

RC-LIO: 退化环境中多传感器融合补偿的 激光雷达惯性里程计

李健翔¹ 翟弟华¹ 丁子恺¹ 蔡鹏程¹ 夏元清^{1,2}

摘 要 基于激光雷达的同步定位与建图在移动机器人和自动驾驶中得到广泛应用,但是在雨、雪和粉尘等退化环境中,激光束易受颗粒物散射干扰产生大量噪点,导致地图失真和定位漂移.本文提出毫米波雷达补偿的强度动态统计离群值去除方法(RC-IDSOR),以实时滤除激光噪点并保留环境结构特征.进一步构建雷达补偿的激光雷达惯性里程计(RC-LIO):一方面,优化动态局部协方差与设计强度置信度加权机制,提高广义ICP匹配的稳定性;另一方面,在误差状态卡尔曼滤波预测中添加二阶补偿项,提升IMU在高动态场景下的传播精度.实验结果显示,RC-IDSOR在WADS数据集上的平均F-score超过0.85,精确度提升约6.8%;RC-LIO在SubT-MRS退化场景中的平均绝对轨迹误差约为0.33 m,在Snail-Radar强降雨环境下的定位误差较不启用滤波降低约49.6%.最后将RC-LIO部署于重粉尘环境工业车辆,测试算法短时重复定位误差小于5.6 cm,且支持长时稳定运行,具备实时性和工程可行性.

关键词 点云去噪;多传感器融合;退化环境;激光雷达惯性里程计;粉尘去除

引用格式 李健翔,翟弟华,丁子恺,蔡鹏程,夏元清. RC-LIO: 退化环境中多传感器融合补偿的激光雷达惯性里程计. 自动化学报, 2026, 52(6): 1260–1278

DOI 10.16383/j.aas.c250640 **CSTR** 32138.14.j.aas.c250640

RC-LIO: LiDAR-inertial Odometry Enhanced by Multi-sensor Fusion Compensation Under Degraded Environments

LI Jian-Xiang¹ ZHAI Di-Hua¹ DING Zi-Kai¹ CAI Peng-Cheng¹ XIA Yuan-Qing^{1,2}

Abstract LiDAR-based simultaneous localization and mapping has been widely applied in mobile robotics and autonomous driving. However, in degraded environments such as rain, snow, and dust, laser beams are easily disturbed by particle scattering, generating a large number of noise points, which leads to map distortion and localization drift. Thus, a millimeter-wave radar-compensated intensity-based dynamic statistical outlier removal method (RC-IDSOR) is proposed to filter laser noise points in real time while preserving environmental structural features. Furthermore, a radar-compensated LiDAR-inertial odometry (RC-LIO) is developed. First, a dynamic local covariance is optimized and an intensity confidence weighting mechanism is designed to improve the stability of generalized ICP matching. Then, a second-order compensation term is incorporated into the error-state Kalman filter prediction to enhance IMU propagation accuracy under highly dynamic scenes. Experimental results show that RC-IDSOR achieves an average F-score exceeding 0.85 on the WADS dataset, with a precision improvement of about 6.8%. RC-LIO attains an average absolute trajectory error of about 0.33 m in degraded SubT-MRS scenarios, and reduces localization error by about 49.6% in heavy-rain environments on the Snail-Radar dataset compared with non-filtering odometry. Finally, RC-LIO is deployed on industrial vehicles operating in heavy-dust environments, where experiments demonstrate short-term repeatability errors below 5.6 cm and stable long-term operation, validating its real-time performance and engineering feasibility.

Keywords point cloud denoising; multi-sensor fusion; degraded environments; LiDAR-inertial odometry; dust removal

Citation Li Jian-Xiang, Zhai Di-Hua, Ding Zi-Kai, Cai Peng-Cheng, Xia Yuan-Qing. RC-LIO: LiDAR-inertial odometry enhanced by multi-sensor fusion compensation under degraded environments. *Acta Automatica Sinica*, 2026, 52(6): 1260–1278

收稿日期 2025-11-15 录用日期 2026-01-30
Manuscript received November 15, 2025; accepted January 30, 2026
国家自然科学基金(U25A20460, 62173035),北京市自然科学基金海淀联合基金重点项目(L252035)资助
Supported by National Natural Science Foundation of China (U25A20460, 62173035) and Key Project of Haidian Joint Fund of Beijing Natural Science Foundation (L252035)

本文责任编辑 罗彪
Recommended by Associate Editor LUO Biao
1. 北京理工大学自动化学院 北京 100081 2. 中原工学院自动化与电气工程学院 郑州 451191
1. School of Automation, Beijing Institute of Technology, Beijing 100081 2. School of Automation and Electrical Engineering, Zhongyuan University of Technology, Zhengzhou 451191

随着自动驾驶与机器人技术的飞速发展,实时且精确的环境感知与定位是实现机器人自主工作的核心关键. 在相关任务中,激光雷达 (LiDAR) 因其能够获取高精度的三维环境几何信息而被广泛应用^[1]. 诸多同步定位与建图 (simultaneous localization and mapping, SLAM) 方法,如 LOAM 在结构化场景与高质量数据集中都取得了优秀的定位精度^[2]. 然而,在实际应用中,诸如雨、雪、粉尘等恶劣天气与退化的作业场景给激光雷达感知带来巨大挑战. 这是因为在结构光的传播中,遇到颗粒物时会产生散射,导致点云数据产生噪声^[3]. 这些噪声点不仅会污染环境地图,更会导致错误的帧间匹配,引起定位漂移,进而造成整个 SLAM 系统的失效^[4]. 因此,设计精确的激光点云去噪方法以及鲁棒的里程计是实现无人系统准确感知、精确定位的关键^[4-6].

激光点云去噪的方法主要分为基于传统滤波算法、基于深度学习方法以及基于其他传感器补偿方法 (例如 4D RADAR) 三个方面^[4]. 其中,滤波是一种常用的实时激光雷达点云去噪方法. 点云库 (point cloud library, PCL)^[7] 中的统计离群值去除 (statistical outlier removal, SOR) 滤波器与半径离群值去除 (radius outlier removal, ROR) 滤波器可以消除部分雨雪噪声,但也会抹去大量关键的环境特征. 因此,相关研究者提出了改进措施. Charron 等^[8] 提出动态半径离群值去除 (DROR) 滤波器用于去除雪噪,但是受制于运算速度以及精度. Kurup 等^[9] 拓展 SOR 滤波器为动态统计离群值去除 (DSOR) 滤波器,并介绍 WADS 数据集以及 DSOR 的优异去噪表现,但是 DSOR 去除噪声的同时会去除大量环境点云,造成感知信息的丢失. 文献 [10] 引入点云强度信息,提出低强度的动态统计离群值去除方法 (LIDSOR),保留高强度的环境点云以提高滤波的准确性. 文献 [11] 引入时间维度进行进一步的拓展,提出时空去除 (TOR). 深度学习应用于去噪时需要针对具体情形开发网络. WeatherNet^[12] 作为首个基于卷积神经网络的点云去噪方法被提出. 随后,Seppänen 等^[13-14] 提出专注于四维点云去噪的 4DenoiseNet 以及 SMEDen. 这些基于网络的方法在 WADS、SnowyKITTI^[9, 13] 等数据集上都取得了不错的去除降雪噪声的效果. 然而,由于带有具体语义标注的退化环境数据集匮乏且网络复杂度高,基于深度学习的方法的泛化性以及实时性面临很大的挑战. 多传感器融合是退化环境中自动驾驶技术的研究热点. 4D 毫米波雷达 (4D RADAR) 被广泛应用于追踪前向目标的 3D 位置,其具有全天候性,可以实现在退化环境下的鲁棒感知^[15-16]. 但是与激光雷达相比,4D 毫米波雷达的分辨率有限,并且毫米波数据容易受到杂波、噪声和多径效应的影响^[17-19].

党相卫等^[20] 提出一种融合毫米波雷达和激光雷达的鲁棒的感知算法,以满足智能驾驶在复杂多变的环境中鲁棒感知的需求. 他们将传感器数据对齐进行互补,实现了噪声准确识别. Chen 等^[21] 在三维成像任务中使用 ICP (iterative closest point)^[22] 精确融合激光点云和毫米波点云,以生成环境的高保真 3D 重建.

激光雷达惯性里程计的状态估计主要沿图优化与滤波两个方向演进. 基于图优化的代表性工作 LIO-SAM^[23] 通过将 IMU 预积分、激光里程计等约束融入因子图,实现在大尺度场景中的高性能位姿估计. 而在滤波方向,FAST-LIO^[24] 算法则展现了卓越的效率优势. 其通过迭代扩展卡尔曼滤波 (iterated extended Kalman filter, IEKF) 实现了毫秒级的处理速度,后续的改进版本 FAST-LIO2^[25] 引入增量式体素地图 (ikd-Tree)^[26] 处理全局点云,进一步提升了精度与鲁棒性. Chen 等^[27] 提出的 IG-LIO 使用增量体素地图来表示周围环境的概率模型,并利用 IMU 数据约束里程计状态,在隧道、走廊等挑战性环境中稳定性更好. Wu 等^[28] 提出的 DALI-SLAM 采用基于双样条的点云运动畸变校正方法,利用当前帧到地图的配准姿态和 IMU 的积分姿态分别拟合连续时间轨迹、更新离散 IMU 位姿,提升了点云运动畸变校正的精度.

在雨、雪及粉尘等退化感知环境中,激光 SLAM 性能下降体现在点云统计特性、几何约束可信度以及惯性模型适用性等多个层面的退化. 首先,悬浮颗粒引入的大量随机分布的离群点,使传统基于统计分布假设的去噪方法难以同时兼顾高效噪声抑制和准确环境特征保留;其次,退化环境下激光点云结构信息显著减弱,导致匹配退化频繁发生与状态估计发散;最后,在高动态工况下,IMU 测量呈现非高斯与时变特性,传统 ESKF^[29] 中基于固定线性化假设的协方差传播模型难以准确刻画实际运动的不确定性.

为应对上述挑战,本文提出雷达补偿的强度动态统计离群值去除 (radar-compensated intensity-based dynamic statistical outlier removal, RC-ID-SOR) 融合去噪方法与雷达补偿的激光雷达惯性里程计 (radar-compensated LiDAR-inertial odometry, RC-LIO). 通过设计 RC-IDSOR 中的动态阈值计算方法以及毫米波点云先验补偿方法,实现噪声与环境的准确分割. 由此,RC-LIO 在数据预处理阶段得以剔除点云噪点,从而获得准确的环境信息. 接着在 RC-LIO 中,重新构建点云协方差,通过为协方差添加各项同性补偿与使用强度置信度加权,提高点云约束的可信度;提出自适应 ESKF 用于 IMU 前向传播. 在 ESKF 的基础上,设计非线性修正项,

添加到协方差传播的雅可比矩阵, 补偿瞬时的 IMU 抖动偏差, 以实时修正系统协方差传播过程, 进而提升 IMU 模型在高动态场景下的传播精度.

本文构建了涵盖数据集验证与真实场景应用的多层级实验体系以全面评估算法的综合性能与泛化能力. 在数据集验证层面, 选取 WADS、SubT-MRS、Snail-Radar 公开数据集进行系统性测试^[9, 30-31]. 结果表明, RC-IDSOR 在 WADS 上对降雪噪声的去除精度较 LIDSOR 有所提升; RC-LIO 在 SubT-MRS 复杂退化场景中保持较低的轨迹漂移, 平均绝对轨迹误差小于 SubT-MRS 挑战参赛算法误差. 在 Snail-Radar 的降雨环境中, 基于 RC-IDSOR 的 RC-LIO 较其他滤波方法以及缺乏滤波环节的里程计具有更高的定位精度. 在实际工业验证层面, 本文将所提算法部署于极端粉尘环境下的工业铲运作业车辆的 ARM 边缘计算平台. 实验结果定性表明 RC-IDSOR 显著改善粉尘场景下的点云密度与几何一致性. 通过统计资源占用和算法速率, 验证了算法的实时性. RC-LIO 的短时重复定位误差维持在厘米级别, 并且在长时作业中端到端的 z 轴漂移较小. 该结果表明, RC-LIO 具备良好的工程可行性与应用潜力. 整体研究为实现全工况下高可靠的移动机器人自主定位提供了一条有效的技术路径.

1 算法概述

本文提出的 RC-LIO 将 RC-IDSOR 作为激光去噪模块嵌入预处理部分, 雷达补偿去噪之后的激光点云经过优化的 (generalized ICP, GICP) 匹配^[32], 形成激光约束; IMU 按照自适应 ESKF 模型传播, 获得状态的初步估计和添加了非线性项补偿的状态协方差, 作为 RC-LIO 系统状态和 IMU 约束. 紧耦

合激光约束和 IMU 约束高速率更新系统状态, 并且将激光点云映射到基于哈希索引的体素概率地图中, 实现定位、建图功能. RC-LIO 的整体算法流程如图 1 所示. 其中, RC-IDSOR 激光去噪模块对应第 2 节; IMU 的自适应前向传播及协方差补偿过程详见第 3.2 节与第 3.3 节; 基于历史体素地图的激光匹配与优化 GICP 约束构建方法分别在第 3.4 节与第 3.5 节中给出; 最终的里程计状态更新过程对应第 3.6 节. 算法具体实施与实际部署可分为三个部分.

1.1 雷达补偿强度动态滤波 RC-IDSOR

采用 OpenCalib 工具包^[33] 标定激光雷达与 4D 毫米波雷达, 将 4D 毫米波点云对齐至激光雷达坐标系. 本文实验中未启用 OpenCalib 提供的在线标定或在线精炼模块. 所有传感器外参固定不变, 以保证里程计性能评估的可重复性与公平性. 基于毫米波点云的强度速度信息滤除多径噪声, 确定毫米波检测目标. 在激光系下搜索两组点云的重叠区域, 并预标记对应激光点为不可去除. 根据激光点云噪声的空间分布设定合理半径阈值, 对阈值范围内点云依次施加强度筛选与动态滤波, 并对不可去除点和 4D 毫米波点进行补偿, 完成 RC-IDSOR 去噪流程.

1.2 改进 GICP 的自适应 RC-LIO

采用 LI-Init 工具包^[34] 标定激光雷达与 IMU 之间的外参及时差. 里程计线程以融合点云与 IMU 测量为输入, 执行状态预测与耦合优化. 点云频率较低 (10 Hz), IMU 频率较高 (200 Hz), 故将点云按照标定结果变换到 IMU 安装位置的右手系中, 与对应时间戳内的 IMU 数据打包为一帧. 系统基于 IMU 微分运动学持续前向传播获得预测状态^[29],

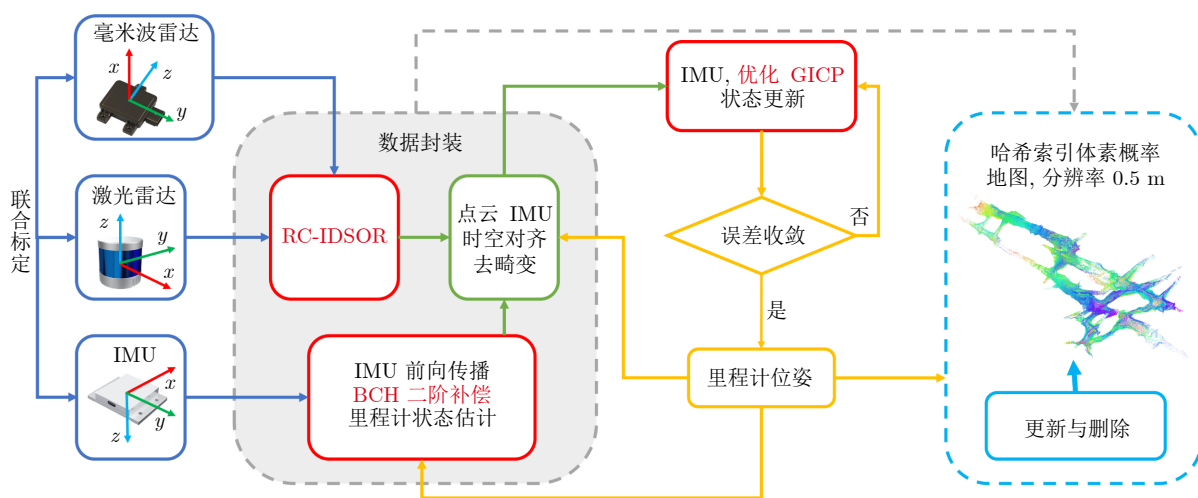


图 1 RC-LIO 算法流程图

Fig.1 Flowchart of the RC-LIO algorithm

并按照设计的二阶 BCH 修正项来精化协方差传播. 使用强度置信度加权修正点云的协方差, 联合改进的 GICP 约束与 IMU 约束更新系统状态. 保存位姿序列与点云地图供后续评估使用, 完成 RC-LIO 线程.

1.3 边缘部署与真实场景验证

将整体系统部署于工业车辆的 Jetson AGX Orin 边缘计算平台上. 采用并行处理架构完成点云补偿去噪、协方差计算、地图构建以及改进 GICP 约束耦合等关键步骤. 统计算法分别在 x86 和 ARM 平台的速率以及资源占用率, 验证算法的实时性. 进一步将算法应用于仓库作业场景, 在重粉尘铲运环境下开展稳定运行与长期定位实验. 实验结果表明, 所提算法在极端退化环境中具备良好的工程可行性, 能够实现工业作业车辆稳定且精确的实时定位.

2 RC-IDSOR 融合去噪

2.1 点云时空对齐

时间同步采用软同步与硬同步相结合的方式. 在实际工作场景采集数据时, 使用 Jetson AGX Orin 设备的秒脉冲信号 (pulse per second, PPS) 来同步传感器的工作, 实现硬同步. 与此同时, 使用 rostopic 录制数据, 以获得激光点云与 4D 毫米波点云的具体点云信息和对应的时间戳. 通过统一所有传感器数据时间戳为 Unix 时间戳来实现设备的软同步.

空间同步使用 OpenCalib 工具包. 将激光点云与毫米波点云数据转化为 pcd 格式, 选择相同时间戳的两组点云作为工具包的输入, 大致估计两组点云的位姿, 旋转两组点云, 使得尽可能多的高置信度的点云对齐, 得到粗匹配结果如式 (1) 所示:

$${}^L\mathbf{T}_R = \begin{bmatrix} {}^L\mathbf{R}_R & {}^L\mathbf{t}_R \\ \mathbf{0}^T & 1 \end{bmatrix} \quad (1)$$

其中, ${}^L\mathbf{T}_R$ 代表毫米波点云到激光点云的位姿变换矩阵; ${}^L\mathbf{R}_R$ 与 ${}^L\mathbf{t}_R$ 为旋转与平移向量. 选取激光点云与毫米波点云的重合部分进一步处理. 为获得更高精度的标定结果, 本文使用基于点到点 ICP^[22] 的非线性最小二乘优化框架, 对粗匹配结果进行细优化. 基于 kd-Tree 搜索获得匹配的激光点 $\mathbf{p}_i^{\text{lidar}}$ 和毫米波点 $\mathbf{p}_i^{\text{radar}}$ 的集合 $\mathcal{C} = \{(\mathbf{p}_i^{\text{radar}}, \mathbf{p}_i^{\text{lidar}})\}$. 位姿优化问题的非线性最小二乘目标函数如式 (2) 所示:

$${}^L\mathbf{T}_R^* = \arg \min_{{}^L\mathbf{T}_R} \sum_{\mathcal{C}} \| {}^L\mathbf{R}_R \mathbf{p}_i^{\text{radar}} + {}^L\mathbf{t}_R - \mathbf{p}_i^{\text{lidar}} \|^2 \quad (2)$$

通过高斯牛顿法不断迭代, 直到误差小于设置

阈值, 从而求得精确对齐的 4D 毫米波雷达到激光雷达的变换矩阵 ${}^L\mathbf{T}_R^*$. 对齐之后的毫米波点云和激光点云如图 2 所示, 其中绿色毫米波点云对齐激光点云检测到的车辆.




图 2 毫米波点云与激光点云时空对齐

Fig. 2 Spatiotemporal alignment of millimeter-wave point clouds and LiDAR point clouds

2.2 RC-IDSOR 滤波器

4D 毫米波雷达常常会受到噪声、杂波及多径的影响, 从而产生许多虚假目标, 为后续的数据融合带来不便. 首先对毫米波雷达进行初步滤波, 即去除强度低于阈值的点, 并且使用 PCL 对其进行半径滤波和体素滤波, 以去除多径干扰和离散点. 在本文实验中, 滤波阈值的取值取决于具体雷达回波特性的离线统计分析. 对于第 4.3 节的场景测试, 毫米波雷达强度阈值设为 50, 径向速度阈值设为 1 m/s. 依据传感器时空对齐的结果 ${}^L\mathbf{T}_R^*$ 将处理完成后的 4D 毫米波点云对齐到激光雷达坐标系, 作为参考点云 $\mathbf{p}_i^{\text{ref}}$. 将激光点云 $\mathbf{p}_i^{\text{lidar}}$ 与 $\mathbf{p}_i^{\text{ref}}$ 重合部分共同统计为先验约束 $\mathcal{P}^{\text{preserve}}$ (高置信的物体, 如行人、车辆).

RC-IDSOR 的滤波流程如下: 对于每个激光点 $\mathbf{p}_i^{\text{lidar}}$, 使用 kd-Tree 搜索其 k 个最近邻点, 记邻域集合为 $\mathcal{N}_i$, 邻域内欧氏距离如式 (3) 所示:

$$d_{ij} = \|\mathbf{p}_i^{\text{lidar}} - \mathbf{p}_j^{\text{lidar}}\|_2, \quad \mathbf{p}_i^{\text{lidar}}, \mathbf{p}_j^{\text{lidar}} \in \mathcal{N}_i \quad (3)$$

依据欧氏距离获得式 (4) 的平均邻域距离:

$$\bar{d}_i = \frac{1}{k-1} \sum_{j=1, j \neq i}^k d_{ij} \quad (4)$$

真实环境中的固体表面点具有空间连续性和局部一致性, 其邻域距离分布集中; 粉尘、雨雪等噪声点属于随机漂浮点, 其邻域距离较大且呈现明显的长尾分布. 基于 Z-score 异常检测法, 将这里的粉尘噪点视为异常点 (outliers). 对全体点进行统计建模,

得到式 (5) 所示的邻域距离的全局均值 μ_d 与标准差 σ_d , 作为空间一致性的度量基准.

$$\mu_d = \frac{1}{N} \sum_{i=1}^N \bar{d}_i, \quad \sigma_d = \sqrt{\frac{1}{N-1} \sum_{i=1}^N (\bar{d}_i - \mu_d)^2} \quad (5)$$

采取动态半径因子与空间尺度归一化策略, 依据点距离激光雷达中心的水平距离 $r_i = \sqrt{x_i^2 + y_i^2}$, 自适应地调整动态阈值. 每一个激光点的动态阈值由式 (6) 计算:

$$T_i = (\mu_d + \alpha \sigma_d) \beta r_i \quad (6)$$

其中, α 为标准差调节系数; β 为距离放大系数. 这两个系数用于平衡局部点云密度变化与雷达先验补偿对阈值调整的影响, 取值均为 0.1. 系数的选取基于以下考虑: 当 α, β 过小时, 阈值变化对环境退化的响应不足, 容易导致有效特征被误剔除; 当 α, β 过大时, 阈值对局部噪声波动过于敏感, 去噪稳定性下降^[9-11]. 距离激光雷达中心越远, 激光点越稀疏, 因此计算其平均邻域距离较近点更大. r_i 的加入确保远处的点具有更大的动态阈值, 以防离群值去除时误将远处平均邻域距离大的真实点去除. 最后引入式 (7) 所示的联合判定规则获得融合点云 $\mathcal{P}$:

$$\mathcal{P} = \{ \mathbf{p}_i^{\text{ref}}, \mathbf{p}_i^{\text{lidar}} | \bar{d}_i < T_i, r_i > R_{\text{thr}}, I_i > I_{\text{thr}}, \mathbf{p}_i^{\text{lidar}} \in \mathcal{P}^{\text{reserve}} \} \quad (7)$$

其中, 动态阈值 T_i 由离群值去除算法确定; 距离阈值 R_{thr} 由点云的密度动态确定, TOR 滤波器指出, 颗粒噪声点主要出现在激光雷达近距离探测范围^[11], 基于该特性, 本文对单帧激光点云按照与传感器的径向距离进行分层统计, 构建离散的径向点云密度序列, 并拟合其随距离变化的衰减曲线, 计算密度下降速率最大的距离区间, 并将对应的径向位置作为距离阈值 R_{thr} ; I_i 为激光点强度值, 强度阈值 I_{thr} 动态统计为激光点云强度值中位数; 毫米波点云补偿由先验约束确定. 本文设计的联合判据减少了需要计算的点云数目, 准确识别噪声的同时保留了足够的环境结构信息. 联合滤波算法流程如图 3 所示.

3 RC-LIO 技术路线

3.1 数据预处理

里程计输入为激光雷达点云、4D 毫米波雷达点云以及 IMU 的角速度与加速度. 在 ROS (robot operating system) 中接收三种传感器数据, 并且依据顺序将一段时间内的一帧激光点云与一帧毫米波点云进行融合去噪, 并且与多帧 IMU 数据封装在一起作为系统的一帧. 要求 IMU 时间戳范围囊括




图 3 RC-IDSOR 去噪算法流程图

Fig.3 Flowchart of the RC-IDSOR denoising algorithm

激光时间戳与毫米波时间戳范围, 以便系统状态的后续传播和补偿.

在 RC-LIO 系统初始化阶段, 为获得 IMU 的加速度偏置 $\mathbf{b}_a$ 和陀螺仪偏置 $\mathbf{b}_g$, 在采集数据时首先需要录制一段静止条件下连续的 IMU 数据. 由于此时载体处于无角运动与无线性加速度状态, IMU 的理想输出应满足加速度仅包含重力分量、角速度为零. 因此, IMU 的静止测量模型可表示为:

$$\begin{cases} \boldsymbol{\omega}_i = \mathbf{b}_g + \mathbf{n}_\omega \\ \mathbf{a}_i = {}^G\mathbf{R}_I^T \mathbf{g} + \mathbf{b}_a + \mathbf{n}_a \end{cases} \quad (8)$$

其中, $\boldsymbol{\omega}_i$ 和 $\mathbf{a}_i$ 分别为第 i 时刻的陀螺仪角速度测量和加速度测量; $\mathbf{g}$ 为重力加速度在全局坐标系下的表达; ${}^G\mathbf{R}_I$ 为 IMU 安装坐标系相对于全局坐标系的旋转矩阵, 当前预处理时为单位矩阵; $\mathbf{n}_\omega$ 与 $\mathbf{n}_a$ 为零均值高斯白噪声.

在静止条件下, 真实角速度为零且 ${}^G\mathbf{R}_I$ 不随时间变化. 偏置可通过对测量序列进行均值估计得到:

$$\mathbf{b}_g = \frac{1}{N} \sum_{i=1}^N \boldsymbol{\omega}_i, \quad \mathbf{b}_a = \frac{1}{N} \sum_{i=1}^N \mathbf{a}_i - {}^G\mathbf{R}_I^T \mathbf{g} \quad (9)$$

其中, N 为采样总数. 上述估计基于以下假设: 噪声项 $\mathbf{n}_\omega$ 和 $\mathbf{n}_a$ 在足够长的时间窗口内均值趋于零, 而偏置项在该时间段内保持常量. 因此, 式 (9) 能够在无外部运动干扰的条件下可靠估计 IMU 的初始偏置, 并为后续的状态估计过程提供有效初值. 进一步标定激光雷达与 IMU, 使用 LI-Init 工具包直接获得激光雷达到 IMU 坐标系的变换矩阵 ${}^I\mathbf{T}_L$. IMU 与激光雷达的传播如图 4 所示. 预处理完的数据按照时间戳被打包在一起不断传播与补偿.

3.2 基于 ESKF 的 IMU 传播

在紧耦合激光惯导系统中, IMU 用于在两帧激




图 4 传感器数据传播示意图

Fig.4 Schematic diagram of sensor data transmission

光数据之间提供连续的运动约束. 因此参考 ESKF, FAST-LIO2 等方法的 IMU 传播过程^[24, 29], 首先定义连续时间下的系统状态向量为:

$$\mathbf{x} = [{}^G\mathbf{R}_I^T, {}^G\mathbf{v}_I^T, {}^G\mathbf{t}_I^T, \mathbf{b}_a^T, \mathbf{b}_g^T, \mathbf{g}^T]^T \quad (10)$$

其中, ${}^G\mathbf{R}_I \in \text{SO}(3)$, 与第 3.1 节的含义保持一致, 同时也是系统状态的旋转分量; ${}^G\mathbf{v}_I \in \mathbf{R}^3$, ${}^G\mathbf{t}_I \in \mathbf{R}^3$ 为 IMU 在全局坐标系下的速度和位置.

记 IMU 的原始测量为角速度 ω_m 和加速度 $\mathbf{a}_m$, 对应的物理模型为:

$$\begin{cases} \omega_m = \omega_{\text{true}} + \mathbf{b}_g + \mathbf{n}_\omega \\ \mathbf{a}_m = {}^G\mathbf{R}_I^T(\mathbf{a}_{\text{true}} - \mathbf{g}) + \mathbf{b}_a + \mathbf{n}_a \end{cases} \quad (11)$$

其中, ω_{true} 和 $\mathbf{a}_{\text{true}}$ 为系统的名义角速度与名义加速度, 即真值. 根据刚体运动学, 系统前三个状态随时间的变化满足以下微分方程:

$$\begin{cases} \dot{{}^G\mathbf{R}_I} = {}^G\mathbf{R}_I(\omega_m - \mathbf{b}_g - \mathbf{n}_\omega)^\wedge \\ \dot{{}^G\mathbf{v}_I} = {}^G\mathbf{R}_I(\mathbf{a}_m - \mathbf{b}_a - \mathbf{n}_a) + \mathbf{g} \\ \dot{{}^G\mathbf{t}_I} = {}^G\mathbf{v}_I \end{cases} \quad (12)$$

其中, $(\cdot)^\wedge$ 表示向量对应的反对称矩阵. 旋转矩阵 ${}^G\mathbf{R}_I$ 是一个正交矩阵. 考虑 IMU 坐标系下列向量坐标为 $\mathbf{u}_I$ 的向量 $\mathbf{u}$, 其在全局坐标系下的列向量坐标表示为 $\mathbf{u}_G = {}^G\mathbf{R}_I\mathbf{u}_I$, 并且这个坐标的变化量仅由刚体旋转引起, 为全局坐标系下名义角速度与自身的叉乘 $\dot{\mathbf{u}}_G = \omega_{\text{true}} \times \mathbf{u}_G$. 另一方面, 由旋转矩阵求导可得 $\dot{\mathbf{u}}_G = {}^G\dot{\mathbf{R}}_I\mathbf{u}_I$. 上述二式等价, 即可得出 ${}^G\dot{\mathbf{R}}_I = {}^G\mathbf{R}_I(\omega_{\text{true}})^\wedge$. 连续时间中, 速度的导数即为 IMU 加速度真值, 位移导数即为 IMU 速度. 为将 IMU 状态进行前向传播, 本文需要将状态方程离散化. 对于时刻 t_k 到 t_{k+1} , 其积分时间为 Δt . 状态的更新通过中值积分估计. 式 (13) 中省略了坐标系变换的角标, 添加了时间信息, 得到变量名义状态的传播, 即忽略误差项的离散运动学.

$$\begin{cases} \hat{\mathbf{R}}_{k+1} = \hat{\mathbf{R}}_k \text{Exp}(\bar{\omega} \Delta t) \\ \hat{\mathbf{v}}_{k+1} = \hat{\mathbf{v}}_k + \bar{\mathbf{a}} \Delta t \\ \hat{\mathbf{t}}_{k+1} = \hat{\mathbf{t}}_k + \hat{\mathbf{v}}_k \Delta t + \frac{1}{2} \bar{\mathbf{a}} (\Delta t)^2 \\ \bar{\omega} = \frac{1}{2}(\omega_{m, k} + \omega_{m, k+1} - \hat{\mathbf{b}}_{g, k} - \hat{\mathbf{b}}_{g, k+1}) \\ \bar{\mathbf{a}} = \frac{1}{2} \hat{\mathbf{R}}_k (\mathbf{a}_{m, k} - \hat{\mathbf{b}}_{a, k}) + \\ \quad \frac{1}{2} \hat{\mathbf{R}}_{k+1} (\mathbf{a}_{m, k+1} - \hat{\mathbf{b}}_{a, k+1}) - \hat{\mathbf{g}}_k \end{cases} \quad (13)$$

其中, $\hat{\cdot}$ 代表变量为名义状态, 即 ESKF 假设下忽略噪声的理想状态; $\text{Exp}(\cdot)$ 代表旋转向量到旋转矩阵的映射. 假设偏置在一帧传播时间内不变, 记 $\hat{\mathbf{b}}_{g, k} = \hat{\mathbf{b}}_{g, k+1} = \mathbf{b}_g$, $\hat{\mathbf{b}}_{a, k} = \hat{\mathbf{b}}_{a, k+1} = \mathbf{b}_a$. 在中值积分法传播 IMU 名义状态的同时计算协方差矩阵来获得预测的不确定性. 对于式 (10) 的状态有如下省略时间下标所示的误差状态计算:

$$\begin{cases} \mathbf{R} = \hat{\mathbf{R}} \text{Exp}(\delta \theta), & \delta \mathbf{v} = \mathbf{v} - \hat{\mathbf{v}} \\ \delta \mathbf{t} = \mathbf{t} - \hat{\mathbf{t}}, & \delta \mathbf{b}_g = \mathbf{b}_g - \hat{\mathbf{b}}_g \\ \delta \mathbf{b}_a = \mathbf{b}_a - \hat{\mathbf{b}}_a, & \delta \mathbf{g} = \mathbf{g} - \hat{\mathbf{g}} \end{cases} \quad (14)$$

其中, 误差 $\delta \theta$ 是在李群 $\text{SO}(3)$ 上的右扰动. 记误差状态传播的雅可比矩阵为 $\mathbf{F}_k$, 噪声传播的雅可比矩阵为 $\mathbf{B}_k$. 误差状态转移方程推导如下.

旋转误差传播

IMU 真实位姿变化由真实的不含偏置的旋转角度决定. 式 (15) 中的真值去除了有关噪声:

$$\begin{aligned} \bar{\omega}_{\text{true}} &= \frac{1}{2}(\omega_{\text{true}, k} + \omega_{\text{true}, k+1}) = \\ &= \frac{1}{2}(\omega_{m, k} + \omega_{m, k+1}) - \mathbf{b}_g - \\ &= \frac{1}{2}(\mathbf{n}_{\omega, k} + \mathbf{n}_{\omega, k+1}) = \\ &= \bar{\omega} - \delta \mathbf{b}_g - \frac{1}{2}(\mathbf{n}_{\omega, k} + \mathbf{n}_{\omega, k+1}) \end{aligned} \quad (15)$$

其中, 记 $-\delta \mathbf{b}_g - \frac{1}{2}(\mathbf{n}_{\omega, k} + \mathbf{n}_{\omega, k+1}) = \delta \omega$. 真实旋转矩阵的变化如式 (16) 所示:

$$\begin{aligned} \mathbf{R}_{k+1} &= \mathbf{R}_k \text{Exp}(\bar{\omega}_{\text{true}} \Delta t) = \\ &= \hat{\mathbf{R}}_k \text{Exp}(\delta \theta_k) \text{Exp}((\bar{\omega} + \delta \omega) \Delta t) \end{aligned} \quad (16)$$

名义更新为式 (13) 的 $\hat{\mathbf{R}}_{k+1} = \hat{\mathbf{R}}_k \text{Exp}(\bar{\omega} \Delta t)$. 将更新过程与 t_{k+1} 时刻的误差状态 $\mathbf{R}_{k+1} = \hat{\mathbf{R}}_{k+1} \text{Exp}(\delta \theta_{k+1})$ 代入式 (16) 中, 得到如式 (17) 所示的结果.

$$\begin{aligned} \text{Exp}(\delta \theta_{k+1}) &= \hat{\mathbf{R}}_{k+1}^{-1} \mathbf{R}_{k+1} = \\ &= \text{Exp}(-\bar{\omega} \Delta t) \text{Exp}(\delta \theta_k) \text{Exp}((\bar{\omega} + \delta \omega) \Delta t) \end{aligned} \quad (17)$$

记 $\mathbf{R}_\omega = \text{Exp}(-\bar{\omega}\Delta t)$, 对式 (17) 两边取对数. 在计算过程中使用了多处近似处理: 使用右雅可比近似将末项展开, 并且近似旋转的雅可比矩阵为单位阵; 使用共轭近似忽略高阶小项, 仅保留旋转矩阵; 使用 BCH 一阶展开处理小项, 忽略二阶以上高阶项. 最终得到如式 (18) 所示的旋转误差状态传播:

$$\begin{aligned} \delta\theta_{k+1} = & \text{Log}(\text{Exp}(-\bar{\omega}\Delta t) \text{Exp}(\delta\theta_k) \text{Exp}((\bar{\omega} + \delta\omega)\Delta t)) \approx \\ & \text{Log}(\text{Exp}(-\bar{\omega}\Delta t) \text{Exp}(\delta\theta_k) \text{Exp}(\bar{\omega}\Delta t) \text{Exp}(\delta\omega\Delta t)) \approx \\ & \text{Log}(\text{Exp}(\text{Exp}(-\bar{\omega}\Delta t)\delta\theta_k) \text{Exp}(\delta\omega\Delta t)) \approx \\ & \text{Log}(\text{Exp}(\text{Exp}(-\bar{\omega}\Delta t)\delta\theta_k + \delta\omega\Delta t)) = \\ & \text{Exp}(-\bar{\omega}\Delta t)\delta\theta_k - (\delta\mathbf{b}_g + \frac{1}{2}(\mathbf{n}_{\omega, k} + \mathbf{n}_{\omega, k+1}))\Delta t = \\ & \mathbf{R}_\omega\delta\theta_k - \Delta t\delta\mathbf{b}_g - \frac{1}{2}\Delta t(\mathbf{n}_{\omega, k} + \mathbf{n}_{\omega, k+1}) \end{aligned} \quad (18)$$

其中, $\text{Log}(\cdot)$ 代表旋转矩阵到旋转向量的映射. 雅可比矩阵 $\mathbf{F}_k$ 中与旋转误差相关的雅可比块为:

$$\mathbf{F}_{\theta, \theta} = \mathbf{R}_\omega, \quad \mathbf{F}_{\theta, b_g} = -\mathbf{I}\Delta t \quad (19)$$

速度误差传播

记 $\mathbf{a}_0 = \mathbf{a}_{m, k} - \mathbf{b}_a$, $\mathbf{a}_1 = \mathbf{a}_{m, k+1} - \mathbf{b}_a$. 在传播过程中, 加速度偏置不发生改变. 在后续更新过程中再对偏置进行更新. 真实速度变化如式 (20) 所示:

$$\begin{cases} \mathbf{v}_{k+1} = \mathbf{v}_k + \bar{\mathbf{a}}_{\text{true}}\Delta t \\ \bar{\mathbf{a}}_{\text{true}} = \frac{1}{2}\mathbf{R}_k(\mathbf{a}_{m, k} - \mathbf{b}_a - \mathbf{n}_{a, k}) + \\ \frac{1}{2}\mathbf{R}_{k+1}(\mathbf{a}_{m, k+1} - \mathbf{b}_a - \mathbf{n}_{a, k+1}) - \mathbf{g} \end{cases} \quad (20)$$

将式 (20) 与式 (13) 的速度传播相减, 并且将相关变量代入. 首先, 将真实速度表达式中有关旋转的操作作小量近似处理:

$$\begin{aligned} \mathbf{R}_k(\mathbf{a}_{m, k} - \mathbf{b}_a - \mathbf{n}_{a, k}) &\approx \\ \hat{\mathbf{R}}_k(\mathbf{I} + (\delta\theta_k)^\wedge)(\mathbf{a}_0 - \delta\mathbf{b}_a - \mathbf{n}_{a, k}) &\approx \\ \hat{\mathbf{R}}_k\mathbf{a}_0 + \hat{\mathbf{R}}_k(\delta\theta_k)^\wedge\mathbf{a}_0 - \hat{\mathbf{R}}_k\delta\mathbf{b}_a - \hat{\mathbf{R}}_k\mathbf{n}_{a, k} \end{aligned} \quad (21)$$

将式 (21) 应用于求解真实加速度和名义加速度的误差, 如式 (22) 所示:

$$\begin{aligned} \bar{\mathbf{a}}_{\text{true}} - \bar{\mathbf{a}} &\approx -\frac{1}{2}\hat{\mathbf{R}}_k(\mathbf{a}_0)^\wedge\delta\theta_k - \frac{1}{2}\hat{\mathbf{R}}_{k+1}(\mathbf{a}_1)^\wedge\delta\theta_{k+1} - \\ &\frac{1}{2}(\hat{\mathbf{R}}_k + \hat{\mathbf{R}}_{k+1})\delta\mathbf{b}_a - \delta\mathbf{g} - \\ &\frac{1}{2}(\hat{\mathbf{R}}_k\mathbf{n}_{a, k} + \hat{\mathbf{R}}_{k+1}\mathbf{n}_{a, k+1}) \end{aligned} \quad (22)$$

将式 (22) 应用于速度误差的传播, 并且代入式 (18) 所示的旋转误差, 整理得到速度误差的传播公式:

$$\begin{aligned} \delta\mathbf{v}_{k+1} = & \delta\mathbf{v}_k - \frac{1}{2}\Delta t(\hat{\mathbf{R}}_k(\mathbf{a}_0)^\wedge + \hat{\mathbf{R}}_{k+1}(\mathbf{a}_1)^\wedge\mathbf{R}_\omega)\delta\theta_k - \\ & \frac{1}{2}(\hat{\mathbf{R}}_k + \hat{\mathbf{R}}_{k+1})\Delta t\delta\mathbf{b}_a + \frac{1}{2}\hat{\mathbf{R}}_{k+1}(\mathbf{a}_1)^\wedge(\Delta t)^2\delta\mathbf{b}_g + \\ & \frac{1}{4}\hat{\mathbf{R}}_{k+1}(\mathbf{a}_1)^\wedge(\Delta t)^2(\mathbf{n}_{\omega, k} + \mathbf{n}_{\omega, k+1}) - \\ & \Delta t\delta\mathbf{g} - \frac{1}{2}\Delta t(\hat{\mathbf{R}}_k\mathbf{n}_{a, k} + \hat{\mathbf{R}}_{k+1}\mathbf{n}_{a, k+1}) \end{aligned} \quad (23)$$

由式 (23) 可得 $\mathbf{F}_k$ 中与速度相关的雅可比块如下:

$$\begin{cases} \mathbf{F}_{v, v} = \mathbf{I} \\ \mathbf{F}_{v, \theta} = -\frac{1}{2}\Delta t(\hat{\mathbf{R}}_k(\mathbf{a}_0)^\wedge + \hat{\mathbf{R}}_{k+1}(\mathbf{a}_1)^\wedge\mathbf{R}_\omega) \\ \mathbf{F}_{v, b_a} = -\frac{1}{2}(\hat{\mathbf{R}}_k + \hat{\mathbf{R}}_{k+1})\Delta t \\ \mathbf{F}_{v, b_g} = \frac{1}{2}\hat{\mathbf{R}}_{k+1}(\mathbf{a}_1)^\wedge(\Delta t)^2 \\ \mathbf{F}_{v, g} = -\mathbf{I}\Delta t \end{cases} \quad (24)$$

位置与偏置误差传播

位置误差的计算过程与速度类似. 同样将真实位置与名义位置作差, 得到式 (25) 所示的位置状态误差传播过程:

$$\delta\mathbf{t}_{k+1} = \delta\mathbf{t}_k + \delta\mathbf{v}_k\Delta t + \frac{1}{2}(\bar{\mathbf{a}}_{\text{true}} - \bar{\mathbf{a}})(\Delta t)^2 \quad (25)$$

将速度误差传播的相关变量代入, 可以得到位置误差的更新公式:

$$\begin{aligned} \delta\mathbf{t}_{k+1} = & \delta\mathbf{t}_k + \delta\mathbf{v}_k\Delta t - \\ & \frac{1}{4}(\Delta t)^2(\hat{\mathbf{R}}_k(\mathbf{a}_0)^\wedge + \hat{\mathbf{R}}_{k+1}(\mathbf{a}_1)^\wedge\mathbf{R}_\omega)\delta\theta_k + \\ & \frac{1}{4}\hat{\mathbf{R}}_{k+1}(\mathbf{a}_1)^\wedge(\Delta t)^3\delta\mathbf{b}_g + \\ & \frac{1}{8}\hat{\mathbf{R}}_{k+1}(\mathbf{a}_1)^\wedge(\Delta t)^3(\mathbf{n}_{\omega, k} + \mathbf{n}_{\omega, k+1}) - \\ & \frac{1}{4}(\hat{\mathbf{R}}_k + \hat{\mathbf{R}}_{k+1})(\Delta t)^2\delta\mathbf{b}_a - \frac{1}{2}(\Delta t)^2\delta\mathbf{g} - \\ & \frac{1}{4}(\Delta t)^2(\hat{\mathbf{R}}_k\mathbf{n}_{a, k} + \hat{\mathbf{R}}_{k+1}\mathbf{n}_{a, k+1}) \end{aligned} \quad (26)$$

$\mathbf{F}_k$ 中与位置误差有关的雅可比块如下所示:

$$\begin{cases} \mathbf{F}_{t, t} = \mathbf{I}, & \mathbf{F}_{t, v} = \mathbf{I}\Delta t \\ \mathbf{F}_{t, \theta} = \frac{1}{2}\Delta t\mathbf{F}_{v, \theta}, & \mathbf{F}_{t, b_a} = \frac{1}{2}\Delta t\mathbf{F}_{v, b_a} \\ \mathbf{F}_{t, b_g} = \frac{1}{2}\Delta t\mathbf{F}_{v, b_g}, & \mathbf{F}_{t, g} = \frac{1}{2}\Delta t\mathbf{F}_{v, g} \end{cases} \quad (27)$$

在 IMU 前向传播过程中, 角速度偏置 $\mathbf{b}_g$ 以及加速度偏置 $\mathbf{b}_a$ 是上一帧的修正量, 其在一帧之中的传播仅受到游离高斯白噪声 $\mathbf{n}_{b_g}$ 和 $\mathbf{n}_{b_a}$ 的影响, 因此有 $\delta\mathbf{b}_{g, k+1} = \delta\mathbf{b}_{g, k} + \Delta t\mathbf{n}_{b_g}$, $\delta\mathbf{b}_{a, k+1} = \delta\mathbf{b}_{a, k} + \Delta t\mathbf{n}_{b_a}$. 重力向量的变化同理, 其传播具有重力误差向量加噪声 $\mathbf{n}_g$ 的形式: $\delta\mathbf{g}_{k+1} = \delta\mathbf{g}_k + \Delta t\mathbf{n}_g$. 对应的 $\mathbf{F}_k$ 雅可比矩阵块为: $\mathbf{F}_{b_g, b_g} = \mathbf{F}_{b_a, b_a} = \mathbf{F}_{g, g} = \mathbf{I}$.

整体误差状态方程

系统误差状态向量为:

$$\delta \mathbf{x} = [(\delta \boldsymbol{\theta})^T, (\delta \mathbf{v})^T, (\delta \mathbf{t})^T, (\delta \mathbf{b}_a)^T, (\delta \mathbf{b}_g)^T, (\delta \mathbf{g})^T]^T \quad (28)$$

依据 ESKF, 误差状态向量具有式 (29) 所示的离散线性化传播过程:

$$\delta \mathbf{x}_{k+1} = \mathbf{F}_k \delta \mathbf{x}_k + \mathbf{B}_k \mathbf{n}_k \quad (29)$$

状态雅可比矩阵 $\mathbf{F}_k$ 的结构由式 (19)、式 (24)、式 (27) 确定, 是一个具有式 (30) 所示的 18×18 维矩阵:

$$\mathbf{F}_k = \begin{bmatrix} \mathbf{F}_{\theta, \theta} & \mathbf{0} & \mathbf{0} & \mathbf{0} & \mathbf{F}_{\theta, b_g} & \mathbf{0} \\ \mathbf{F}_{v, \theta} & \mathbf{F}_{v, v} & \mathbf{0} & \mathbf{F}_{v, b_a} & \mathbf{F}_{v, b_g} & \mathbf{F}_{v, g} \\ \mathbf{F}_{t, \theta} & \mathbf{F}_{t, v} & \mathbf{F}_{t, t} & \mathbf{F}_{t, b_a} & \mathbf{F}_{t, b_g} & \mathbf{F}_{t, g} \\ \mathbf{0} & \mathbf{0} & \mathbf{0} & \mathbf{I} & \mathbf{0} & \mathbf{0} \\ \mathbf{0} & \mathbf{0} & \mathbf{0} & \mathbf{0} & \mathbf{I} & \mathbf{0} \\ \mathbf{0} & \mathbf{0} & \mathbf{0} & \mathbf{0} & \mathbf{0} & \mathbf{I} \end{bmatrix} \quad (30)$$

传播过程中的噪声是符合高斯分布的白噪声. 定义噪声向量为:

$$\mathbf{n}_k = [\mathbf{n}_{\omega, k}^T, \mathbf{n}_{a, k}^T, \mathbf{n}_{\omega, k+1}^T, \mathbf{n}_{a, k+1}^T, \mathbf{n}_{b_a}^T, \mathbf{n}_{b_g}^T, \mathbf{n}_g^T]^T \quad (31)$$

噪声所对应的协方差矩阵如式 (32) 所示:

$$\mathbf{Q}_k = \text{diag}\{\sigma_{\omega}^2 \mathbf{I}, \sigma_a^2 \mathbf{I}, \sigma_{\omega}^2 \mathbf{I}, \sigma_a^2 \mathbf{I}, \sigma_{b_a}^2 \mathbf{I}, \sigma_{b_g}^2 \mathbf{I}, \sigma_g^2 \mathbf{I}\} \quad (32)$$

噪声的雅可比矩阵 $\mathbf{B}_k$ 的求解过程与误差状态传播的雅可比矩阵相同. 由式 (18)、式 (23)、式 (26) 等误差状态传播过程, 最终得到噪声传播矩阵 $\mathbf{B}_k$ 的结构以及误差状态 $\delta \hat{\mathbf{x}}$ 的协方差传播形式如式 (33) 所示:

$$\left\{ \begin{array}{l} \mathbf{B}_k = \begin{bmatrix} \mathbf{B}_{\theta, n_{\omega}} & \mathbf{0} & \mathbf{B}_{\theta, n_{\omega+1}} & \mathbf{0} & \mathbf{0} & \mathbf{0} & \mathbf{0} \\ \mathbf{B}_{v, n_{\omega}} & \mathbf{B}_{v, n_a} & \mathbf{B}_{v, n_{\omega+1}} & \mathbf{B}_{v, n_{a+1}} & \mathbf{0} & \mathbf{0} & \mathbf{0} \\ \mathbf{B}_{t, n_{\omega}} & \mathbf{B}_{t, n_a} & \mathbf{B}_{t, n_{\omega+1}} & \mathbf{B}_{t, n_{a+1}} & \mathbf{0} & \mathbf{0} & \mathbf{0} \\ \mathbf{0} & \mathbf{0} & \mathbf{0} & \mathbf{0} & \mathbf{I} & \mathbf{0} & \mathbf{0} \\ \mathbf{0} & \mathbf{0} & \mathbf{0} & \mathbf{0} & \mathbf{0} & \mathbf{I} & \mathbf{0} \\ \mathbf{0} & \mathbf{0} & \mathbf{0} & \mathbf{0} & \mathbf{0} & \mathbf{0} & \mathbf{I} \end{bmatrix} \\ \mathbf{B}_{\theta, n_{\omega}} = \mathbf{B}_{\theta, n_{\omega+1}} = -\frac{1}{2} \mathbf{I} \Delta t \\ \mathbf{B}_{v, n_{\omega}} = \mathbf{B}_{v, n_{\omega+1}} = \frac{1}{4} \hat{\mathbf{R}}_{k+1} (\mathbf{a}_1)^{\wedge} (\Delta t)^2 \\ \mathbf{B}_{v, n_a} = -\frac{1}{2} \hat{\mathbf{R}}_k \Delta t, \quad \mathbf{B}_{v, n_{a+1}} = -\frac{1}{2} \hat{\mathbf{R}}_{k+1} \Delta t \\ \mathbf{B}_{t, n_{\omega}} = \mathbf{B}_{t, n_{\omega+1}} = \frac{1}{8} \hat{\mathbf{R}}_{k+1} (\mathbf{a}_1)^{\wedge} (\Delta t)^3 \\ \mathbf{B}_{t, n_a} = -\frac{1}{4} \hat{\mathbf{R}}_k (\Delta t)^2, \quad \mathbf{B}_{t, n_{a+1}} = -\frac{1}{4} \hat{\mathbf{R}}_{k+1} (\Delta t)^2 \\ \mathbf{P}_{k+1} = \mathbf{F}_k \mathbf{P}_k \mathbf{F}_k^T + \mathbf{B}_k \mathbf{Q}_k \mathbf{B}_k^T \end{array} \right. \quad (33)$$

3.3 自适应 ESKF 修正

在挑战场景下, 一阶 ESKF 近似的 IMU 传播对于极端的 IMU 角速度与加速度较为敏感. 为减小 IMU 前向中一阶 BCH 线性化的误差, 本文在旋转误差传播中保留了 BCH 的二阶对易子项. 将二阶展开代入旋转误差传播并作小量近似, 修正旋转误差状态的传播过程如式 (34) 所示:

$$\delta \boldsymbol{\theta}_{k+1} = \mathbf{R}_{\omega} \delta \boldsymbol{\theta}_k + \delta \boldsymbol{\omega} \Delta t + \frac{1}{2} (\mathbf{R}_{\omega} \delta \boldsymbol{\theta}_k) \times (\delta \boldsymbol{\omega} \Delta t) \quad (34)$$

其中, 相关符号与式 (18) 保持一致. 该展开在小量近似下严格成立, 旋转误差状态的雅可比矩阵出现如式 (35) 所示的修正:

$$\begin{cases} \mathbf{F}_{\theta, \theta} \leftarrow \mathbf{R}_{\omega} - \frac{1}{2} (\delta \boldsymbol{\omega})^{\wedge} \mathbf{R}_{\omega} \\ \mathbf{F}_{\theta, b_g} \leftarrow -\mathbf{I} \Delta t - \frac{1}{2} \Delta t (\mathbf{R}_{\omega} \delta \boldsymbol{\theta}_k)^{\wedge} \end{cases} \quad (35)$$

在误差状态卡尔曼滤波框架下, 系统误差动力学通常通过在名义轨迹处进行一阶线性化得到. 该过程隐含假设误差状态在名义点附近保持足够小, 从而其均值可近似为零, 且高阶状态项对误差传播的影响可忽略. 因此, 在状态转移雅可比矩阵 $\mathbf{F}_k$ 的构建过程中, 所有显式依赖误差状态的高阶项均可在名义点处被舍弃, 使得误差状态传播保持一阶线性形式. 这一处理方式也是 FAST-LIO2 等高效滤波里程计方法所采用的标准假设.

然而, 需要指出的是, 该一阶近似仅对加性形式进入系统的状态误差项在统计意义下是封闭的. 对于式 (34) 所述旋转误差状态而言, 其误差传播不仅包含加性噪声项, 还通过旋转群上的 BCH 对易项与当前姿态误差产生显式耦合, 使噪声映射呈现出状态相关性. 具体而言, $\delta \boldsymbol{\omega}$ 虽然在均值意义下为零, 但其通过二阶对易项引入的乘性噪声效应会导致误差协方差的额外增长, 该增长无法通过标准的一阶噪声传播项 $\mathbf{B}_k \mathbf{Q}_k \mathbf{B}_k^T$ 完整刻画. 现有方法 FAST-LIO2 在工程实现中忽略了该状态相关噪声项, 在协方差传播中仅保留一阶噪声贡献. 该假设在短时间尺度内是可接受的, 也解释了其在大多数场景下的良好性能. 然而, 从随机系统理论角度看, 这种处理并不能保证误差传播在二阶统计意义下的一致性.

因此, 本文在保持误差状态一阶线性化形式不变的前提下, 引入对 BCH 二阶对易项所诱导的状态相关噪声的统计补偿. $\delta \boldsymbol{\omega}$ 与噪声 $\mathbf{n}_k, \mathbf{n}_{k+1}$ 呈线性关系. 为方便起见, 直接将 $\delta \boldsymbol{\omega}$ 视作耦合的噪声状态, 其对应的一阶噪声雅可比矩阵为 $\mathbf{B}_k = \mathbf{I} \Delta t$. 引入二阶项后, 依据式 (34), 对应的二阶修正噪声项变为 $\mathbf{B}_k = \mathbf{I} \Delta t + \frac{1}{2} (\mathbf{R}_{\omega} \delta \boldsymbol{\theta}_k)^{\wedge} \Delta t$. 记 $\mathbf{H} = \frac{1}{2} (\mathbf{R}_{\omega} \delta \boldsymbol{\theta}_k)^{\wedge} \Delta t$,

且陀螺仪噪声协方差为 $\mathbf{Q}_\omega$. 依据以上假设, 直接将旋转误差的噪声传播项的期望写为式 (36) 的形式:

$$\begin{aligned} E((\Delta t \mathbf{I} + \mathbf{H})\mathbf{Q}_\omega(\Delta t \mathbf{I} + \mathbf{H})^T) = \\ (\Delta t)^2 \mathbf{Q}_\omega + \Delta t(\mathbf{Q}_\omega \mathbf{H}^T + \mathbf{H}\mathbf{Q}_\omega) + \mathbf{H}\mathbf{Q}_\omega \mathbf{H}^T \end{aligned} \quad (36)$$

式 (36) 中后两项即为由二阶展开引入的附加协方差增量, 可记为式 (37):

$$\Delta E = \Delta t(\mathbf{Q}_\omega \mathbf{H}^T + \mathbf{H}\mathbf{Q}_\omega) + \mathbf{H}\mathbf{Q}_\omega \mathbf{H}^T \quad (37)$$

从算法实现角度来看, 本文希望维持噪声雅可比一阶形式 $\mathbf{B}_k = \mathbf{I}\Delta t$ 不变, 但是此时考虑二阶 BCH 的真实映射为 $\mathbf{B}_{\text{eff}} = \Delta t \mathbf{I} + \mathbf{H}$, 所以需寻找一个等效的 $\mathbf{Q}_\omega^*$ 满足式 (38):

$$\mathbf{B}_k \mathbf{Q}_\omega^* \mathbf{B}_k^T \approx \mathbf{B}_{\text{eff}} \mathbf{Q}_\omega \mathbf{B}_{\text{eff}}^T \quad (38)$$

将式 (36)、式 (37) 与式 (38) 结合, 可得如式 (39) 所示的等效 $\mathbf{Q}_\omega^*$ 的具体形式:

$$\begin{cases} \mathbf{Q}_\omega^* = \frac{1}{(\Delta t)^2} (\Delta t \mathbf{I} + \mathbf{H})\mathbf{Q}_\omega(\Delta t \mathbf{I} + \mathbf{H})^T = \\ \mathbf{Q}_\omega + \Delta \mathbf{Q}_\omega \\ \Delta \mathbf{Q}_\omega = \frac{1}{(\Delta t)^2} (\Delta t(\mathbf{Q}_\omega \mathbf{H}^T + \mathbf{H}\mathbf{Q}_\omega) + \mathbf{H}\mathbf{Q}_\omega \mathbf{H}^T) \end{cases} \quad (39)$$

因为 $\mathbf{H}$ 的一阶矩为 0, 所以 $\Delta \mathbf{Q}_\omega$ 引入的唯一有效统计项为 $E[\mathbf{H}\mathbf{Q}_\omega \mathbf{H}^T]$. 在 ESKF 假设中, $\delta \theta_k$ 服从零均值高斯分布, 其协方差为 $\mathbf{P}_\theta$, 直接将 $E[\mathbf{H}\mathbf{Q}_\omega \mathbf{H}^T]$ 按元素展开求解, 记 $(\delta \theta_k)^\wedge$ 为 $\mathbf{R}_\theta$, 得到如式 (40) 所示的形式:

$$\begin{cases} E[\mathbf{H}\mathbf{Q}_\omega \mathbf{H}^T] = \frac{1}{4} (\Delta t)^2 \mathbf{R}_\omega E[\mathbf{R}_\theta \mathbf{Q}_\omega \mathbf{R}_\theta^T] \mathbf{R}_\omega^T \\ E[\mathbf{R}_\theta \mathbf{Q}_\omega \mathbf{R}_\theta^T] = \\ \begin{bmatrix} q_2 P_{33} + q_3 P_{22} & -q_3 P_{12} & -q_2 P_{13} \\ -q_3 P_{12} & q_1 P_{33} + q_3 P_{11} & -q_1 P_{23} \\ -q_2 P_{13} & -q_1 P_{23} & q_1 P_{22} + q_2 P_{11} \end{bmatrix} \end{cases} \quad (40)$$

其中, $P_{11} \sim P_{33}$ 为 $\mathbf{P}_\theta$ 的对应元素; $q_1 \sim q_3$ 为 $\mathbf{Q}_\omega$ 的对角线元素. 该二阶补偿项显式地刻画了姿态不确定性与角速度噪声之间的耦合关系, 使协方差传播能够根据当前姿态不确定性结构进行自适应调整. 对于实际在线系统, 在每个 IMU 传播步中引入完整的矩阵二阶补偿不仅会增加额外的矩阵运算开销, 还会提高协方差一致性与数值稳定性的维护难度. 考虑到该二阶效应在工程实践中主要体现为角速度噪声幅值的整体放大, 本文同时采用标量放大策略对矩阵二阶补偿进行近似建模. 对误差状态的

噪声矩阵进行式 (41) 所示的自适应放大处理, 以应对过大的角速度误差.

$$\mathbf{Q}_\omega^* = \alpha_\omega^2 \mathbf{Q}_\omega, \alpha_\omega = 1 + \lambda_\omega \|\Delta \omega\| \Delta t \quad (41)$$

其中, 经验调节因子 λ_ω 为常数; $\Delta \omega$ 为角速度的短时扰动项. 具体实现为对测量角速度 ω_m 作平滑处理得到 ω_m^* , 再使用差值 $(\omega_{m,k+1}^* - \omega_{m,k}^*)/2$ 作为 $\Delta \omega$ 的代理. 当系统处于平稳运动状态时, $\Delta \omega$ 近似为零, 放大系数退化为 $\alpha_\omega \approx 1$, 从而不影响标准 ESKF 的协方差传播过程. 对状态变量中的速度和位移分量所对应的噪声作相同的处理. 由此便完成自适应 ESKF 的协方差修正, 使得算法可以有效应对采样抖动、高动态场景.

3.4 体素地图构建

为提高环境表示的效率与精度, 本研究采用基于体素的概率地图表示方法, 对融合点云进行增量式建图与更新. 该体素地图通过对局部空间进行离散化, 将每个体素区域内的点云统计特征作为局部环境的概率模型进行维护, 从而实现计算效率与精度的平衡.

体素地图采用基于哈希索引的存储与访问方式. 由空间离散坐标直接计算体素的哈希值, 在均摊意义下其查询时间复杂度为 $O(1)$, 计算开销较点级 ikd-Tree 更低且易于并行化实现. 体素分辨率 s 在实验中统一设为 0.5 m, 以平衡匹配精度与计算开销. 此外, 这种地图结构支持基于体素的 GICP 配准方式, 拓展性更强. 在全局坐标系下, 每个体素具有以下信息: $\mathcal{M} = \{N, \mathbf{p}, \mathbf{C}, \boldsymbol{\mu}, \boldsymbol{\Sigma}\}$. 其中, N 为体素中点的数量; $\mathbf{p}$ 为所有点坐标的和; $\mathbf{C}$ 为所有点的外积和; $\boldsymbol{\mu}$ 为所有点坐标的均值; $\boldsymbol{\Sigma}$ 为体素的协方差矩阵. 对于滤波之后的融合点云 $\mathcal{P}$, 首先按照标定结果 ${}^I\mathbf{T}_L$ 将点云对齐到 IMU 坐标系, 再按照 IMU 位姿传播 $\hat{\mathbf{x}}_k$ 变换到全局坐标系下, 记点为 $\mathbf{p}_i = [p_x, p_y, p_z]^T$, 其哈希索引 $hash_index$ 的计算如式 (42) 所示:

$$\begin{cases} \mathbf{g} = \left[\left\lfloor \frac{p_x}{s} \right\rfloor, \left\lfloor \frac{p_y}{s} \right\rfloor, \left\lfloor \frac{p_z}{s} \right\rfloor \right]^T \\ hash_index = (g_x n_x) \oplus (g_y n_y) \oplus (g_z n_z) \bmod \mathcal{M}_{max} \end{cases} \quad (42)$$

其中, s 为分辨率; $\oplus$ 表示按位异或操作; n_x, n_y, n_z 为大素数; $\mathcal{M}_{max}$ 为体素地图的最大容量; $\mathbf{g} = [g_x, g_y, g_z]^T$ 为体素坐标. 取模后的 $hash_index$ 可以与空间的体素块一一对应, 相同索引的点位于同一体素块内. 依据索引将点加入体素地图 $\mathcal{V}$ 中. 对应体素块 $\mathcal{M}[i]$ 的参数的更新过程如式 (43) 所示:

$$\begin{cases} \mathcal{M}[i].N = \mathcal{M}[i].N + N_i, & \mathcal{M}[i].\mathbf{p} = \mathcal{M}[i].\mathbf{p} + \mathbf{p}_i \\ \mathcal{M}[i].\mathbf{C} = \mathcal{M}[i].\mathbf{C} + \mathbf{C}_i, & \mathcal{M}[i].\boldsymbol{\mu} = \frac{\mathcal{M}[i].\mathbf{p}}{\mathcal{M}[i].N} \\ \mathcal{M}[i].\boldsymbol{\Sigma} = \frac{1}{\mathcal{M}[i].N + 1} (\mathcal{M}[i].\mathbf{C} - \mathcal{M}[i].\mathbf{p}(\mathcal{M}[i].\boldsymbol{\mu})^T) \end{cases} \quad (43)$$

3.5 高置信度点云优化 GICP 匹配

为从点云信息中获取相邻帧之间的相对运动约束, 本文采用改进的 GICP 算法. 与经典 ICP 算法相比, GICP 在点到点与点到面的统一框架下, 通过对局部几何结构进行高斯分布建模, 从而在高曲率或非平面区域显著提升匹配精度与收敛稳定性. 本文在此基础上进一步设计结构感知与强度加权机制, 构建高置信度点云 GICP 约束, 以增强退化环境下点云配准的鲁棒性与几何约束强度.

融合点云并不是孤立的离散点. 在 GICP 的前提假设中, 相邻的激光束通常只相差极小的角度, 所以它们打到的点在三维空间中的位置接近. 这意味着在局部区域内, 点云分布具有强连续性和平滑性. 在此假设下, 每个点均可近似为某个局部高斯分布的样本. 对于变换到全局坐标系下的融合点 $\mathbf{p}_i$ 满足 $\mathbf{p}_i \sim \mathcal{N}(\boldsymbol{\mu}_i, \boldsymbol{\Sigma}_i)$, 其中 $\boldsymbol{\mu}_i$ 是点所在局部区域的均值 (近似为点本身的位置), $\boldsymbol{\Sigma}_i$ 是该点在当前融合点云帧下由 KNN 方法计算获得的局部协方差矩阵, 反映点云在局部邻域的分布形态. 假设其落在体素块 $\mathcal{M}[j]$ 中, 对应的均值 $\mathcal{M}[j].\boldsymbol{\mu}$ 即为改进 GICP 的匹配目标, 匹配残差定义为式 (44) 所示的两者之差:

$$\mathbf{r}_i^{\text{GICP}} := \mathcal{M}[j].\boldsymbol{\mu} - \mathbf{p}_i = \mathcal{M}[j].\boldsymbol{\mu} - (\hat{\mathbf{R}}_k(^I\mathbf{R}_L\mathbf{p}_i + ^I\mathbf{t}_L) + \hat{\mathbf{t}}_k) \quad (44)$$

其中, $^I\mathbf{R}_L$ 和 $^I\mathbf{t}_L$ 为标定坐标变换矩阵的旋转向量和平移向量. 标准 GICP 中局部协方差 $\boldsymbol{\Sigma}_i$ 仅反映点云的几何分布特性, 在退化场景 (如边缘或稀疏区域) 中易退化为奇异矩阵. 对体素的协方差矩阵进行特征值分解, 如式 (45) 所示:

$$\boldsymbol{\Sigma}_i = \mathbf{U} \begin{bmatrix} \lambda_1 & 0 & 0 \\ 0 & \lambda_2 & 0 \\ 0 & 0 & \lambda_3 \end{bmatrix} \mathbf{U}^T \quad (45)$$

其中, $\mathbf{U}$ 为正定矩阵经过 SVD 分解得到的奇异矩阵; $\lambda_1 \geq \lambda_2 \geq \lambda_3 \geq 0$ 为 $\boldsymbol{\Sigma}_i$ 的特征值. 本文引入结构感知指标 κ_i 描述局部特征退化程度, 如式 (46) 所示:

$$\kappa_i = \frac{\lambda_2 + \lambda_3}{\lambda_1 + \epsilon} \quad (46)$$

其中, ϵ 小量用于保持数值稳定性. 若 κ_i 较小, 表明局部点云分布呈现显著的线性退化特征, 真实几何约束维度不足以支撑稳定配准. 针对上述情况, 本文不直接对协方差进行各向同性平滑, 而是基于特征分解对协方差谱结构进行显式重整. 具体而言, 在保持特征向量不变的前提下, 重整特征值为 1, 1, 10^{-3} . 修正协方差矩阵如式 (47) 所示, 以减少线性退化.

$$\boldsymbol{\Sigma}_i \leftarrow \mathbf{U} \begin{bmatrix} 1 & 0 & 0 \\ 0 & 1 & 0 \\ 0 & 0 & 10^{-3} \end{bmatrix} \mathbf{U}^T \quad (47)$$

结构退化指标 κ_i 仅用于判定是否触发上述谱重整操作. 当 $\kappa_i \geq \kappa_{th}$ 时, 表明局部几何结构良好, 协方差保持原始估计结果 (体、面特征); 当 $\kappa_i < \kappa_{th}$ 时, 启用平面谱约束以增强几何约束的稳定性. 本文通过离线统计和相关里程计的具体情形选择 $\kappa_{th} = 0.4$ 作为平面退化阈值^[24-25, 27, 32].

由上, 将体素均值视作一个随机向量, 服从高斯分布 $\mathcal{M}[j].\boldsymbol{\mu} \sim \mathcal{N}(\boldsymbol{\mu}_j, \mathcal{M}[j].\boldsymbol{\Sigma})$. 源点在激光雷达坐标系下的重整协方差 $\boldsymbol{\Sigma}_i$ 变换到 IMU 坐标系下记为 $\boldsymbol{\Sigma}_{imu}$, 再变换到全局坐标系记为 $\hat{\mathbf{R}}_k\boldsymbol{\Sigma}_{imu}(\hat{\mathbf{R}}_k)^T$. 在 GICP 假设中, 体素代表与变换后的源点是互相独立的随机变量. 两者差值的协方差为两者协方差之和. 残差 $\mathbf{r}_i^{\text{GICP}}$ 的协方差为:

$$\begin{aligned} \boldsymbol{\Sigma}_{r_i} &= \text{Cov}(\mathcal{M}[j].\boldsymbol{\mu} - \mathbf{p}_i) = \\ &= \text{Cov}(\mathcal{M}[j].\boldsymbol{\mu}) + \text{Cov}(\mathbf{p}_i) = \\ &= \mathcal{M}[j].\boldsymbol{\Sigma} + \hat{\mathbf{R}}_k\boldsymbol{\Sigma}_{imu}(\hat{\mathbf{R}}_k)^T \end{aligned} \quad (48)$$

对基于 RC-IDSOR 获得的点云进行进一步的强度一致性置信度加权, 用于补偿激光点云退化条件下噪声的强度失真. 落实到具体激光点有如式 (49) 所示的强度权重函数:

$$c_i = \exp(-\gamma_I |I_i - \bar{I}|) \quad (49)$$

其中, c_i 为加权系数; I_i 为点的强度; $\bar{I}$ 为该帧点云的平均强度; γ_I 为调节系数. 修正协方差为 $\boldsymbol{\Sigma}_i \leftarrow \boldsymbol{\Sigma}_i / c_i$. 强度一致的点在优化中获得更高权重; 数目少、低强度的噪声在传播时被进一步弱化.

3.6 点云/IMU 紧耦合状态更新

为统一符号表达, 本文假定已经完成了对于融合里程计名义状态 $\hat{\mathbf{x}}_{k-1}$ 的修正. 同时, 通过 IMU 的先验传播获得了 t_k 时刻初步的状态估计 $\hat{\mathbf{x}}_k$. 状态更新的目的是修正 $\hat{\mathbf{x}}_k$, 以便于将其作为下一个状态估计的前置条件. IMU 残差具有式 (50) 所示形式:

$$\mathbf{r}_k^{\text{IMU}} = \begin{bmatrix} \text{Log}(\hat{\mathbf{R}}_k^T \mathbf{R}_k) \\ \mathbf{v}_k - \hat{\mathbf{v}}_k \\ \mathbf{t}_k - \hat{\mathbf{t}}_k \\ \mathbf{b}_{a,k} - \hat{\mathbf{b}}_{a,k} \\ \mathbf{b}_{g,k} - \hat{\mathbf{b}}_{g,k} \\ \mathbf{g}_k - \hat{\mathbf{g}}_k \end{bmatrix} \quad (50)$$

其中, 本文对旋转项作简单近似: $\text{Log}(\hat{\mathbf{R}}_k^T \mathbf{R}_k) = \text{Log}(\hat{\mathbf{R}}_k^T \hat{\mathbf{R}}_k \text{Exp}(\delta\boldsymbol{\theta}_k)) \approx \delta\boldsymbol{\theta}_k$, 则有 $\mathbf{r}_k^{\text{IMU}} \approx \delta\mathbf{x}_k$. 因此, $\text{Cov}(\mathbf{r}_k^{\text{IMU}}) \approx \text{Cov}(\delta\mathbf{x}_k) = \mathbf{P}_k$. 然而, 旋转残差 $\mathbf{r}_{\text{ori}} = \text{Log}(\hat{\mathbf{R}}_k^T \mathbf{R}_k)$ 是定义在李群 $\text{SO}(3)$ 上的非线性映射. 在此空间中, 微分关系应通过李代数的右雅可比矩阵 $\mathbf{J}_r$ 描述. 为保持旋转残差线性化的精度, 仍然需要通过式 (51) 来计算旋转残差关于 $\delta\boldsymbol{\theta}_k$ 的求导以及 IMU 残差的雅可比矩阵 $\mathbf{J}^{\text{IMU}}$:

$$\begin{cases} \frac{\partial \mathbf{r}_{\text{ori}}}{\partial \delta\boldsymbol{\theta}_k} \approx \mathbf{J}_r^{-1} \left(\text{Log}(\hat{\mathbf{R}}_k^T \mathbf{R}_k) \right) \\ \mathbf{J}^{\text{IMU}} = \frac{\partial \mathbf{r}_k^{\text{IMU}}}{\partial \delta\mathbf{x}_k} = \begin{bmatrix} \frac{\partial \mathbf{r}_{\text{ori}}}{\partial \delta\boldsymbol{\theta}_k} & \mathbf{0} \\ \mathbf{0} & \mathbf{I}_{15 \times 15} \end{bmatrix} \end{cases} \quad (51)$$

残差 $\mathbf{r}_i^{\text{GICP}}$ 是线性化的, 记 $\mathbf{s}_i = {}^I \mathbf{R}_L \mathbf{p}_i + {}^I \mathbf{t}_L$. 全局坐标系下的融合点由 IMU 先验估计 $\hat{\mathbf{x}}_k$ 变换, 其对于误差状态的雅可比矩阵 $\mathbf{J}_i^{\text{GICP}}$ 有式 (52) 所示的结构:

$$\mathbf{J}_i^{\text{GICP}} = \frac{\partial \mathbf{r}_i^{\text{GICP}}}{\partial \delta\mathbf{x}_k} = \begin{bmatrix} -\hat{\mathbf{R}}_k(\mathbf{s}_i)^\wedge & -\mathbf{I}_{3 \times 3} & \mathbf{0}_{3 \times 12} \end{bmatrix} \quad (52)$$

因此, 将具有协方差和匹配成功的所有点 $\mathcal{I}_{\text{GICP}}$ 与 IMU 残差堆叠, 构造如式 (53) 所示的加权最小二乘代价:

$$\begin{aligned} \mathbb{E}[\delta\mathbf{x}_k] &= \frac{1}{2} \sum_{i \in \mathcal{I}_{\text{GICP}}} (\mathbf{r}_i^{\text{GICP}})^T \boldsymbol{\Sigma}_{r_i}^{-1} \mathbf{r}_i^{\text{GICP}} + \\ &\quad \frac{1}{2} (\mathbf{r}_k^{\text{IMU}})^T \mathbf{P}_k^{-1} \mathbf{r}_k^{\text{IMU}} \end{aligned} \quad (53)$$

使用高斯牛顿法来解决这个线性最小二乘问题. 点云贡献 $\mathbf{H}_{\text{GICP}}$ 主要影响状态变量的旋转和平移部分, IMU 贡献 $\mathbf{H}_{\text{IMU}}$ 一方面作用于位姿, 另一方面更新加速度零偏和角速度零偏以及重力数值的修正. 点云和 IMU 对于 Hessian 矩阵的贡献如下式所示

$$\begin{aligned} \mathbf{H}_{\text{GICP}} &= \sum_{i \in \mathcal{I}_{\text{GICP}}} (\mathbf{J}_i^{\text{GICP}})^T \boldsymbol{\Sigma}_{r_i}^{-1} \mathbf{J}_i^{\text{GICP}} \\ \mathbf{b}_{\text{GICP}} &= - \sum_i (\mathbf{J}_i^{\text{GICP}})^T \boldsymbol{\Sigma}_{r_i}^{-1} \mathbf{r}_i^{\text{GICP}} \end{aligned}$$

$$\mathbf{H}_{\text{IMU}} = (\mathbf{J}^{\text{IMU}})^T \mathbf{P}_k^{-1} \mathbf{J}^{\text{IMU}}$$

$$\mathbf{b}_{\text{IMU}} = -(\mathbf{J}^{\text{IMU}})^T \mathbf{P}_k^{-1} \mathbf{r}_k^{\text{IMU}}$$

$$\mathbf{H} = \mathbf{H}_{\text{GICP}} + \mathbf{H}_{\text{IMU}}, \quad \mathbf{b} = \mathbf{b}_{\text{GICP}} + \mathbf{b}_{\text{IMU}}$$

其中, $\mathbf{b}_{\text{GICP}}$ 和 $\mathbf{b}_{\text{IMU}}$ 为对应的观测向量. 求解正规方程 $\delta\hat{\mathbf{x}}_k = \mathbf{H}^{-1} \mathbf{b}$, 更新状态变量 $\hat{\mathbf{x}}_k$. 迭代求解得到范数足够小的 $\delta\hat{\mathbf{x}}_k$ 以及对应的 Hessian 矩阵 $\mathbf{H}$. 最终得到更新过后的 $\mathbf{x}_k^{\text{update}} = \hat{\mathbf{x}}_k + \delta\hat{\mathbf{x}}_k$ 作为下一次更新的起点, 协方差矩阵 $\mathbf{P}_k^{\text{update}} = \mathbf{L} \mathbf{H}^{-1} \mathbf{L}^T$ 作为下一次协方差的起点. 其中 $\mathbf{L}$ 的结构如式 (54) 所示. 这是在 ESKF 中的重置操作, 目的是将协方差映射到更新的名义起点下.

$$\mathbf{L} = \begin{bmatrix} \mathbf{I}_{3 \times 3} - \frac{1}{2} (\delta\hat{\boldsymbol{\theta}}_k)^\wedge & \mathbf{0} \\ \mathbf{0} & \mathbf{I} \end{bmatrix} \quad (54)$$

4 实验结果

4.1 RC-IDSOR 去噪测试

冬季恶劣驾驶数据集 (winter adverse driving dataset, WADS) 是一个专为应对严寒冬季条件下自动驾驶关键技术挑战而构建的大规模多模态数据集. 该数据集在密歇根州上半岛雪带地区采集完成, 其开创性在于首次提供了在强降雪和广泛积雪等退化环境中获取的带有密集点级标注的连续激光雷达扫描数据. WADS 中具体的一帧点云标注如图 5 所示.




图 5 WADS 中具有点级标注的一帧激光点云

Fig. 5 A frame of LiDAR point cloud with point-level annotations in the WADS

在 WADS 上测试 RC-IDSOR 的滤波效果. 依据 Kurup 等^[9] 对于 WADS 标注的解释和 Bos 等^[35] 描述的点云分割方法以及毫米波雷达的目标检测特性, 本文将具有车辆、行人标签的点云作为毫米波识别先验. 图 6 中展示了不同基于统计离群值去除方法在 WADS 上的去噪效果. 其中, 红色点为标注的噪声点, 蓝色点为非噪声点. 滤波结果显示, 传统




图6 不同滤波方法去噪效果示意图

Fig.6 Schematic diagram of denoising effects using different filtering methods


的基于 PCL 的 SOR 方法效果较差. DSOR 去除噪声点云效果较好, 但是与此同时滤除了部分环境点云. LIDSOR 和 RC-IDSOR 在准确滤除噪声的同时, 保留了大部分的环境点云, 经过多组数据的测试, 二者在多组数据上的效果相当, 但是后者对于噪声点云的识别准确度较高.

按照式 (55) 计算相关参数指标. 其中, accuracy 为检测准确率; error 为检测错误率; precision 为滤波器识别噪声的精确度; recall 为去除噪声点的比例; F-score 为算法综合得分.

$$\left\{ \begin{array}{l} \text{accuracy} = \frac{TP + TN}{TP + TN + FP + FN} \\ \text{error} = 1 - \text{accuracy} \\ \text{precision} = \frac{TP}{TP + FP} \\ \text{recall} = \frac{TP}{TP + FN} \\ \text{F-score} = \frac{2 \times \text{precision} \times \text{recall}}{\text{precision} + \text{recall}} \end{array} \right. \quad (55)$$

其中, TP (true positive) 表示滤波器识别结果为噪声, 且实际标签也为噪声的点的数量; TN (true negative) 表示滤波器识别结果为非噪声, 且实际标签也为非噪声的点的数量; FP (false positive) 表示滤波器识别结果为噪声, 但是实际标签为非噪声的点的数量; FN (false negative) 表示滤波器识别结果为非噪声, 但是实际标签为噪声的点的数量. 召回率越高代表去除噪声越多, 准确率越高代表保留环境信息越多. 因此, 使用 F-score 综合评价滤波去噪效果.

为分析 RC-IDSOR 中动态阈值参数对性能的影响, 本文在 WADS 的 Sequence 13 序列上对参数 α (std_mul) 与 β (range_mul) 进行二维敏感性分析. 两参数均在 [0.04, 0.20] 区间内取值, 并以 F-score 作为评价指标, 结果如图 7 所示. 实验结果表明, F-score 在一片连续的参数区域内保持接近最优值. 记

图7 RC-IDSOR 参数 α 与 β 对 F-score 影响的敏感性分析 (Sequence 13)Fig.7 F-score sensitivity analysis of RC-IDSOR with respect to parameters α and β on Sequence 13

最高分为 $F_{\max}$, 当得分 $F \geq 0.99F_{\max}$ 时, 对应的稳定区间为 $\alpha \in [0.086, 0.154]$, $\beta \in [0.063, 0.109]$. 该区间覆盖本文所采用的默认参数设置 ($\alpha = 0.1$, $\beta = 0.1$), 说明 RC-IDSOR 对稳定区间内参数选取不敏感, 具有良好的鲁棒性与可复现性. 此外, 参数 α 在较大范围内变化时对性能影响较小, 而参数 β 过大将导致有效点被过度抑制, 从而使 F-score 明显下降. 这一现象与 RC-IDSOR 中距离衰减机制的物理含义一致.

本文将 RC-IDSOR 与几种基于统计离群的滤波方法进行了对比实验. 在 WADS 多个场景下计算每一组点云的指标平均值, 得到表 1 所示的定量评估结果. RC-IDSOR 在整体性能上显著优于 PCL 自带的 SOR 滤波方法, 并在各项指标上均表现优异. 具体而言, 与 SOR 相比, RC-IDSOR 在准确率、精确度和 F-score 等方面均有大幅提升; 尽管在部分场景下召回率略低于 DSOR 等方法, 但其更高的精确率有效保障了环境点云的完整性, 从而实现更优的 F-score 综合性能. 此外, RC-IDSOR 在多项指标上与 LIDSOR 表现相当, 甚至更优, 如在场景 13 和场景 18 中, RC-IDSOR 的 F-score 分别达到 0.916 4 和 0.926 1, 优于 LIDSOR 的 0.874 2 和 0.877 7. RC-IDSOR 的平均 F-score 超过 0.85, 较 LIDSOR 提升约 6.8%. 更重要的是, RC-IDSOR 在保持高性能的同时具备更快的处理速度. 实验平台配置为 i5-10400 处理器与 RTX4060Ti 显卡, RC-IDSOR 可实现毫秒级别的运算速率, 有效支撑了点云的稳定融合与实时更新.

4.2 RC-LIO 里程计测试

SubT-MRS 是一个多模态、多机器人的数据集, 主要从具有多种退化条件的地下环境中收集, 包括烟雾和灰尘等感知遮蔽物退化场景. 此外, 该

表 1 WADS 序列定量评估结果
Table 1 Quantitative evaluation results of WADS sequences

场景	方法	accuracy	error	precision	recall	F-score
11	SOR	0.7633	0.2367	0.1302	0.2881	0.1791
	DSOR	0.9316	0.0684	0.6038	0.8208	0.6902
	LIDSOR	0.9623	0.0377	0.7911	0.8056	0.7936
	RC-IDSOR	0.9711	0.0289	0.8767	0.8022	0.8319
12	SOR	0.7277	0.2723	0.1312	0.2400	0.1668
	DSOR	0.9366	0.0634	0.7693	0.7393	0.7395
	LIDSOR	0.9539	0.0461	0.9039	0.7298	0.7952
	RC-IDSOR	0.9566	0.0434	0.9346	0.7267	0.8061
13	SOR	0.7986	0.2014	0.1257	0.4375	0.1939
	DSOR	0.9628	0.0372	0.6103	0.9822	0.7488
	LIDSOR	0.9842	0.0158	0.7923	0.9776	0.8742
	RC-IDSOR	0.9901	0.0099	0.8646	0.9756	0.9164
18	SOR	0.7983	0.2017	0.1571	0.5075	0.2386
	DSOR	0.9458	0.0542	0.5528	0.9888	0.7041
	LIDSOR	0.9829	0.0171	0.7951	0.9819	0.8777
	RC-IDSOR	0.9903	0.0097	0.8794	0.9787	0.9261

数据集封装了来自不同范围的时间同步传感器的信息, 包括激光雷达、视觉相机和不同载具运动 (如空中、腿部和轮式) 得到的 IMU 数据, 以支持传感器融合的研究. 这对于在复杂环境中实现准确和鲁棒的机器人感知至关重要.

本文选择 SubT-MRS 数据集来验证优化的耦合方法带来的性能提升. RC-IDSOR 具有一定的鲁棒性和退化能力: 对于缺失毫米波雷达点云的数据, 滤波算法会自适应地退化为纯激光处理模式, 其效果与 LIDSOR 算法相当; 对于缺失强度信息的数据, 滤波算法则退化为 DSOR 算法. 这种设计确保了算法在不同传感器配置下的可用性, 体现了系统的工程实用性. 由于多数最先进 (state of the art, SOTA) 方法的里程计没有融合毫米波数据, 这里让 RC-LIO 退化为激光模式, 再对比 RC-LIO 与其他参赛里程计的定位精度. 未使用滤波的 RC-LIO (wo/filter) 对数据集场景的直接建图和启用 RC-IDSOR 的 RC-LIO (w/filter) 建图的对比如图 8 所示.

在 Factory 这种具有显著点云噪声的场景中, 直接基于噪声点云数据的定位会引起超过 1 m 的绝对轨迹误差 (absolute trajectory error, ATE). 使用去噪步骤处理激光点云, 地图实现了准确闭合, 并且里程计的 ATE 小于 0.54 m, 对比其他里程计测试结果取得了最优. 噪声的存在导致环境地图中产生大量错误点云, 这些错误的地图点使得里程计 GICP 约束产生了错误匹配, 进而影响位姿状态估




图 8 SubT-MRS 数据集噪声点云去除效果示意图
Fig.8 Schematic diagram of noise point clouds removal effect in the SubT-MRS dataset

计. 在未进行去噪操作的情况下, 里程计的定位发生了较大漂移, 偏移误差不断累计, 导致运动轨迹无法闭合, 并且点云地图出现大量错误点与噪声点.

RC-LIO 与其他里程计方法的 ATE 对比如表 2 所示. FAST-LIO^[24-25]、Point-LIO^[36]、LIO-EKF^[37]、DLO^[38] 源于 SubT-MRS 原文^[30, 39]. 本文采用均方根误差 (root mean square error, RMSE) 作为 ATE 的评价指标, 用于量化估计轨迹与真实轨迹之间的偏差. RMSE 定义为预测值与真实值之差的平方的平均值的平方根, 能够综合反映整体定位精度, 并且对异常值较为敏感. 由表 2 可见, RC-LIO 在大多数 SubT-MRS 激光-惯性场景中均取得了更高的定位精度. 综合各场景的结果, RC-LIO 最小 ATE

表 2 不同里程计在 SubT-MRS 数据集上的 ATE (m)
Table 2 ATE of different odometries in the SubT-MRS dataset (m)

场景	FAST-LIO2, HBA	FAST-LIO, Pose Graph	Point-LIO, Quatro	LIO-EKF	DLO, Scan-Context++	RC-LIO
Urban	0.307	0.260	0.331	1.060	1.205	0.409
Tunnel	0.095	0.096	0.092	0.220	0.695	0.067
Cave	0.629	0.617	0.787	0.750	—	0.491
Nuclear-1	0.122	0.120	0.123	0.470	1.175	0.040
Nuclear-2	0.235	0.222	0.270	0.620	1.720	0.183
LaurelCaverns	0.260	0.402	0.279	9.140	2.080	0.269
Factory	0.889	0.998	10.628	4.920	0.889	0.540
Ocean	0.757	0.770	22.425	0.280	0.778	0.387
Sewerage	0.978	1.586	7.147	24.460	1.130	0.588

为 0.04 m, 其平均 0.33 m 的 ATE 较于 FAST-LIO2 的平均 ATE 减少约 29.8%, 表明该里程计在多种复杂环境下具有鲁棒性与泛化能力。

绝对轨迹误差主要反映里程计的全局一致性。在退化场景中, 局部连续估计的稳定性同样重要。本文对比分析了 RC-LIO 与 FAST-LIO2 在同一序列上的相对位姿误差 (relative pose error, RPE)。考虑到测试序列总长度约为 200 m, 为保证统计稳定性并刻画不同空间尺度下的漂移特性, 本文选取以下评估窗口长度: 5 m、10 m 和 20 m。RPE 关注的是在给定的时间窗口内估计位姿与真实位姿之间的差异, 能够反映里程计在短时间尺度内的漂移情况, 从而揭示其局部估计的稳定性。

图 9 展示了不同评估窗口长度下两种算法 RPE 的 RMSE 柱状图。其中, 横轴表示评估窗口长度, 纵轴表示 RPE 的 RMSE。定量结果表明, 在不同评估窗口下, RC-LIO 的 RPE 均低于 FAST-LIO2, 其平均 RMSE 相对下降约 7.9%。在 20 m 局




图 9 不同评估窗口长度下 RC-LIO 与 FAST-LIO2 的局部漂移对比 (RPE RMSE)

Fig.9 Local drift comparison between RC-LIO and FAST-LIO2 measured by RPE RMSE under different evaluation window lengths

部窗口下, RC-LIO 的 RPE 降低 10.4%, 显示出其在较大局部尺度下更强的漂移抑制能力。

Snail-Radar 是由武汉大学 SNAIL 团队推出的专为 4D 毫米波雷达 SLAM 研究而设计的大规模、多场景数据集。在传感器配置方面, Snail-Radar 配备了 4D 毫米波雷达、激光雷达、相机、IMU 及 GNSS/INS 系统。所有传感器经过时间同步与外参校准, 以确保数据和参考轨迹质量。该数据集在多种天气与环境条件下采集, 涵盖了从小雨到强降雨等多种典型退化感知场景。为综合评价 RC-IDSOR 给里程计带来的性能提升, 本文选择 Snail-Radar 中小雨、中雨、强降雨场景来对比不同滤波算法与关闭滤波算法的 ATE。算法处理后的相关点云如图 10 所示。

其中, 绿色点云表示 RC-IDSOR 滤波后的激光点云, 红色点云表示原始激光点云, 黑色点云表示 4D 毫米波雷达点云。可以看出, RC-IDSOR 能够有效滤除降雨过程中由雨滴散射引起的离群噪声, 同时较好地保留环境结构特征。对比滤波点云与原始激光点云作为里程计输入的定位结果如表 3 所示, 毫米波方法 4DRadarSLAM、EKF-RIO、4D-




图 10 激光点云、滤波点云以及毫米波点云示意图

Fig.10 Schematic diagram of laser point cloud, filtered point cloud, and millimeter-wave point cloud

表 3 RC-LIO 不同模式在 Snail-Radar 数据集集中的 ATE (m)

Table 3 ATE of different RC-LIO modes in the Snail-Radar dataset (m)

激光/毫米波里程计	小雨	中雨	强降雨
RC-LIO (w/RC-IDSOR)	0.175 6	0.372 6	1.244 1
RC-LIO (w/LIDSOR)	0.177 8	0.564 8	1.855 0
RC-LIO (wo/filter)	0.206 4	0.443 5	2.466 4
4DRadarSLAM	1.600 0	27.500 0	37.800 0
EKF-RIO	6.000 0	58.300 0	143.900 0
4D-iRIOM	0.700 0	12.600 0	31.700 0

iRIOM 的 RMSE 数值源于 Snail-Radar 数据集原文^[31], 不同算法的 ATE 为在相同评测设置下对多段测试序列的 RMSE 结果进行统计得到的平均值. 其中, RC-LIO (w/RC-IDSOR) 为基于 RC-IDSOR 的里程计; RC-LIO (w/LIDSOR) 为使用 LIDSOR 滤波的里程计; RC-LIO (wo/filter) 为未启用滤波算法的里程计.

结果表明, 引入 RC-IDSOR 滤波后, RC-LIO 在不同降雨强度下的定位精度均得到提升. 与不启用滤波环节的 RC-LIO (wo/filter) 相比, RC-LIO (w/RC-IDSOR) 在小雨和中雨场景中的 ATE 分别降低约 14.9% 和 16.0%; 在强降雨场景中, ATE 降幅约为 49.6%. 在相同参数的多组测试中, RC-LIO (wo/filter) 在强降雨场景中出现了不同程度的漂移, ATE 呈现出长尾分布特征. 考虑到强降雨退化环境下轨迹误差分布的非对称性, 本文采用多次测试中 ATE 的中位数作为强降雨场景的最终评价指标. 上述现象表明, 降雨引入的离群点具有显著的随机性, 使得前端匹配过程在退化条件下可能收敛至不同的局部最优解, 而 RC-IDSOR 的引入能够有效抑制降雨噪声对点云质量的影响, 从而提升里程计在退化环境中的鲁棒性. 进一步地, 将 RC-LIO (w/RC-IDSOR) 与基于 LIDSOR 滤波的 RC-LIO (w/LIDSOR) 进行对比, 在小雨场景下两者的 ATE 差异较小, 而在中雨和强降雨场景中, RC-IDSOR 分别将 ATE 降低约 34.0% 和 32.9%, 验证了引入 4D 毫米波先验在噪声干扰环境中的有效性.

4.3 真实场景测试

随着智能制造的深入推进, 自动化仓储与柔性物流系统已成为现代工业发展的关键环节. 在这一背景下, 自主移动机器人作为执行物料搬运、分拣与上/下架等任务的核心装备, 其感知系统的可靠性直接决定了整个系统的智能化水平与运行效率. 然而, 在真实的工业场景中, 如酿酒、食品加工、建

材生产等行业, 生产与搬运过程中常会产生大量粉尘、碎屑等悬浮颗粒物, 形成了退化的感知环境. 本文用于数据采集的作业车辆如图 11 所示.




图 11 作业车辆及传感器安装示意图
Fig. 11 Schematic diagram of the work vehicle and sensor installation

图 11 中, 激光雷达安装在车顶前方, 毫米波雷达安装在激光雷达下方的护栏位置, IMU 和 ARM 工控机安装在车体防爆控制箱内, 防爆相机安装在车辆探照灯上方. 依据第 2 节与第 3 节的工具包标定激光雷达、毫米波雷达以及 IMU 数据, 获得精确的传感器空间位置外参. 作业车辆所采用的传感器和工控机具体选型以及部分参数如表 4 所示.

表 4 作业车辆传感器配置参数
Table 4 Sensor configuration parameters of the work vehicle

传感器	型号	参数
激光雷达	禾赛 PandarQT	76.8 万点/秒, 104.2° 垂直视场角
毫米波雷达	纳雷 SR75	4D 成像, 120° 水平视场角
IMU	轮趣 N100	200 Hz, 0.003 (°)/s 陀螺仪噪声密度
工控机	米文 AD10	NVIDIA Jetson AGX Orin (64 GB)

作业场景中的激光雷达感知主要存在以下挑战: 离散粉尘对激光的反射强度通常较低, 在激光雷达近距离范围内表现为弱回波信号; 同一束激光会穿透粉尘, 返回多个探测点; 空间中粉尘分布较为离散、连续性差, 点云位置会随粉尘运动而快速变化. 为应对作业场景中粉尘噪声的干扰, 本文将 RC-LIO 应用于该作业车辆的定位任务中, 以实现退化环境的鲁棒感知. 图 12 展示了作业场景仓库的具体环境、粉尘示意图、RC-IDSOR 对于噪声环境的滤波效果以及 RC-LIO 算法初步建立的环境去噪点云地图.

在定量评估粉尘去噪效果方面, 由于对真实仓储铲运场景中的粉尘浓度难以进行精确标定, 且具有显著的随机性与非均匀性, 所以不适合采用人为




图 12 工业仓储作业环境及 RC-IDSOR 滤波效果示意图

Fig.12 Industrial warehousing operation environment and RC-IDSOR filtering effect diagram

分级或传感器标定方式进行定量比较. 基于工程应用角度, 本文转而统计分析滤波后可参与后端 GICP 匹配的有效点云比例, 以反映滤波算法在真实退化环境中对点云质量的改善效果. 实验结果表明, 在一次完整作业过程中, 平均每帧约有 2 000 个体素点, RC-IDSOR 滤波后平均约 77% 的点被用于里程计更新, 验证了 RC-IDSOR 在强粉尘条件下对有效结构信息的保留能力.

通过在线测试评估对比启用滤波算法的 RC-LIO (w/filter)、LIO-SAM 以及 FAST-LIO2 的实时性与资源占用, 以验证算法的可部署性. 其中, LIO-SAM 是多线程的, IMU 处理和点云匹配是并行的, 在计算 LIO-SAM 资源开销时对所有线程开销求和. 关闭建图线程, 记录算法的 IMU 加去畸变、点云匹配与系统完成一帧点云处理的单线程总耗时平均值以及 CPU、内存占用峰值. 本文选择测试集长度为 300 s 的序列, IMU 数据频率为 200 Hz, 点云数据频率为 10 Hz, 符合实际作业工况. 选取的测试平台分别为: 基于 x86 架构的主机, 配置

为 i5-10400 处理器, 8 GB 内存, RTX4060Ti 显卡; 基于 ARM 架构的 Jetson AGX Orin 嵌入式计算平台, 配置为 12 核 Cortex-A78AE 处理器, 32 GB 内存, 1792 核 NVIDIA Ampere 显卡.

具体测试结果如表 5 所示. 总体来看, 算法在 x86 平台的大部分性能指标优于 ARM 平台. 其主要原因在于 ARM 架构处理器的单核性能相对较弱, 同时 x86 架构在第三方库的调度与并行执行效率方面具有优势, 使得 ARM 平台上部分计算密集型任务难以充分并行化, 从而影响整体处理效率. 在 x86 平台上, RC-LIO (w/filter) 实现了约 213 Hz 的处理频率, 最大 CPU 占用率约为 2.1%, 最大内存占用约为 36.4 MB; 而在 ARM 平台上, 其处理频率约为 38 Hz, 最大 CPU 占用率约为 6.3%, 最大内存占用约为 78.4 MB. RC-LIO (w/filter) 在 x86 平台以及 ARM 平台上的 IMU 加去畸变耗时以及单线程总耗时均表现为次优, 其与 FAST-LIO2 相比差距较小. 尽管本文对算法结构进行了优化与重写, 但是受限于点云去畸变中额外引入的 RC-ID-

表 5 不同平台上 RC-LIO 实时性测试结果
Table 5 Real-time performance test results of RC-LIO on different platforms

平台	算法	CPU 占用率 (%)	内存占用 (MB)	IMU 加去畸变耗时 (ms)	点云匹配耗时 (ms)	单线程总耗时 (ms)
x86	RC-LIO (w/filter)	2.1	36.4	3.7	0.9	4.7
	FAST-LIO2	3.7	130.7	1.3	3.0	4.4
	LIO-SAM	12.0	87.2	6.5	11.7	16.4
ARM	RC-LIO (w/filter)	6.3	78.4	21.6	4.1	26.4
	FAST-LIO2	3.7	167.5	3.5	19.9	24.6
	LIO-SAM	10.9	224.6	9.9	24.5	34.4

SOR 算法的结构特性, 仍不可避免地会带来额外的点云处理时间开销. 然而, RC-LIO (w/filter) 在 ARM 平台上仍保持了最低的内存占用, 并能够实现超过 30 Hz 的实时处理能力, 满足大多数移动机器人应用的实时性需求, 具备良好的部署适应性.

本文通过比较机器人多次经过同一目标点的端到端相对误差来评估滤波算法如何改善机器人感知效果. 在该仓储环境中, 作业车辆执行倾倒操作时需要回到倾倒点这一固定位置, 由于铲斗尺寸和倾倒口尺寸接近, 车辆每次到达倾倒点时位姿均相同. 因此, 短时工作测试中, 选择倾倒点作为里程计起点, 统计 RC-LIO 开启滤波、关闭滤波及 FAST-LIO2 三种情况下车辆经过倾倒点的位姿. 计算其与起点的偏差, 评估定位的精确度. 进一步, 确保在完整作业过程中里程计偏差在容许范围内, 以保证定位精度要求.

首先, 选取作业车辆 20 min 的工作片段, 作业仓库的点云地图以及具体的倾倒点如图 12 所示. 在 20 min 时间区间内, 车辆总共完成了 10 次作业. 统计每次作业回到固定位置时位姿与初始固定点的误差, 评估算法部署在实际应用场景下的性能. 在这里, 统计每次回到倾倒点的绝对位置误差, 并且将角度误差换算为等效位置误差, 计算二者的二范数以获得总误差. 实际作业过程显示, 算法在车载 AD10 设备上以 10 Hz 的频率发布里程计和点云信息. 建图结果显示, RC-LIO (wo/filter) 和 FAST-LIO2 的地图有不同程度的点云漂移. 误差统计如表 6 所示, 其中 RC-LIO (w/filter) 取得了 5.6 cm 级别的最大漂移, 优于 RC-LIO (wo/filter) 和 FAST-LIO2 的表现.

其次, 为评估滤波算法在长时间作业过程中的定位稳定性, 本文选取连续 60 min 的作业数据进

行测试. 由于作业场景中缺乏可用的高精度真实轨迹, 本文未对估计轨迹与真值进行对齐, 而仅将各方法的轨迹起点统一至原点. 在此条件下, z 轴方向的漂移并不表示相对于真实轨迹的绝对定位误差, 而是反映了激光雷达惯性里程计系统在长时间运行过程中端到端估计误差的累积效应.

60 min 工作时间内不同算法的 z 轴漂移变化曲线如图 13 所示. 设置倾倒点为起点, 在往复作业过程中, 作业车辆行进到最远处漂移最大, 回到起点处漂移最小. 对齐不同算法的时间以及初始倾倒起点, 可以看出, RC-LIO (w/filter) 在整个作业过程中表现出较低的漂移增长速率, z 轴最大漂移约为 0.8 m; 相比之下, RC-LIO (wo/filter) 和 FAST-LIO2 的漂移增长更为显著, 最终分别达到约 1.3 m 和 0.9 m. 对应到返回倾倒点时, RC-LIO (w/filter) 的 z 轴漂移最小. 综上所述, 在真实工业仓储作业环境中, RC-LIO 结合 RC-IDSOR 滤波方法有效提升了作业车辆在粉尘退化环境下的定位精度.




图 13 不同算法在 60 min 作业过程中的 z 轴漂移对比曲线 (轨迹起点对齐)

Fig. 13 Comparison of z -axis drift curves of different algorithms during a 60-minute operation (with trajectories aligned at the origin)

表 6 RC-LIO 不同模式定位偏差对比 (m)
Table 6 Comparison of positioning deviations in different RC-LIO modes (m)

次数	RC-LIO (w/filter)	RC-LIO (wo/filter)	FAST-LIO2
1	0	0	0
2	0.024	0.026	0.051
3	0.022	0.030	0.076
4	0.052	0.055	0.088
5	0.056	0.066	0.072
6	0.045	0.053	0.117
7	0.056	0.056	0.138
8	0.037	0.038	0.127
9	0.044	0.053	0.102
10	0.025	0.024	0.136

5 结束语

本文针对激光雷达在雨、雪、粉尘等退化环境下点云噪声干扰严重、感知能力下降的问题,提出一种 4D 毫米波雷达补偿的激光点云去噪方法 RC-IDSOR,并构建了相应的紧耦合激光雷达惯性里程计系统 RC-LIO. 主要贡献如下:

1) 提出 RC-IDSOR 融合去噪方法,通过毫米波雷达点云对激光点云中的可靠目标进行空间标记与补偿,结合动态半径滤波与强度筛选,在有效滤除激光噪声的同时保持良好的环境结构完整性。

2) 构建 RC-LIO 紧耦合里程计框架,将融合点云与 IMU 数据深度融合,采用自适应 ESKF 与优化的 GICP 耦合优化策略,在 SubT-MRS 退化场景中实现了优于现有主流算法的定位精度,平均绝对轨迹误差最低达到 0.04 m;在 Snail-Radar 数据集强降雨场景中,多传感器融合降低了约 49.6% 的绝对轨迹误差,有效抑制了定位漂移。

3) 在真实工业场景中验证了系统的可行性与实用性。在粉尘密集的仓储作业环境中,RC-LIO 被部署于 Jetson AGX Orin 计算平台建立去噪地图。其对计算资源占用适中,点云处理、里程计更新速率均大于 10 Hz。在短时工作中,RC-LIO 的重复定位误差小于 5.6 cm,优于未使用去噪模块的基准系统;在长时工作中,RC-LIO 端到端的 z 轴漂移最小。RC-LIO 有效支撑了机器人在退化感知条件下的实时、持续稳定工作。

实验结果表明,本文所提出的 RC-IDSOR 方法在噪声识别准确性与环境信息保留方面取得了良好平衡,RC-LIO 系统在多种退化环境中均表现出优异的鲁棒性与实时性。未来工作中,本文将进一步研究多传感器时序对齐的优化策略,并探索自适应滤波机制,以提升系统在更复杂动态环境中的泛化能力。

参考文献


- Cadena C, Carlone L, Carrillo H, Latif Y, Scaramuzza D, Neira J, et al. Past, present, and future of simultaneous localization and mapping: Toward the robust-perception age. *IEEE Transactions on Robotics*, 2016, **32**(6): 1309–1332
- Zhang J, Singh S. LOAM: LiDAR odometry and mapping in real-time. In: Proceedings of the Robotics: Science and Systems. Berkeley, USA: University of California, 2014.
- Goodin C, Carruth D, Doude M, Hudson C. Predicting the influence of rain on LiDAR in ADAS. *Electronics*, 2019, **8**(1): Article No. 89
- Dreissig M, Scheuble D, Piewak F, Boedecker J. Survey on LiDAR perception in adverse weather conditions. In: Proceedings of the IEEE Intelligent Vehicles Symposium (IV). Anchorage, USA: IEEE, 2023. 1–8
- Park J I, Jo S, Seo H T, Park J. LiDAR denoising methods in adverse environments: A review. *IEEE Sensors Journal*, 2025, **25**(5): 7916–7932
- Jiang X Y, Xie Y, Na C N, Yu W Y, Meng Y. Algorithm for point cloud dust filtering of LiDAR for autonomous vehicles in mining area. *Sustainability*, 2024, **16**(7): Article No. 2827
- Rusu R B, Cousins S. 3D is here: Point cloud library (PCL). In: Proceedings of the IEEE International Conference on Robotics and Automation (ICRA). Shanghai, China: IEEE, 2011. 1–4
- Charron N, Phillips S, Waslander S L. Denoising of LiDAR point clouds corrupted by snowfall. In: Proceedings of the 15th Conference on Computer and Robot Vision (CRV). Toronto, Canada: IEEE, 2018. 254–261
- Kurup A, Bos J. DSOR: A scalable statistical filter for removing falling snow from LiDAR point clouds in severe winter weather. arXiv preprint arXiv: 2109.07078, 2021.
- Huang H, Yan X, Yang J, Cao Y, Zhang X. LIDSOR: A filter for removing rain and snow noise points from LiDAR point clouds in rainy and snowy weather. In: Proceedings of the ISPRS Geospatial Week. Cairo, Egypt: ISPRS, 2023. 733–740
- Yan X Y, Yang J X, Zhu X Y, Liang Y, Huang H. Denoising framework based on multiframe continuous point clouds for autonomous driving LiDAR in snowy weather. *IEEE Sensors Journal*, 2024, **24**(7): 10515–10527
- Ibrahim M R, Haworth J, Cheng T. WeatherNet: Recognising weather and visual conditions from street-level images using deep residual learning. *ISPRS International Journal of GeoInformation*, 2019, **8**(12): Article No. 549
- Seppänen A, Ojala R, Tammi K. 4DenoiseNet: Adverse weather denoising from adjacent point clouds. *IEEE Robotics and Automation Letters*, 2023, **8**(1): 456–463
- Seppänen A, Ojala R, Tammi K. Self-supervised multi-echo point cloud denoising in snowfall. *Pattern Recognition Letters*, 2024, **185**: 52–58
- Patole S M, Torlak M, Wang D, Ali M. Automotive radars: A review of signal processing techniques. *IEEE Signal Processing Magazine*, 2017, **34**(2): 22–35
- Major B, Fontijne D, Ansari A, Sukhvasi R T, Gowaikar R, Hamilton M, et al. Vehicle detection with automotive radar using deep learning on range-azimuth-Doppler tensors. In: Proceedings of the IEEE/CVF International Conference on Computer Vision Workshops (ICCVW). Seoul, South Korea: IEEE, 2019. 924–932
- Zhang X Y, Wang L, Chen J, Fang C, Yang G Q, Wang Y C, et al. Dual radar: A multi-modal dataset with dual 4D radar for autonomous driving. *Scientific Data*, 2025, **12**(1): Article No. 439
- Xiang C, Feng C, Xie X P, Shi B T, Lu H, Lv Y S, et al. Multi-sensor fusion and cooperative perception for autonomous driving: A review. *IEEE Intelligent Transportation Systems Magazine*, 2023, **15**(5): 36–58
- Fan L L, Wang J H, Chang Y M, Li Y K, Wang Y T, Cao D P. 4D mmWave radar for autonomous driving perception: A comprehensive survey. *IEEE Transactions on Intelligent Vehicles*, 2024, **9**(4): 4606–4620
- Dang Xiang-Wei, Qin Fei, Bu Xiang-Xi, Liang Xing-Dong. A robust perception algorithm based on a radar and LiDAR for intelligent driving. *Journal of Radars*, 2021, **10**(4): 622–631 (党相卫, 秦斐, 卜祥玺, 梁兴东. 一种面向智能驾驶的毫米波雷达与激光雷达融合的鲁棒感知算法. 雷达学报, 2021, **10**(4): 622–631)
- Chen H Y, Zhang S, Tan K, Xu F. Fusion of LiDAR and MMW radar point clouds for environment sensing. In: Proceedings of the International Applied Computational Electromagnetics Society Symposium. Hangzhou, China: IEEE, 2023. 1–3
- Besl P J, McKay N D. A method for registration of 3-D shapes. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 1992, **14**(2): 239–256
- Shan T X, Englot B, Meyers D, Wang W, Ratti C, Rus D. LIO-SAM: Tightly-coupled LiDAR inertial odometry via smoothing and mapping. In: Proceedings of the IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS). Las Vegas, USA: IEEE, 2020. 5135–5142

- 24 Xu W, Zhang F. FAST-LIO: A fast, robust LiDAR-inertial odometry package by tightly-coupled iterated kalman filter. *IEEE Robotics and Automation Letters*, 2021, 6(2): 3317–3324
- 25 Xu W, Cai Y X, He D J, Lin J R, Zhang F. FAST-LIO2: Fast direct LiDAR-inertial odometry. *IEEE Transactions on Robotics*, 2022, 38(4): 2053–2073
- 26 Cai Y X, Xu W, Zhang F. ikd-Tree: An incremental K-D tree for robotic applications. arXiv preprint arXiv: 2102.10808, 2021.
- 27 Chen Z J, Xu Y, Yuan S H, Xie L H. iG-LIO: An incremental GICP-based tightly-coupled LiDAR-inertial odometry. *IEEE Robotics and Automation Letters*, 2024, 9(2): 1883–1890
- 28 Wu W T, Chen C, Yang B S, Zou X H, Liang F X, Xu Y H, et al. DALI-SLAM: Degeneracy-aware LiDAR-inertial SLAM with novel distortion correction and accurate multi-constraint pose graph optimization. *ISPRS Journal of Photogrammetry and Remote Sensing*, 2025, 221: 92–108
- 29 Solà J. Quaternion kinematics for the error-state Kalman filter. arXiv preprint arXiv: 1711.02508, 2017.
- 30 Zhao S B, Gao Y J, Wu T H, Singh D, Jiang R S, Sun H X, et al. SubT-MRS dataset: Pushing SLAM towards all-weather environments. In: Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Seattle, USA: IEEE, 2024. 22647–22657
- 31 Huai J Z, Wang B L, Zhuang Y, Chen Y W, Li Q P, Han Y L. SNAIL radar: A large-scale diverse benchmark for evaluating 4D-radar-based SLAM. *The International Journal of Robotics Research*, 2025, 44(12): 1941–1958
- 32 Segal A, Hähnel D, Thrun S. Generalized-ICP. In: Proceedings of the Robotics: Science and Systems V. Seattle, USA: The MIT Press, 2009. Article No. 435
- 33 Yan G H, Liu Z C, Wang C J, Shi C L, Wei P J, Cai X Y, et al. OpenCalib: A multi-sensor calibration toolbox for autonomous driving. *Software Impacts*, 2022, 14: Article No. 100393
- 34 Zhu F C, Ren Y F, Zhang F. Robust real-time LiDAR-inertial initialization. In: Proceedings of the IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS). Kyoto, Japan: IEEE, 2022. 3948–3955
- 35 Bos J P, Chopp D, Kurup A, Spike N. Autonomy at the end of the earth: An inclement weather autonomous driving data set. In: Proceedings of the Autonomous Systems: Sensors, Processing, and Security for Vehicles and Infrastructure. Anaheim, USA: SPIE, 2020. Article No. 1141507
- 36 He D J, Xu W, Chen N, Kong F Z, Yuan C J, Zhang F. Point-LIO: Robust high-bandwidth light detection and ranging inertial odometry. *Advanced Intelligent Systems*, 2023, 5(7): Article No. 2200459
- 37 Vizzo I, Guadagnino T, Mersch B, Wiesmann L, Behley J, Stachniss C. KISS-ICP: In defense of point-to-point ICP-simple, accurate, and robust registration if done the right way. *IEEE Robotics and Automation Letters*, 2023, 8(2): 1029–1036
- 38 Chen K, Lopez B T, Agha-mohammadi A A, Mehta A. Direct LiDAR odometry: Fast localization with dense point clouds. *IEEE Robotics and Automation Letters*, 2022, 7(2): 2000–2007
- 39 Helmberger M, Morin K, Berner B, Kumar N, Cioffi G, Scaramuzza D. The hilti SLAM challenge dataset. *IEEE Robotics and Automation Letters*, 2022, 7(3): 7518–7525



李健翔 北京理工大学自动化学院硕士研究生. 主要研究方向为多传感器融合的 SLAM, 点云去噪.
E-mail: 3120240869@bit.edu.cn
(**LI Jian-Xiang** Master student at the School of Automation, Beijing Institute of Technology. His re-

search interests include multi-sensor fused SLAM and point cloud denoising.)



翟弟华 北京理工大学自动化学院副教授. 主要研究方向为智能机器人, 网络机器人, 机器人视觉, 医学人工智能, 切换控制和最优控制. 本文通信作者. E-mail: zhaidih@bit.edu.cn
(**ZHAI Di-Hua** Associate professor at the School of Automation, Beijing Institute of Technology. His research interests include intelligent robot, networked robots, robotic vision, artificial intelligence in medicine, switched control, and optimal control. Corresponding author of this paper.)



丁子恺 北京理工大学自动化学院博士研究生. 主要研究方向为图优化的 SLAM, 机器人感知.
E-mail: 3220245206@bit.edu.cn
(**DING Zi-Kai** Ph.D. candidate at the School of Automation, Beijing Institute of Technology. His research interests include graph-optimized SLAM and robot perception.)



蔡鹏程 北京理工大学自动化学院硕士研究生. 主要研究方向为强化学习, 机器人感知.
E-mail: 3220241249@bit.edu.cn
(**CAI Peng-Cheng** Master student at the School of Automation, Beijing Institute of Technology. His research interests include reinforcement learning and robot perception.)



夏元清 北京理工大学自动化学院教授. 主要研究方向为云控制系统, 网络化控制系统, 鲁棒控制与信号处理, 自抗扰控制, 无人系统控制和飞行控制.
E-mail: xia_yuanqing@bit.edu.cn
(**XIA Yuan-Qing** Professor at the School of Automation, Beijing Institute of Technology. His research interests include cloud control systems, networked control systems, robust control and signal processing, active disturbance rejection control, unmanned systems control, and flight control.)