得到的 IMU 零偏、速度、重力方向以及位姿估计结果进一步精细化调整, 提升整体系统的鲁棒性和精度。

1.3 位姿跟踪与局部建图模块

在多源信息约束下, 需要重新设计 SLAM 系统的位姿跟踪模块, 需兼顾位姿状态估计和局部地图构建的准确性和快速性。提出共视投影匹配策略用于提高特征点的精度, 消除地图点“重影”现象, 所提出的 SLAM 系统采用滑动窗口优化的方式设计位姿跟踪与局部建图模块, 详述如下。

1) 共视投影匹配

在多传感器融合 SLAM 系统中, 为解决地图点的冗余、精度不足等问题, 本研究提出一种基于共视投影的地图点匹配方法。通过滑窗内关键帧的共视关系, 利用地

图点的投影匹配对最新关键帧的地图点进行筛选与优化,从而提升地图点的精度与视觉观测约束关系的鲁棒性。

当最新帧被判断为关键帧后,将滑窗内共视关键帧中可观测到的所有地图点投影到最新关键帧的图像平面上。利用描述子匹配方法判断投影点是否与最新关键帧图像中的特征点匹配成功。如果某个投影点未能在最新关键帧的特征点中找到匹配点,则抛弃该投影点。对于成功匹配的投影点,进一步判断其对应的特征点是否已存在关联的原地图点。如果特征点已存在对应的原地图点,即地图点有“重影”,则对地图点进行替换处理;若特征点未关联任何地图点,则新增地图点能够扩展关键帧的地图点观测范围。

在地图点替换处理中,通过比较投影点对应地图点和原地图点的被观测次数,保留被观测次数多的地图点,并更新滑动窗口内所有关键帧的视觉观测约束关系,同时删除冗余地图点。这有效解决了“影子”地图点的问题,即同一实际场景点因多次观测或多线程创建而生成的重复地图点现象,从而提高了地图点的精度和唯一性。对于未有对应地图点的特征点,通过新增地图点的方式与最新关键帧建立新的观测约束,进一步增强了地图点的覆盖范围和关键帧匹配的成功率。通过共视投影匹配方法,有效提升了关键帧与地图点的匹配精度,优化了视觉观测约束关系,为SLAM系统的高精度定位与建图提供了坚实的基础。共视投影匹配的处理算法伪代码如算法1所示,其中, K_{new} 为最新关键帧, K_{COV} 为与最新关键帧共视的关键帧集合, m_{global} 为视觉局部地图, $m_{updated}$ 为更新后的视觉局部地图, m_{p_j} 为第 j 个地图点, m_k 为关键帧 K 观测到的地图点集合, $m_{p_j}^m$ 为地图点 m_{p_j} 在地图坐标系下的坐标, $T_{K_{new}}^m$ 为从 K_{new} 坐标系到地图坐标系的位姿变换, F_{new} 为 K_{new} 的特征集合, uv 为投影后的像素坐标,

$m_{p_{keep}}$ 为保留的地图点, F_p 为匹配成功得到的当前帧特征集合, $m_{p_{orig}}$ 为已与 F_p 匹配的既有地图点, $m_{p_{discard}}$ 为需从地图中移除的冗余或“重影”地图点, $m_{p_{new}}$ 为由当前帧生成地图点, T_p^m 为将当前帧下的点 p 变换到地图坐标系的变换矩阵。

算法 1: 基于共视投影的地图点优化

```

输入:  $K_{new}, K_{COV}, m_{global}$ 
输出:  $m_{updated}$ 
1: for each  $K \in K_{COV}$  do:
2:   for each  $m_{p_j} \in m_k$  do:
3:     transform  $m_{p_j}^m$  into  $K_{new}$  as  $p$  by  $(T_{K_{new}}^m)^{-1}$ 
4:      $uv \leftarrow \pi(p)$ 
5:     if  $uv \in ImageBoundary$ :
6:        $F_p \leftarrow findmatch(des(m_{p_j}), F_{new}, uv)$ 
7:       if  $F_p \neq \emptyset$ :
8:         if  $\exists m_{p_{orig}}$  linked to  $F_p$ :
9:            $m_{p_{keep}} = argmax(m_{p_j}.obs\_count, m_{p_{orig}}.obs\_count)$ 
10:           $m_{updated}.remove(m_{p_{discard}})$ 
11:        else:
12:          transform  $p$  into  $m$  as  $m_{p_{new}}$  by  $T_p^m$ 
13:           $m_{updated}.add(m_{p_{new}})$ 
14: return  $m_{updated}$ 
    
```

2) 局部因子图构建与滑动窗口优化

滑窗优化联合 IMU 预积分因子、激光雷达因子、视觉重投影因子和边缘化因子构建优化目标函数,对滑窗内的位姿、速度等状态量进行优化。通过多传感器的联合约束,显著提升了位姿估计的精度与系统的鲁棒性,为高精度定位与建图提供了可靠保障。滑窗优化因子图模型如图3所示。

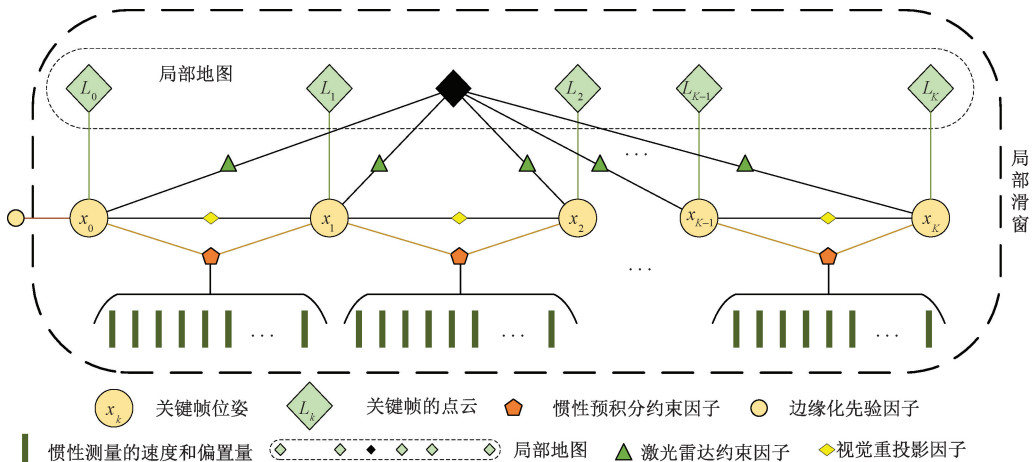


图3 滑窗因子图模型

Fig. 3 Sliding window factor graph model

滑窗优化目标函数为最小化残差项加权平方和,即:

$$\min_{\varphi} \left\{ \sum_{k \in [1, K]} e_C^2(\mathbf{x}_{k-1}, \mathbf{x}_k) + \sum_{k \in [1, K]} e_B^2(\mathbf{x}_{k-1}, \mathbf{x}_k) + \sum_{k \in [0, K]} e_L^2(\mathbf{x}_k, \mathbf{m}) + e_M^2 \right\} \quad (9)$$

其中, $e_C(\mathbf{x}_{k-1}, \mathbf{x}_k)$ 、 $e_B(\mathbf{x}_{k-1}, \mathbf{x}_k)$ 、 $e_L(\mathbf{x}_k, \mathbf{m})$ 和 e_M 分别表示视觉约束残差、IMU 预积分约束残差、激光雷达残差和边缘化先验约束残差, \mathbf{m} 表示局部点云地图。滑动窗口内所有关键帧的状态变量表示为 $\varphi = [\mathbf{x}_0, \mathbf{x}_1, \dots, \mathbf{x}_N]$, 滑动窗口内所有关键帧总数为 $N + 1$, N 取值为 9 (8 ~ 10 即可), 太大会影响实时性, 太小会降低精度。对于第 k 关键帧, 在地图坐标系下的状态向量 $\mathbf{x}_k = [p_{b_k}^m, \mathbf{Y}_{b_k}^m, q_{b_k}^m, \mathbf{b}_{a_k}, \mathbf{b}_{w_k}]$, $p_{b_k}^m$ 、 $\mathbf{v}_{b_k}^m$ 和 $q_{b_k}^m$ 分别为第 k 关键帧的位置、速度和姿态, \mathbf{b}_{a_k} 和 \mathbf{b}_{w_k} 分别为第 k 关键帧的加速度计偏置量和陀螺仪偏置量。

滑窗优化算法采用非线性 LM 求解器, 结合舒尔补边缘化技术。设 LM 算法迭代次数为 I , 则单次滑窗优化的总时间复杂度为:

$$T_w = I \times [O(N_c + N_s + N_L) + O(P \cdot \bar{o}^2)] \quad (10)$$

其中, $O(\cdot)$ 表示用于描述算法复杂度的函数, $O(N_c + N_s + N_L)$ 为非线性优化时间复杂度, $O(P \cdot \bar{o}^2)$ 为舒尔补时间复杂度, N_c 为视觉因子数, N_L 为雷达因子数, N_s 为滑窗内 IMU 因子数, P 为地图点数, \bar{o} 为平均观测次数。由于滑窗大小固定, 因子数 N_c 、 N_L 、 N_s 保持不变; 尽管 P 和 \bar{o} 会发生变化, 但其变化范围受窗口机制限制。因此, 在理论上保证了系统具有良好的实时性能。

1.4 回环检测与全局建图模块

1) 回环检测

本系统采用一种融合时空协同约束与几何结构一致性的回环检测方法, 有效提升了在复杂场景下的闭环识别可靠性。该方法通过分层筛选机制实现高效且准确的回环候选判别, 空间层以当前关键帧为中心, 在关键帧位姿图中基于 kd-tree 数据结构进行半径搜索, 提取空间距离在一定阈值范围内的所有历史关键帧, 阈值一般选取 10~20 m, 这能够覆盖数公里轨迹运行后典型的累积误差范围, 同时避免在大型开放空间中产生过多无关候选帧; 时间层进一步施加时序约束, 排除时间戳过于接近的候选帧, 以避免短时重复感知带来的误匹配, 确保回环检测仅在具有显著时间间隔的帧间进行。

在获得时空层筛选后的候选帧后, 系统执行精细化的几何验证。系统提取当前帧的特征点云及其对应历史候选帧的局部点云地图, 通过 ICP 进行精确配准。当配准结果满足严格的一致性条件时, 才判定为有效回环, 并将其作为位姿图优化中的闭环约束因子, 有效校正累积位姿误差。

2) 全局因子图构建及优化

系统采用基于因子图的增量优化框架, 融合 IMU 预积分、视觉重投影、点云配准与回环检测信息。全局优化目标函数为最小化各类残差项加权平方和, 即:

$$\min_{\mathbf{x}_{\text{loop}}} \left\{ \sum_{k \in [1, K]} e_C^2(\mathbf{x}_{k-1}, \mathbf{x}_k) + \sum_{k \in [1, K]} e_B^2(\mathbf{x}_{k-1}, \mathbf{x}_k) + \sum_{k \in [0, K]} e_L^2(\mathbf{x}_k, \mathbf{M}) + e_{\text{loop}}^2 \right\} \quad (11)$$

其中, 需要优化的关键帧的状态变量表示为 $\mathbf{x}_{\text{loop}} = [\mathbf{x}_1, \dots, \mathbf{x}_k, \dots, \mathbf{x}_K]$, $e_C(\mathbf{x}_{k-1}, \mathbf{x}_k)$ 、 $e_B(\mathbf{x}_{k-1}, \mathbf{x}_k)$ 、 $e_L(\mathbf{x}_{k-1}, \mathbf{M})$ 和 e_{loop} 分别表示视觉重投影残差、IMU 预积分约束残差、激光雷达约束残差和回环约束残差, \mathbf{M} 是全局地图点云集合。

由于 IMU 可提供加速度向量 $\mathbf{a} = [a_x, a_y, a_z]^T$, 可解析地估计俯仰角 θ 与横滚角 γ , 计算表达式为:

$$\begin{cases} \theta = \arctan(-a_x / \sqrt{a_y^2 + a_z^2}) \\ \gamma = \arctan(a_y / a_z) \end{cases} \quad (12)$$

其中, 俯仰角 θ 的角度范围为 $-\frac{\pi}{2}$ 到 $\frac{\pi}{2}$, 横滚角 γ 的角度范围为 $-\pi$ 到 π 。因此, 在优化过程中固定 θ 、 γ , 仅优化航向角 ϕ 及位置 $[x, y, z]$, 有效压缩自由度, 提升计算效率。回环残差构建表达式为:

$$e_{\text{loop}} = \mathbf{R}_m^{b_i} (\mathbf{P}_{b_j}^m - \mathbf{P}_{b_i}^m) + \varepsilon \times \text{wrap}(\phi_j - \phi_i) \quad (13)$$

其中, 序号 j 表示当前帧的索引号, 序号 i 表示当前帧匹配到的回环帧的索引号, ϕ 表示航向角, ε 表示航向角误差权重, \mathbf{R}_m^b 表示地图坐标系到 IMU 坐标系的旋转向量, \mathbf{P}_b^m 表示地图坐标系下的位置向量, $\text{wrap}(\cdot)$ 表示角度周期性处理函数。

本系统的全局优化模块基于 iSAM2 算法, 其优势在于利用贝叶斯树数据结构实现高效的增量式优化。检测到回环约束后, 算法仅需重新线性化受影响的局部贝叶斯子树进行更新, 从而避免了高计算代价的全局图重构。贝叶斯树的更新机制识别变量间的条件独立性, 并仅对与回环帧存在依赖关系的节点及其路径上的父节点执行增量消元操作。结合 Givens 旋转加速 QR 分解, 整体优化复杂度由典型的立方阶降至近似对数阶。这大幅提升了优化过程的鲁棒性与实时性。

2 实 验

为了验证所提算法的精度和鲁棒性, 分别在公开数据集和实车平台上进行测试, 选取 LEGO-LOAM、LOAM、VINS-MONO 和 LIO-SAM 进行对比。

2.1 公开数据集测试和评估

1) KITTI 数据集精度评估

软件测试平台为 Ubuntu 20.04 系统,基于 ROS noetic 版本,依赖于 Opencv4.5.1、Ceres2.1.0、GTSAM4.0.2、PCL 1.8.1,电脑硬件配置 CPU 为 i5-13500H,运行内存为 16 GB。

为验证所提算法的鲁棒性和精度,选取含有城市、

乡村、公路等多环境特征以及存在回环、地面坡度变化等室外因素的 KITTI 数据集的序列 00、07 和 09 测试,实验均在数据集×1 的播放速率下进行。

图 4 清晰展示了本方法、对比方法及轨迹真值之间的差异。其中,图 4(d)~(f) 分别对应图 4(a)~(c) 的框选区域。

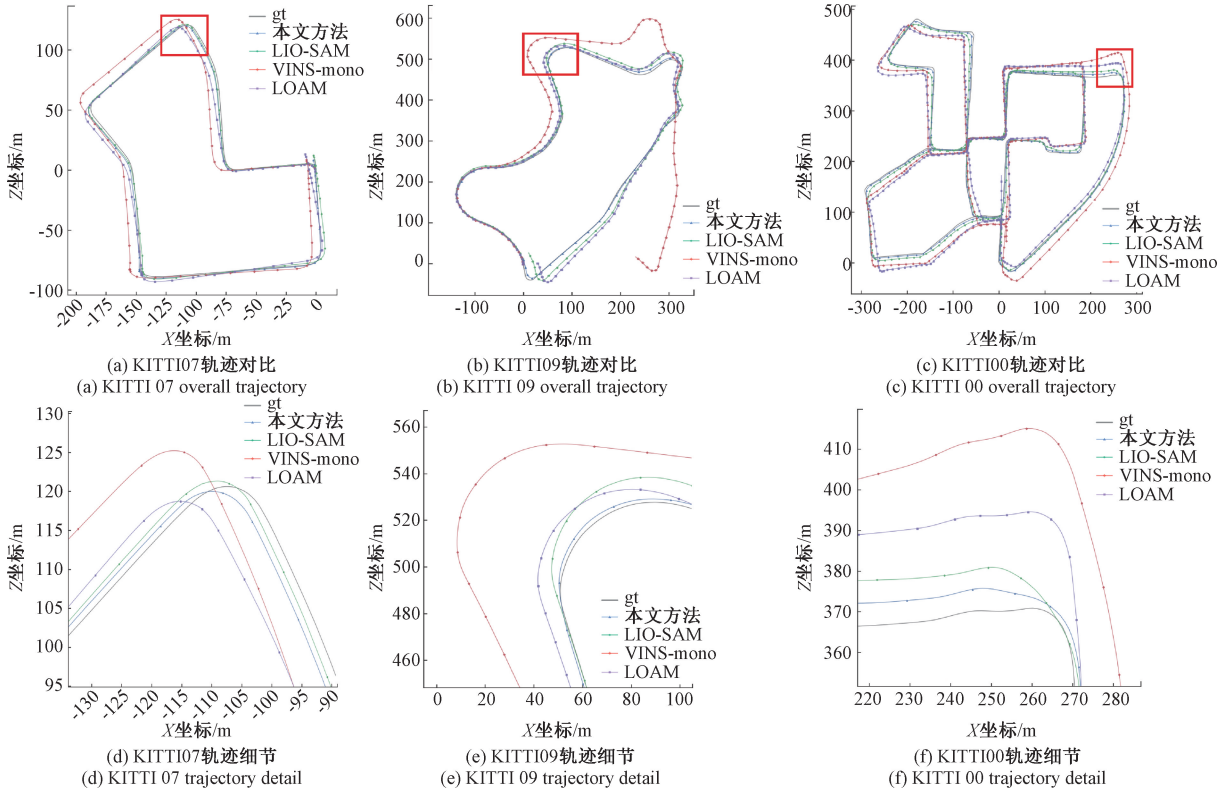


图 4 本算法与其他算法在 KITTI07、KITTI09、KITTI00 与真值轨迹对比

Fig. 4 Trajectory comparison: Proposed method vs. other algorithms vs. ground truth (KITTI 00, 07, 09)

分析可知,由于 VINS-MONO 依靠单目视觉三角化恢复的特征点深度存在尺度问题,其轨迹出现大幅漂移; LOAM 在短距离定位场景表现尚可,但随着位移增加,在所有数据集中均表现出显著的轨迹偏差,且偏差随距离累积而增大;LIO-SAM 融合 IMU 并加入回环检测后,定位性能得到改善,在各数据集表现良好。然而在具有大回环的 09 数据集上,其轨迹仍未能完全闭合。相比之

下,本算法融合了视觉、IMU 与激光雷达数据,使用激光雷达数据恢复视觉特征点深度信息,改进 IMU 初始化方法,并在滑窗优化时加入 3 种传感器约束,在各个数据集上的表现都优于其他算法。

定量分析结果如表 1 所示,对于 KITTI07,本算法均方根误差(root mean square error, RMSE) 仅为 0.54 m,展现了在简单场景下的高精度,较 LIO-SAM 降低了

表 1 本方法的绝对位姿误差与 KITTI07、09、00 序列上的其他算法比较

Table 1 The absolute pose error of this method is compared with other algorithms on the KITTI sequences 07, 09, and 00

(m)

方法	平均误差			均方根误差		
	07 序列	09 序列	00 序列	07 序列	09 序列	00 序列
本文方法	0.507 433	5.356 368	4.598 594	0.541 544	5.750 955	5.004 418
LIO-SAM	0.858 806	7.530 672	12.699 085	0.997 812	9.574 961	13.746 166
LOAM	1.676 901	8.059 945	40.873 700	2.009 622	10.536 044	44.254 326
VINS-MONO	10.593 748	51.343 098	36.796 060	11.698 526	66.577 785	40.043 853

45.45%,较 LOAM 降低了 73%;对于 KITTI00,本算法 RMSE 为 5 m。得益于增加的视觉约束,其精度相较同样具备回环检测的 LIO-SAM 提升了 73.8%,LOAM 因缺乏回环检测而出现大幅漂移,VINS-MONO 虽具备回环检测,但仍因较大的视觉尺度误差导致显著漂移;对于 KITTI09,该场景下,本算法 RMSE 为 5.75 m,较 LIO-SAM 提升了 39.95%,较 LOAM 提升了 45.23%,而 VINS-MONO 在此高速场景下完全失效。实验结果表明,本提出算法在定位精度与鲁棒性方面均显著优于对比方法。

2) KITTI 数据集实时性评估

为了评估本算法的运行复杂性和运行速度,将本算法、LIO-SAM 算法、LOAM 算法和 VINS-MONO 算法在数据集上进行评估。平均单帧处理时间如表 2 所示。实验结果表明,在相同数据集上,本算法的平均处理时间慢于 VINS-MONO 算法,与 LIO-SAM 算法相当,并显著快于 LOAM 算法。

尽管实时性弱于视觉方案 VINS-MONO,但本算法通过融合多模态数据,在轨迹精度上具有显著优势,且

27.39 ms 的单帧处理时间完全满足实时处理需求。


表 2 KITTI 平均运行时间

Table 2 Average running time (ms)

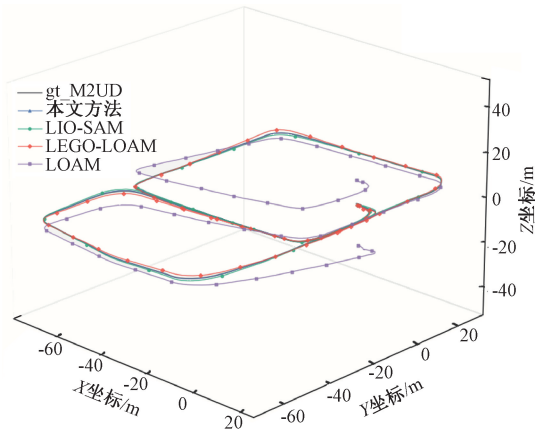
方法	00 序列	09 序列	07 序列	平均运行时间
本文方法	26.43	27.35	28.39	27.39
LIO-SAM	28.46	27.08	29.27	28.27
LOAM	53.62	55.48	56.55	55.22
VINS-MONO	20.61	22.05	21.39	21.35

3) 极端天气数据集评估

针对复杂场景下的挑战,使用 M2UD 数据集中的序列 extreme_04 进行专项测试,如图 5(a) 所示,该序列记录了真实道路积雪并伴随雨夹雪的恶劣天气条件。图 5(b) 清晰展示了本方法、对比方法及轨迹真值之间的差异。由于数据集中轨迹较短,累积漂移并不严重,本方法与 LIO-SAM、LEGO-LOAM 表现都很优秀,而 LOAM 没有回环检测漂移比较严重,主要表现为垂直漂移。



(a) 建图与局部图像数据
(a) Mapping and local image data



(b) 轨迹对比
(b) Trajectory comparison chart

图 5 M2UD 的定位结果

Fig. 5 Localization results in M2UD

图 6(a) 对比了各算法沿 X、Y、Z 坐标轴的轨迹表现。如图所示,各算法的 X 与 Y 轴轨迹整体较为稳定。然而,在 Z 轴上,各算法均表现出不同程度的偏差,LOAM 的 Z 轴偏差幅度大且呈现明显的漂移趋势;LEGO-LOAM 和 LIO-SAM 的 Z 轴轨迹相对平缓,但仍存在小幅波动;本算法在 Z 轴轨迹稳定性方面表现最优,偏差波动范围最小,且未出现明显漂移现象。图 6(b) 展示了各算法在 M2UD 中的绝对轨迹误差统计柱状图,各项指标给出在表 3 中。数据表明,本算法性能显著优于对比算法,以 RMSE 作为评估标准,与 LOAM、LEGO-LOAM 和 LIO-SAM 相比,本算法的轨迹误差分别显著降低了 94%、71% 和 66%。

2.2 实车数据集测试与评估

1) 精度评估

为了进一步评估提出的方法,在真实的户外自主移动无人车平台上进行了实验,如图 7 所示。

实验场地为校园内的道路环境,车辆沿预定路线行驶以完成数据采集。为在不同场景下评估算法的鲁棒性和适应性,选择了 2 种具有代表性的测试环境:一段长直道路和一段带有回环的道路。由于 VINS-MONO 仅具备定位功能而无法完成建图,因此在实车测试使用 LEGO-LOAM 替代 VINS-MONO 进行评估,同时选取了 LOAM 和 LIO-SAM 作为对比算法。

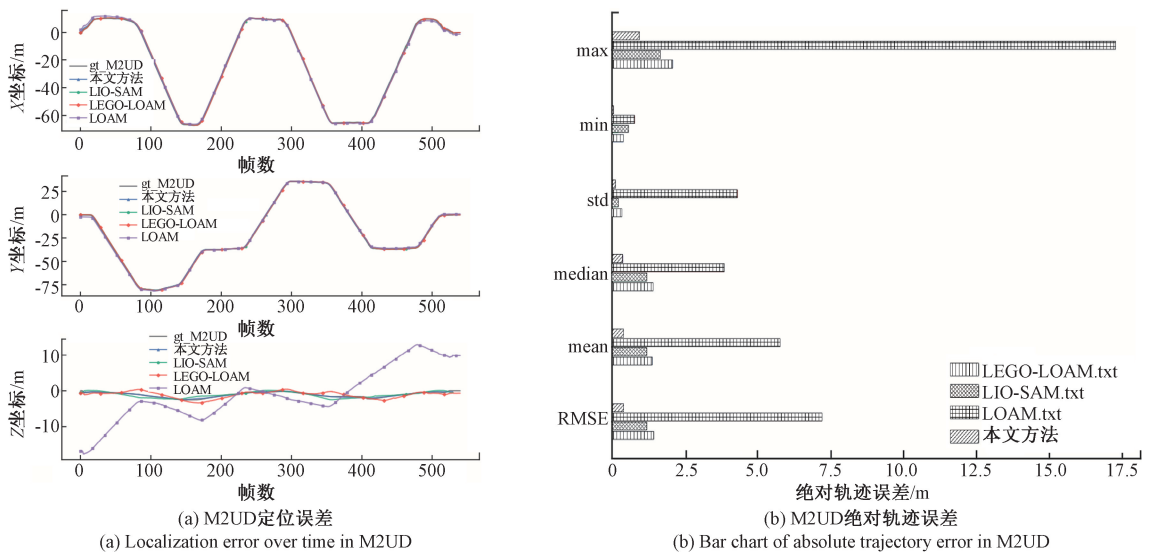


图6 M2UD 的定位误差
Fig. 6 Localization error in M2UD

表3 本方法与 M2UD 上的其他开源算法的绝对轨迹误差进行比较

Table 3 Comparison of ATE between the proposed method and other open-source algorithms in M2UD (m)

方法	均方根误差	平均误差	误差中位数	误差标准差	最小误差	最大误差
本文方法	0.413 328	0.396 032	0.392 463	0.118 318	0.061 105	0.938 775
LIO-SAM	1.217 340	1.196 263	1.194 162	0.225 545	0.249 709	1.662 063
LOAM	7.213 061	5.771 683	3.862 442	4.326 190	0.808 366	17.258 294
LEGO-LOAM	1.439 630	1.400 227	1.424 385	0.334 510	0.404 186	2.109 201




图7 自主移动无人车实验平台


Fig. 7 Autonomous mobile robot experimental platform

在首个驾驶场景中,车辆沿一条长直道路行驶,其轨迹如图 8(a) 所示。起点位于左侧教学楼入口处,车辆初始沿道路右侧行驶,穿过道路后持续保持在左侧车道行进。行驶过程中经过两处弯道,轨迹未呈现明显漂移现象。图 8(b) 对比了本方法与其他主流算法在场景 1 中的轨迹,清晰展示了所提方法在定位精度与轨迹一致性方面的优势。

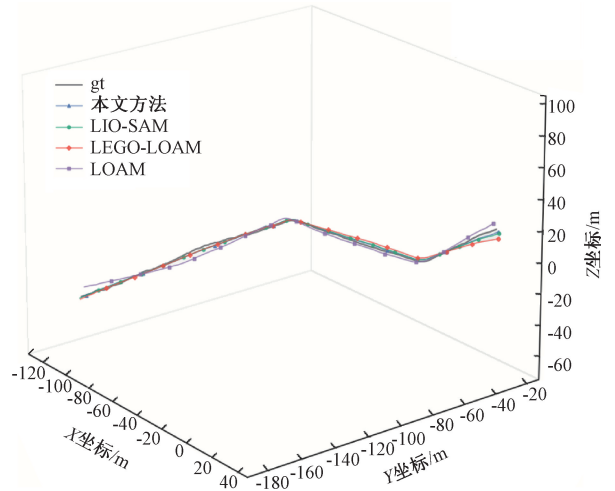
图 9(a) 进一步对比了各算法沿 X、Y、Z 坐标轴的轨迹表现。如图所示,各算法的 X 与 Y 轴轨迹整体较为稳

定。然而,在 Z 轴上,各算法均表现出不同程度的偏差,主要受限于实验平台搭载的 16 线激光雷达垂直分辨率较低以及 GPS 参考真值本身的 Z 轴漂移。具体分析 Z 轴轨迹可得,LEGO-LOAM 与 LOAM 的 Z 轴偏差波动幅度大且呈现明显的漂移趋势;LIO-SAM 的 Z 轴轨迹相对平缓,但仍存在小幅波动;得益于视觉约束的引入和精确的初始化,本算法在 Z 轴轨迹稳定性方面表现最优,偏差波动范围最小,且未出现明显漂移现象。图 9(b) 展示了各算法在场景 1 中的绝对轨迹误差统计柱状图,各项指标给出在表 4 中。数据表明,本算法性能显著优于对比算法,以 RMSE 作为评估标准,与 LOAM、LEGO-LOAM 和 LIO-SAM 相比,本算法的轨迹误差分别显著降低了 55.8%、41.2% 和 9.7%。

第 2 个驾驶场景的复杂度显著提升,驾驶时间长达 1 300 s,转弯数量增至 14 个,其轨迹如图 10(a) 所示。无人车行驶至中段时,轨迹出现轻微漂移,但通过回环检测及时校正;返回起点时再次进行回环检测,整体轨迹未表现出明显漂移现象。图 10(b) 对比了本方法与其他算法在场景 2 中的轨迹,清晰展示了所提方法在定位精度与轨迹一致性方面的优势。




(a) 卫星参考影像映射图
(a) Satellite reference image



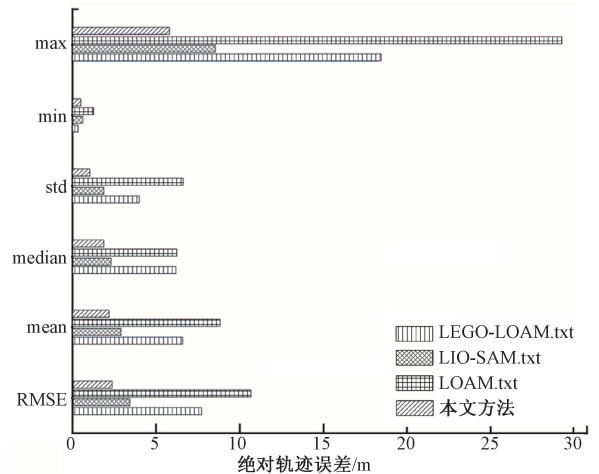
(b) 轨迹对比
(b) Trajectory comparison chart

图 8 场景 1 的定位结果

Fig. 8 Localization results in scene 1



(a) 场景 1 定位误差
(a) Localization error over time in scene 1



(b) Bar chart of absolute trajectory error in scene 1

图 9 场景 1 的定位误差

Fig. 9 Localization error in scene 1

表 4 本方法与场景 1 上的其他开源算法的绝对轨迹误差进行比较

Table 4 Comparison of ATE between the proposed method and other open-source algorithms in scene 1 (m)

方法	均方根误差	平均误差	误差中位数	误差平方差	最小误差	最大误差
本文方法	1.1027 78	1.043 083	0.982 679	0.357 906	0.279 195	1.949 848
LIO-SAM	1.221 246	1.127 068	1.086 076	0.470 275	0.199 305	2.875 828
LOAM	2.487 693	2.201 359	1.792 623	1.158 720	0.683 747	5.479 859
LEGO-LOAM	1.872 708	1.512 951	1.122 339	1.103 637	0.136 086	5.988 046

图 11(a) 进一步对比了各算法在 X、Y、Z 三轴上的轨迹表现。如图所示,各算法的 X 与 Y 轴轨迹整体保持稳定。与场景 1 一致,受实车搭载的 16 线激光雷达垂直分

辨率较低的限制,各算法的 Z 轴轨迹均存在不同程度的偏差。具体分析 Z 轴轨迹可得,LEGO-LOAM 与 LOAM 的 Z 轴偏差波动显著,且呈现明显漂移趋势,其中 LEGO-

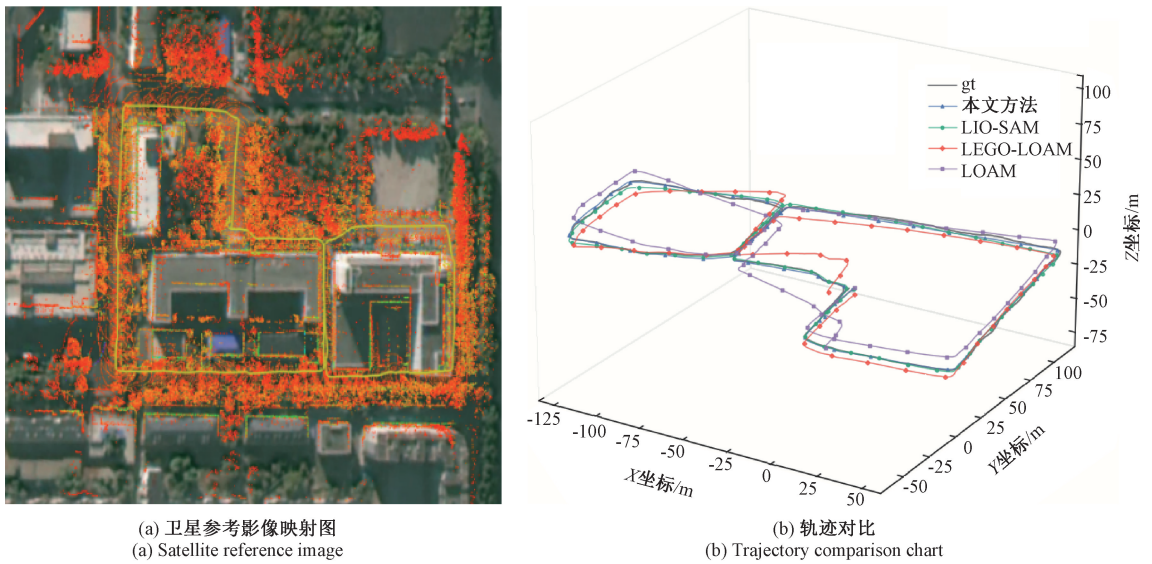


图 10 场景 2 的定位结果
Fig. 10 Localization results in scene 2

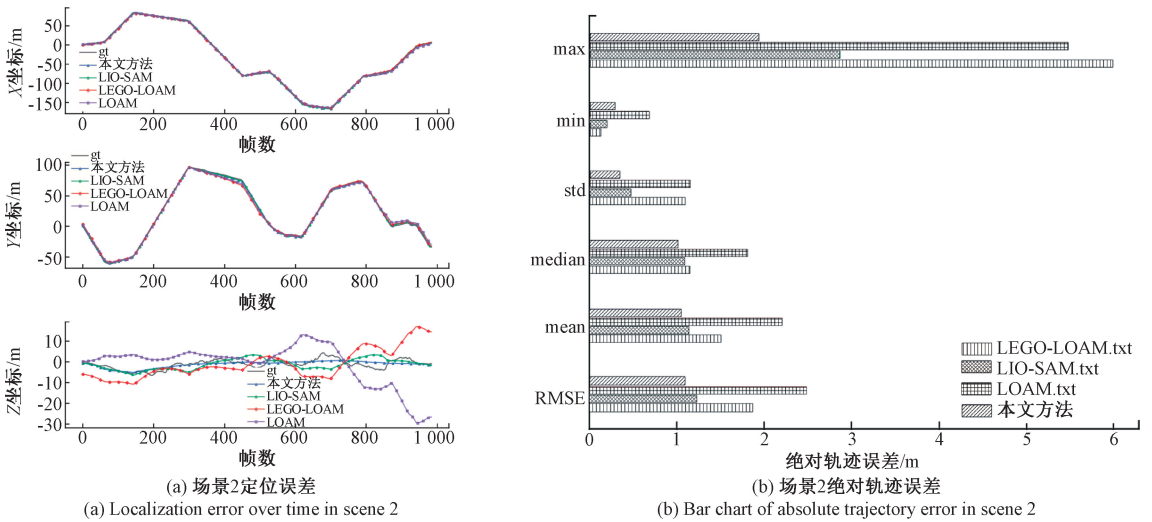


图 11 场景 2 的定位误差
Fig. 11 Localization error in scene 2

LOAM 的 Z 轴波动范围为 -10~20 m, LOAM 更是达到 -30~15 m; LIO-SAM 的 Z 轴轨迹相对平缓, 但仍存在小幅波动; 得益于视觉约束的引入, 本算法在 Z 轴轨迹稳定性上表现最优, 其轨迹几乎与理论平面参考线完全吻合, 偏差波动范围最小。图 11(b) 以柱状图形式展示了场景 2 中各算法的绝对轨迹误差统计结果, 结合表 5 的定量数据可知, 本算法在所有评估指标上均显著优于对比算法。其中, 以关键指标 RMSE 为例, 本算法的轨迹误差较 LOAM 降低了 77.4%, 较 LEGO-LOAM 降低了 68.7%, 较 LIO-SAM 降低了 30.9%, 性能优势随场景复杂度提升更加显著。

2) 建图效果评估
为全面验证本算法的建图能力, 本部分通过俯视与侧视视角对场景 1 和 2 的建图效果进行可视化分析, 结果如图 12 和 13 所示。
本算法与其他算法对场景 1 的建图效果对比如图 12(a) 俯视图和图 12(b) 侧视图所示。由于场景 1 结构相对简单, 移动距离短且转向少, 各算法的俯视建图效果均较好, 无明显漂移, 仅 LOAM 在最后的长直道出现轻微弯曲。然而在侧视图中, 漂移现象显著, LOAM 和 LEGO-LOAM 建图结果随车辆运动发生严重向上漂移; LIO-SAM 建图也存在轻微上漂趋势; 相比之下, 本算法在

表 5 本方法与场景 2 上的其他开源算法的绝对轨迹误差进行比较

Table 5 Comparison of ATE between the proposed method and other open-source algorithms in scene 2 (m)

方法	均方根误差	平均误差	误差中位数	误差平方差	最小误差	最大误差
本文方法	2.416 33	2.154 49	1.889 47	1.093 99	0.547 17	5.642 17
LIO-SAM	3.497 68	2.937 96	2.321 60	1.897 94	0.570 31	8.486 69
LOAM	10.737 21	8.431 86	6.252 22	6.647 66	1.316 77	29.315 88
LEGO-LOAM	7.742 61	6.629 55	6.227 82	3.999 63	0.387 26	18.372 12

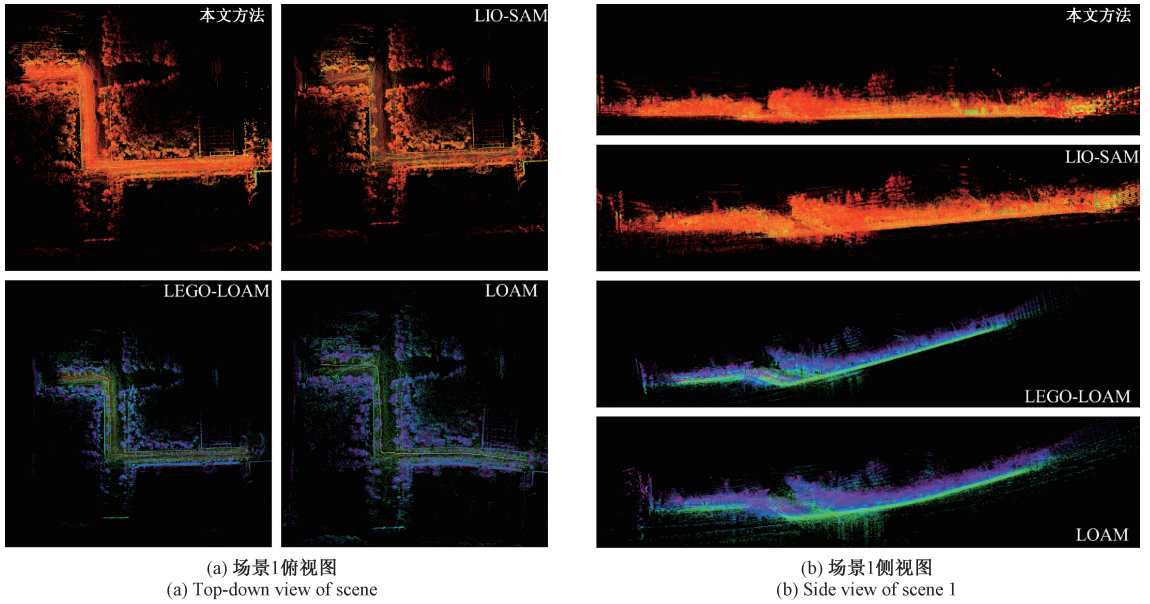


图 12 各算法实车场景 1 建图效果

Fig. 12 Real-vehicle mapping effects of different algorithms in scene 1

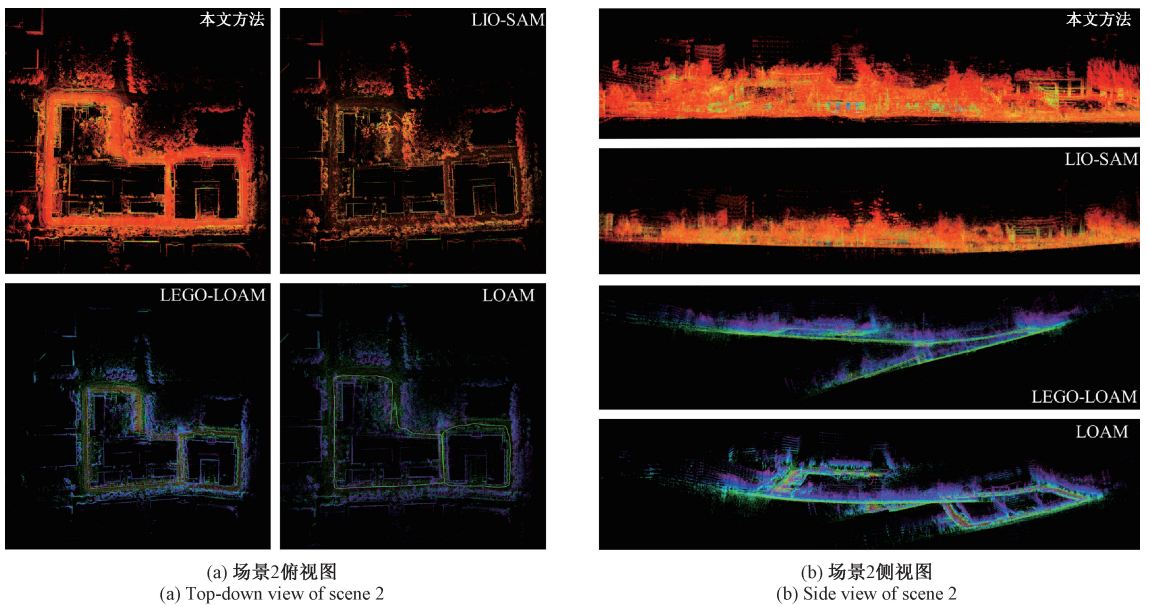


图 13 各算法实车场景 2 建图效果

Fig. 13 Real-vehicle mapping effects of different algorithms in scene 2

侧视图的表现几乎完全吻合理论平面参考线,且偏差波动范围最小。

本算法与其他算法针对复杂场景2的建图效果对比如图13(a)俯视图和图13(b)侧视图所示。在俯视图中可见,由于场景2结构复杂、移动距离长且转向频繁,LEGO-LOAM与LOAM在下方长直道区域出现明显地图弯曲,LIO-SAM在教学楼中间小道发生局部漂移;而本算法未出现明显形变,长直道结构保持线性。在侧视图中,LOAM和LEGO-LOAM随运动地图发生大幅上下漂移;LIO-SAM随着车辆的移动,呈现中部下凹、两侧上凸的地图漂移形态;本提出的算法所建立的地图与理论平面参考线高度吻合,偏差波动范围最小,点云沿道路方向紧密分布且无扭曲变形,印证了其在复杂场景下的稳定性。

3) 实时性评估

为评估本算法的运行效率,在校园实车数据集上将其与LIO-SAM、LEGO-LOAM和LOAM算法进行了对比分析。各算法的平均单帧处理时间如表6所示。实验结果表明,在相同数据集上,本算法的平均处理时间略慢于LEGO-LOAM算法,与LIO-SAM算法相当,并显著快于LOAM算法。本算法在轨迹精度与建图质量上具有明显优势,且34 Hz的处理帧率完全满足相机与激光雷达的实时性要求。

表6 平均运行时间
Table 6 Average running time

方法	校园 场景 1/ms	校园 场景 2/ms	平均运行 时间/ms	频率/Hz
本文方法	27.43	31.35	29.39	34.02
LIO-SAM	28.46	30.08	29.27	34.17
LOAM	54.62	56.48	55.55	18.00
LEGO-LOAM	26.76	27.98	27.37	36.54

3 结 论

针对当前多传感器SLAM系统存在视觉尺度误差大、IMU参数与重力方向估计不准确以及局部滑窗优化地图点“重影”的问题,提出了一种基于因子图优化的激光雷达-视觉-惯性紧耦合的SLAM算法。主要结论为:

1) 以激光点云为基准估计视觉特征点深度信息,结合邻域筛选与统计优化,有效抑制异常点并提升深度估计精度,融合视觉、激光雷达与IMU信息联合求解IMU内参和重力方向,有效降低地图垂直漂移,提升图优化起点精度;

2) 依据多源异构传感器的数据信息,基于滑动窗口

优化框架重新设计局部优化方案,通过共视投影匹配消除视觉特征点漂移,增强地图点精度与鲁棒性,同时融合视觉重投影、激光几何约束与IMU预积分因子,在滑窗内优化位姿与地图点,保障实时性的同时提升局部精度;

3) 通过融合时空协同约束与几何结构感知的回环检测方法在因子图中添加回环因子,并采用增量式优化的方案对全局因子图进行优化,保证实时性的同时有效抑制累积误差。

参考文献

- [1] 周治国,曹江微,邸顺帆. 3D激光雷达SLAM算法综述[J]. 仪器仪表学报, 2021, 42(9): 13-27.
ZHOU ZH G, CAO J W, DI SH F. Overview of SLAM algorithm for 3D LiDAR [J]. Chinese Journal of Scientific Instrument, 2021, 42(9): 13-27.
- [2] MUR-ARTAL R, MONTIEL J M M, TARDOS J D. ORB-SLAM: A versatile and accurate monocular SLAM system [J]. IEEE Transactions on Robotics, 2015, 31(5): 1147-1163.
- [3] MUR-ARTAL R, TARDOS J D. ORB-SLAM2: An open-source slam system for monocular, stereo, and RGB-D cameras [J]. IEEE Transactions on Robotics, 2017, 33(5): 1255-1262.
- [4] GUO H L, ZHU J K, CHEN Y P. E-LOAM: LiDAR odometry and mapping with expanded local structural information [J]. IEEE Transactions on Intelligent Vehicles, 2022, 8(2): 1911-1921.
- [5] XU X B, ZHANG L, YANG J, et al. A review of multi-sensor fusion SLAM systems based on 3D LiDAR [J]. Remote Sens. 2022, 14(12): 2835.
- [6] LIN J R, ZHANG F. R3LIVE: A robust, real-time, RGB-colored, LiDAR-inertial-visual tightly-coupled state Estimation and mapping package [C]. 2022 IEEE International Conference on Robotics and Automation, 2022: 10672-10678.
- [7] LIN J R, ZHANG F. R3LIVE++: A robust, real-time, radiance reconstruction package with a tightly-coupled LiDAR-inertial-visual state estimator [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2024, 46(12): 11168-11185.
- [8] 诸葛晶昌,高宏,罗其俊,等. 激光雷达IMU紧耦合SLAM算法研究[J]. 仪器仪表学报, 2025, 45(11): 243-251.
ZHUGE J CH, GAO H, LUO Q J, et al. Research on tightly coupled SLAM algorithm for LiDAR IMU [J].

- Chinese Journal of Scientific Instrument, 2025, 45(11): 243-251.
- [9] XU W, CAI Y X, HE D J, et al. FAST-LIO2: Fast direct LiDAR-inertial odometry [J]. IEEE Transactions on Robotics, 2022, 38(4):2053-2073.
- [10] ZHENG CH R, ZHU Q Y, XU W, et al. FAST-LIVO: Fast and tightly-coupled sparse-direct LiDAR-inertial-visual odometry [C]. 2022 IEEE/RSJ International Conference on Intelligent Robots and Systems, 2022: 2671-2677.
- [11] ZHENG CH R, XU W, ZOU Z H, et al. FAST-LIVO2: Fast, direct LiDAR-inertial-visual odometry [J]. IEEE Transactions on Robotics, 2024:326-346.
- [12] 李春磊, 陈久朋, 伞红军, 等. 基于多传感器的紧耦合三维室内定位与建图 [J]. 仪器仪表学报, 2024, 45(7):121-131.
- LI CH L, CHEN J P, SAN H J, et al. Tightly coupled 3D indoor SLAM based on multi-sensor [J]. Chinese Journal of Scientific Instrument, 2024, 45(7):121-131.
- [13] WEN T C, FANG Y CH, LU B, et al. LIVER: A tightly coupled LiDAR-inertial-visual state estimator with high robustness for underground environments [J]. IEEE Robotics and Automation Letters, 2024, 9(3):2399-2406.
- [14] SHAN T X, ENLOT B, RATTI C, et al. LVI-SAM: Tightly-coupled LiDAR-visual-inertial odometry via smoothing and mapping [C]. 2021 IEEE International Conference on Robotics and Automation, 2021: 5692-5698.
- [15] 孙明晓, 王鑫源, 栾添添, 等. 动态环境下基于深度图的无人车激光 SLAM 算法 [J]. 仪器仪表学报, 2025, 46(3):101-109.
- SUN M X, WANG X Y, LUAN T T, et al. A laser SLAM algorithm for unmanned vehicles based on depth map in dynamic environment [J]. Chinese Journal of Scientific Instrument, 2025, 46(3):101-109.
- [16] LUO H K, LIU Y, GUO CH, et al. SuperVINS: A real-time visual-inertial SLAM framework for challenging imaging conditions [J]. IEEE Sensors Journal, 2025, 25(13):26042-26050.
- [17] 叶俊强, 尤睿, 于明鑫, 等. 基于稀疏直接法的特征增强视觉 SLAM 算法 [J]. 仪器仪表学报, 2023, 44(6):205-212.
- YE J Q, YOU R, YU M X, et al. Feature-enhanced visual SLAM algorithm based on the sparse direct method [J]. Chinese Journal of Scientific Instrument, 2023, 44(6):205-212.
- [18] CHENG X L, GENG K K, LIU ZH CH, et al. LIVOX-CAM: Adaptive coarse-to-fine visual-assisted LiDAR odometry for solid-state LiDAR [J]. IEEE Robotics and Automation Letters, 2025:10982-10989.
- [19] VIZZO I, GUADAGNINO T, MERSCH B, et al. KISS-ICP: In defense of point-to-point icp-simple, accurate, and robust registration if done the right way [J]. IEEE Robotics and Automation Letters, 2023, 8(2):1029-1036.
- [20] 王禹, 王彬彬, 王斐, 等. 基于闭环检测和地面优化的激光雷达惯性里程计建图与定位 [J]. 仪器仪表学报, 2025, 46(5):205-213.
- WU Y, WU B B, WU F, et al. Research on the localization and mapping based on closed-loop detection and ground optimization [J]. Chinese Journal of Scientific Instrument, 2025, 46(5):205-213.

作者简介



班喜程, 2012 年于黑龙江科技大学获得学士学位, 2017 年、2022 年于哈尔滨工程大学获得硕士学位、博士学位, 现为哈尔滨理工大学讲师, 主要研究方向为无人系统的智能感知、定位与建图、导航与控制。

E-mail: banxicheng@hrbust.edu.cn

Ban Xicheng received his B. Sc. degree from Heilongjiang University of Science and Technology in 2012, his M. Sc. and Ph. D. degrees both from Harbin Engineering University in 2017 and 2022, respectively. He is currently a lecturer at Harbin University of Science and Technology. His main research interests include intelligent perception, localization and mapping (SLAM), and navigation and control for unmanned systems.



马继瑞, 2023 年于哈尔滨理工大学获得学士学位, 现于哈尔滨理工大学攻读硕士学位, 主要研究方向为多传感器融合 SLAM。

E-mail: 2320510144@hrbust.edu.cn

Ma Jierui received his B. Sc. degree from Harbin University of Science and Technology in 2023. He is currently pursuing a master's degree at Harbin University of Science and Technology. His main research interest is multi-sensor fusion SLAM.



尤波(通信作者),1982年于哈尔滨工业大学获得学士学位,1987年于哈尔滨科技大学获得硕士学位,1995年于哈尔滨工业大学获得博士学位,现为哈尔滨理工大学教授,主要研究方向为智能机器人与机电控制。

E-mail: youbo@hrbust.edu.cn

You Bo (Corresponding author) received his B. Sc. degree from Harbin Institute of Technology in 1982, M. Sc. degree from Harbin University of Science and Technology in 1987, and Ph. D. degree from Harbin Institute of Technology in 1995. He is currently a professor at Harbin University of Science and

Technology. His main research interests include intelligent robot, and mechatronic control.



史涛,2002年于中国人民解放军炮兵学院获得学士学位,现为山东百盟信息技术有限公司副高级工程师,主要研究方向为电子信息工程技术。

E-mail:st800820@163.com

Shi Tao received his B. Sc. degree from PLA Artillery College. He is currently an associate senior engineer in Shandong Baimeng Information Technology Co., Ltd. His main research interest includes electronic information engineering technology.