

DOI: 10.19650/j.cnki.cjsi.J2514589

面向城市动态环境的 LiDAR/IMU/UWB 融合 SLAM 定位技术研究*

徐启敏¹, 姚钰欢¹, 赵鑫¹, 胡悦²

(1. 东南大学仪器科学与工程学院 南京 210046; 2. 国防科技大学第六十三研究所 南京 210046)

摘要:针对城市环境中动态干扰导致的激光雷达同步定位与地图构建(LiDAR SLAM)定位精度下降问题,提出了一种基于LiDAR/IMU/UWB紧耦合的多源融合SLAM方法,旨在提升系统在动态干扰下的鲁棒性与定位精度。在里程计环节,构建了深度融合惯性测量单元(IMU)预积分和多基站超宽带(UWB)距离观测的因子图框架,其中IMU提供高频运动先验,补偿点云畸变,UWB通过无累积误差的绝对测距引入稳定外部约束,可有效抑制激光雷达(LiDAR)在动态环境下的累积误差,显著提升了在动态干扰场景下的位姿估计鲁棒性。此外,在回环检测与全局优化环节,设计了一种结合UWB信息的扩展描述子,将点云几何特征与UWB绝对测距及信号强度信息进行编码融合,形成区分度更强的场景表征。基于该描述子,采用“粗检索-精验证”两级回环检测策略:先利用UWB信息快速筛选候选回环帧,再经点云描述子几何验证,有效提高了动态与同质化环境下的回环检测准确性。检测到回环后,将UWB历史信息与点云约束共同纳入全局因子图进行协同优化,进一步提升轨迹一致性与地图闭合精度。在真实城市动态场景数据集上的实验表明,所提方法相比FAST-LIO2、MR-ULINS等方法,能显著降低绝对轨迹误差(ATE)。同时,UWB辅助的回环检测机制在查准率-查全率曲线上表现更优,有效减少了动态鬼影与误匹配,验证了该方法在城市动态环境中的有效性和优越性。

关键词:紧耦合里程计;动态干扰;扩展描述子;多源传感器融合

中图分类号: TH761 TH89 **文献标识码:** A **国家标准学科分类代码:** 580.20

Research on LiDAR/IMU/UWB fusion SLAM positioning technology for urban dynamic environments

Xu Qimin¹, Yao Yuhuan¹, Zhao Xin¹, Hu Yue²

(1. School of Instrument Science and Engineering, Southeast University, Nanjing 210046, China;
2. 63rd Research Institute, National University of Defense Technology, Nanjing 210046, China)

Abstract: This paper proposes a multi-source fusion SLAM method based on LiDAR/IMU/UWB tight coupling to address the problem of decreased positioning accuracy caused by dynamic interference in urban environments. The aim is to improve the robustness and localization accuracy of the system under dynamic interference. In the odometry stage, this paper constructs a factor graph framework that deeply integrates IMU pre integration and multi base station UWB distance observation. IMU provides high-frequency motion priors to compensate for point cloud distortion, while UWB introduces stable external constraints through absolute ranging without cumulative errors, which can effectively suppress the cumulative errors of LiDAR in dynamic environments and significantly improve the robustness of pose estimation in dynamic interference scenarios. In addition, in the loop detection and global optimization stage, this paper designs an extended descriptor that combines UWB information to encode and fuse point cloud geometric features with UWB absolute range and signal strength information, forming a more discriminative scene representation. Based on this descriptor, a two-level loop detection strategy of "coarse retrieval fine verification" is adopted: First, UWB information is used to quickly screen candidate loop frames, and then point cloud descriptor geometry verification is performed, effectively improving the accuracy of loop detection in dynamic and homogeneous environments. After detecting the loop, the UWB historical information and point cloud constraints are jointly incorporated into the global factor map for collaborative optimization, further improving trajectory consistency and map closure accuracy. Experiments real-word urban dynamic-scene datastes show

收稿日期:2025-10-16 Received Date: 2025-10-16

* 基金项目:国家重点研发计划(2022YFB3904404)项目资助

that our method can significantly reduce absolute trajectory error (ATE) compared with methods such as FAST-LIO2 and MR-ULINS. Meanwhile, the UWB assisted loop back detection mechanism performs better on the precision recall curve, effectively reducing dynamic ghosting and false matching, verifying the effectiveness and superiority of this method in urban dynamic environments.

Keywords: tightly coupled odometer; dynamic interference; extended descriptor; multi source sensor fusion

0 引言

随着自动驾驶技术的快速发展,基于机载激光雷达(light detection and ranging, LiDAR)的同步定位与建图(simultaneous localization and mapping, SLAM)技术取得了显著进展。SLAM包含了里程计环节与回环优化环节两个部分,相比视觉方案, LiDAR弥补了视觉在快速运动、弱纹理环境下的不足,提供了更鲁棒、尺度一致的定位与地图。然而,在城市环境中,复杂的动态交通参与者给 LiDAR SLAM系统带来了严峻挑战。这些动态障碍不仅会导致定位误差增大、地图质量下降,还会降低算法的鲁棒性、增加计算负担,使得场景的依赖性增强^[1-8]。

单一 LiDAR SLAM利用激光雷达逐帧采集点云,通过连续帧的几何配准(scan-to-scan或scan-to-map)估计自身运动,同时把已配准的点云累加成全局地图,实现“一边建图一边定位”,后端采用图优化或滤波器对前端里程计累计误差进行全局校正,并辅以回环检测保持长期一致性。Wang等^[9]与Pfreundschuh等^[10]均先利用基于轻量卷积神经网络(convolutional neural network, CNN)对行人、车辆等潜在动态目标进行逐点/逐体素标记,随后以速度先验或自动生成标签为约束,将动态簇整体剔除或赋予零权重参与迭代最近点(iterative closest point, ICP);然而,在Semantic POSS等密集动态数据集上,剔除后轨迹误差仍较静态工况放大2~3倍,暴露出语义模型对边缘遮挡和误检的敏感性。Jie等^[11]引入LiDAR原始多普勒信息直接估计径向速度,以阈值法滤除动态点,但当目标速度趋近于0或呈横向运动时区分失效,动态序列绝对轨迹误差(absolute trajectory error, ATE)上升1.7倍,表明单一几何-速度约束的判别边界有限。Wang等^[12]通过对象级语义图将动态节点以低权重而非硬剔除方式纳入因子图优化,试图保留部分几何约束,却在Semantic KITTI-Moving子集上仍出现相对姿态误差(relative pose error, RPE)相对静态场景65%的膨胀,且对语义分割误差高度敏感。4类方法虽在语义、速度或图权重层面抑制动态干扰,但均受限于单一LiDAR的几何退化与特征稀疏,导致在高动态并发场景下定位鲁棒性显著降低,因此引入新的传感器与LiDAR进行互补是必然之举。

惯性测量单元(inertial measurement unit, IMU)能在LiDAR帧间提供高频六自由度运动先验,既补偿点云畸变又降低匹配搜索维度,从而在动态环境中维持实时性

与精度,因此LiDAR/IMU融合的方案成了研究者的不二选择。整体而言,使用LiDAR/IMU融合方案普遍遵循“IMU预测-几何一致性-权重调整”的三级剔除策略。Jia等^[13]提出的具有3D动态目标跟踪与移除的高效激光雷达里程计(an efficient LiDAR odometry with 3D dynamic object tracking and removal, TRLO)以3D动态目标跟踪与贝叶斯概率地图联合更新为核心,通过帧间分割-跟踪-验证链显式估计并剔除运动目标,但在遮挡严重或目标短时静止时会误判为静态而残留伪影;Wang等^[14]在动态物体移除的激光雷达-惯性同步定位与地图构建(dynamic objects removal LiDAR-inertial SLAM, DORLINS)提出地面伪占据栅格先验,将LiDAR/IMU紧耦合残差与栅格一致性检验结合,实现快速动态体素清除,却因栅格分辨率固定导致近处小目标过度剔除、远处大目标遗漏。Qian等^[15]在高动态环境下“先移除”的紧耦合激光雷达-惯性里程计(removal-first tightly-coupled LiDAR inertial odometry in high dynamic environments, RF-LIO)采用“先移除后优化”策略:IMU预积分补偿畸变后,利用滑动窗口残差阈值即时剔除异常点,再执行紧耦合优化,虽在高动态场景显著降低漂移,但阈值全局固定致使纹理稀疏环境易误删静态结构。尽管LiDAR/IMU融合方案相比单一LiDAR的方案有显著的提升,但在特征稀疏、目标短暂静止或持续占主导视野等极端条件下,动态/静态边界判定仍欠自适应,且缺乏对后续定位精度的定量回溯修正机制。这使得研究者不得不考虑引入额外的观测传感器来应对上述挑战。

多源传感融合的LiDAR SLAM是当前SLAM热门的研究方向之一,其旨在利用异构信息的互补性来抑制前述单一LiDAR或仅LiDAR/IMU融合的退化与失效。例如,在动态物体密集的城市场景中,视觉特征点可为LiDAR提供纹理辅助,当LiDAR因移动车辆遮挡造成几何结构缺失时,视觉线索仍可维持位姿跟踪;再如,在长廊、隧道等视觉弱纹理且LiDAR几何退化并存的极端环境下,单目或双目视觉虽易因纹理缺失而跟踪失败,但其颜色与亮度信息可与LiDAR点云形成局部互补,共同应对特征稀疏的挑战。Zheng等^[16]提出的快速且紧耦合的稀疏直接激光雷达-惯性-视觉里程计(fast and tightly-coupled sparse-direct LiDAR-inertial-visual odometry, FAST-LIVO)与Wang等^[17]提出的面向高动态环境下鲁棒激光雷达-惯性-视觉SLAM的语义-几何融合方法(semantic-geometric Fusion for robust LiDAR-inertial-visual SLAM in dynamic environments, GR-

Fusion), 分别依托光流/几何一致性及语义-几何联合检验构建多源传感融合框架, 均属于 LiDAR/IMU/视觉多源传感融合 SLAM 的典型方案。在动态场景下, 这类多源组合常因移动物体遮挡、几何退化及特征缺失而迅速漂移, 且外观剧烈变化会使回环检测召回率骤降。

相比之下, 超宽带 (ultra wide band, UWB) 凭借厘米级单向测距且不依赖于视觉或几何特征, 使其在特征缺失或剧烈变化的环境中依然能提供稳定的绝对位置约束^[18]。UWB 以稀疏锚点提供的绝对测距作为一维几何约束, 可直接嵌入滤波或图优化后端, 在无需回环的条件下抑制 SLAM 的积分漂移。其信号对光照、纹理及动态目标不敏感, 且计算残差简洁, 兼具低成本部署与即插即用优势^[19]。因此, 将 UWB 引入 LiDAR/IMU 系统, 构建 LiDAR/IMU/UWB 融合框架成为了新的多源融合方向之一。Pan 等^[20]采用误差状态卡尔曼滤波-非线性优化两层架构, 依据点云退化指数在线调节 UWB 残差权重, 里程计阶段 UWB 以单锚点距离因子紧耦合入图。Kuang 等^[21]提出“多历元一致性”投票, 首次把非视距 (non-line-of-sight, NLOS) 与 LiDAR 动态离群统一在因子图内同步剔除, 同样只在里程计紧耦合单锚点 UWB。Wang 等^[22]将改进沙猫群算法嵌入粒子滤波, 自适应调整 LiDAR-IMU 与 UWB 距离量测的粒子权重, 实现紧耦合里程计。Sun 等^[23]提出的基于 B 样条表示的连续时间激光雷达-惯性-UWB 里程计 (continuous-time LiDAR-inertial-UWB odometry with B-spline representation, CT-UIO) 以连续时间 B 样条 (B-spline) 统一 LiDAR-IMU-UWB, 单/双基站即可保持可观性, UWB 距离因子全程紧耦合。Zhang 等^[24]提出的多机器人 UWB-激光雷达-惯性导航系统 (multi-robot UWB-LiDAR-inertial navigation system, MR-ULINS) 在滑窗因子图中用单锚点 UWB 与 LiDAR-IMU 紧耦合, 并引入跨历元异常投票。Nguyen 等^[25]提出的 VIRAL SLAM, 利用 UWB 绝对距离抑制漂移, VIRAL 采用视觉-IMU-UWB-LiDAR 四传感器松-紧耦合混合架构, 其中, UWB 仅作为 3-D 位置因子接入滑窗, 回环仍依赖视觉词袋。综上, 现有融合方法对 UWB 信息的利用仍存在明显局限: 多数工作仅以松耦合方式将单锚点 UWB 测距或粗略定位结果引入系统, 且其作用范围基本局限于前端里程计阶段。这种浅层次的融合方式导致 UWB 的潜力未能充分发挥, 主要体现在两方面: 一方面, 仅依赖单一基站的单向距离约束, 缺乏多基站冗余观测, 一旦出现基站与机器人间共线或信号遮挡, 系统可观性将急剧下降, 定位可靠性难以保证; 另一方面, UWB 信息止步于里程计环节, 未能进一步延伸至回环检测与全局优化层, 致使系统在外观剧烈变化或几何特征退化场景中, 仍然完全依赖传统的 LiDAR 描述子进行回环识别, 整体召回率难以得到 UWB 全局位置信息的有效提升。

本研究提出了一种面向城市动态环境的 LiDAR/IMU/UWB 融合 SLAM 定位技术, 重点研究解决城市动态环境下 LiDAR SLAM 的定位精度急剧下降问题, 旨在通过提升系统在动态干扰下的鲁棒性, 进而实现并维持高精度的位姿估计, 主要贡献为:

1) 在里程计环节, 引入多基站的 LiDAR/IMU/UWB 紧耦合因子图架构, 有效抑制城市动态环境下的动态目标所带来的位姿估计漂移与地图结构扭曲;

2) 在回环优化环节, 设计了含 UWB 历史信息的扩展描述子, 提高城市动态环境下回环识别的准确性和可靠性, 并将 UWB 的历史信息引入到优化部分, 进一步提升全局位姿图优化的收敛精度与鲁棒性。

1 理论分析

本研究提出的融合定位系统架构如图 1 所示, 主要包括紧耦合里程计、回环检测与全局优化这 3 部分。

首先通过 3 种传感器获得原始数据, 并利用原始数据的紧耦合里程计输出位姿估计, 同时对关键帧的描述子生成加入 UWB 信息, 生成拓展描述子以便后续的回环检测; 最后将 UWB 的历史信息与回环帧信息结合, 与关键帧共同进行全局优化。

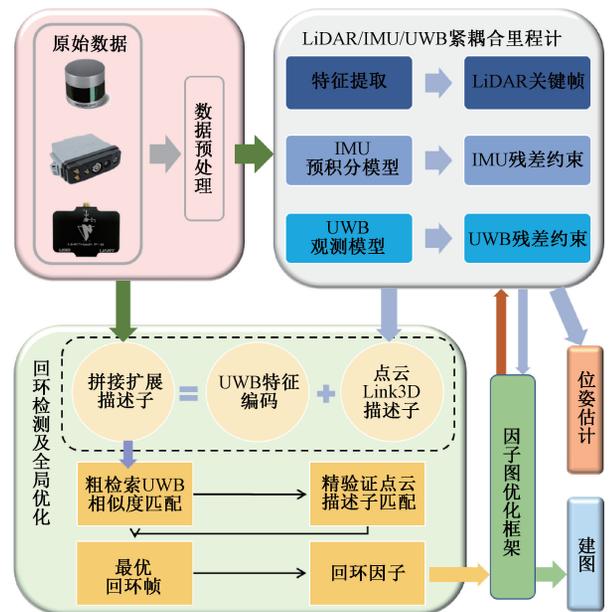


图 1 LiDAR/IMU/UWB 多源融合定位流程

Fig. 1 LiDAR/IMU/UWB multi-source fusion positioning process

1.1 LiDAR/IMU/UWB 紧耦合里程计

对这 3 种传感器进行融合, 首先需要在这 3 种传感器的原始数据进行预处理, 使其时空同步, 然后分别构建模型, 最后进行联合求解。

1) IMU 预积分模型建立

IMU 可以输出三轴加速度 $\tilde{\mathbf{a}}$ 和三轴角速度 $\tilde{\mathbf{w}}$, 在实际应用中, IMU 的测量值会受到高斯白噪声 \mathbf{n} 和零偏 \mathbf{b} 的影响, 在对原始信号进行滤波处理后在实际工程中, 由于 IMU 测量得到的是数字信号, 所以一般采用预积分模型的离散形式, 即:

$$\boldsymbol{\alpha}_{B_i^{k+1}} = \boldsymbol{\alpha}_{B_i^k} + \boldsymbol{\beta}_{B_i^k} \delta t + \frac{1}{2} \mathbf{a} \delta t^2 \quad (1)$$

$$\boldsymbol{\beta}_{B_i^{k+1}} = \boldsymbol{\beta}_{B_i^k} + \mathbf{a} \delta t \quad (2)$$

$$\mathbf{q}_{B_i^{k+1}} = \mathbf{q}_{B_i^k} \otimes \begin{bmatrix} 1 \\ \frac{1}{2} \mathbf{w} \delta t \end{bmatrix} \quad (3)$$

式中: \mathbf{w} 和 \mathbf{a} 一般采用中值积分的方法获得, 表达式为:

$$\mathbf{w} = \frac{1}{2} [(\mathbf{w}^{B_k} - \mathbf{b}^g - \mathbf{n}^g) + (\mathbf{w}^{B_{k+1}} - \mathbf{b}^g - \mathbf{n}^g)] \quad (4)$$

$$\mathbf{a} = \frac{1}{2} [\mathbf{q}_{B_i^k} (\mathbf{a}^{B_k} - \mathbf{b}^a - \mathbf{n}^a) + \mathbf{q}_{B_i^{k+1}} (\mathbf{a}^{B_{k+1}} - \mathbf{b}^a - \mathbf{n}^a)] \quad (5)$$

式中: \mathbf{w}^B 和 \mathbf{a}^B 分别表示 IMU 在车体坐标系下的角速度和加速度; \mathbf{b}^g 和 \mathbf{b}^a 分别表示角速度和加速度的随机游走; \mathbf{n}^g 和 \mathbf{n}^a 分别表示角速度和加速度的测量噪声。

2) UWB 观测模型

与 LiDAR、IMU 这类传感器的工作方式不同, UWB 通过布设基站并接受接收距离信息来估计移动载体的位置, 是一种不含累积误差的绝对定位方式, 尤其在卫星拒止环境下, 更能体现其优势。因此, 本文模拟卫星拒止环境并引入 UWB 传感器来为移动载体的当前状态提供观测约束。

UWB 的观测量能够以松耦合或紧耦合的方式融入到因子图中, 松耦合的方式首先通过多个 UWB 基站提供的距离信息解算得到车载标签的三维位置, 然后将位置信息作为观测量来为因子图的当前状态节点提供约束; 紧耦合的方式是将原始的距离信息直接作为观测量来为状态节点提供约束, 本文采用紧耦合的方式, 相应的残差函数为:

$$f^{U_i} = \sqrt{(x^U - x^i)^2 + (y^U - y^i)^2 + (z^U - z^i)^2} - d^i \quad (6)$$

式中: (x^i, y^i, z^i) 为基站已知的三维位置坐标; (x^U, y^U, z^U) 为车载标签未知的三维位置坐标; d^i 为第 i 个 UWB 基站提供给标签的距离观测量。

在得到残差函数后, 与其余传感器的残差方程进行联合求解, 结合非线性优化方法来对车载标签进行准确的位置估计。基于紧耦合的 UWB 观测模型虽然能够直接以位置观测约束因子图中的当前状态节点, 然而在解算 UWB 三维位置的过程中, 需要对原始观测信息进行预处理, 这将引入计算误差, 从而降低位置估计的准确性。而对于紧耦合的融合方式, 其将 UWB 的原始距离信息作为观测模型以约束当前状态, 该方式能够最大程度利用

传感器的信息并获得可靠准确的状态估计结果。因此, 本文采用紧耦合的方式来融合 UWB 观测因子。

3) 基于 IMU/UWB 的局部因子图优化

在建立了 IMU 预积分模型与 UWB 观测模型后, 通过建立各自的残差函数来约束因子图中的节点状态, IMU 预积分模型的残差函数为:

$$f_{IMU} = \begin{bmatrix} \mathbf{r}_p = \mathbf{q}_{B_i}^W (\mathbf{p}_j^W - \mathbf{p}_i^W - \mathbf{v}_i^W \Delta t + \frac{1}{2} \mathbf{g} \Delta t^2) - \boldsymbol{\alpha}_{B_i^{B_j}} \\ \mathbf{r}_q = 2 [\mathbf{q}_{B_i}^{B_j} \otimes (\mathbf{q}_{B_i}^{B_i} \otimes \mathbf{q}_{B_i}^W)]_{xyz} \\ \mathbf{r}_v = \mathbf{q}_{B_i}^{B_j} (\mathbf{v}_j^W - \mathbf{v}_i^W + \mathbf{g} \Delta t) - \boldsymbol{\beta}_{B_i^{B_j}} \\ \mathbf{r}_b^a = \mathbf{b}_j^a - \mathbf{b}_i^a \\ \mathbf{r}_b^g = \mathbf{b}_j^g - \mathbf{b}_i^g \end{bmatrix} \quad (7)$$

基于紧耦合的 UWB 观测模型的残差函数为:

$$f_{UWB}^{dis} = r(d_k^i - h_{UWB}(\mathbf{X}_k, \mathbf{X}^i)) \quad (8)$$

式中: d_k^i 表示 k 时刻由第 i 个 UWB 基站提供的距离观测; $h_{UWB}(\mathbf{X}_k, \mathbf{X}^i)$ 表示 k 时刻转换到 UWB 坐标系下的当前状态与第 i 个基站的位置 \mathbf{X}^i 之间的距离函数。

由于 UWB 的作用范围有限, 且距离精度与非视距遮挡有很大关系, 为保证位姿估计精度, 本文设定了严格的阈值来保证 UWB 观测在因子图融合时的准确性, 具体规则为:

(1) 若当前因子图输出的位置置信度在阈值 th_p (本文设置为 0.25 m) 要求之内, 则不融入 UWB 因子;

(2) UWB 的输出频率较高 (为 50 Hz), 若当前时刻采集的距离观测相对于上一时刻的距离观测变化量超过阈值 $th_{\Delta d}$ (本文设置为 0.5 m), 此时认为受到了非视距的影响, 也不融入 UWB 因子;

(3) UWB 的测距精度随距离增大而减小, 若当前的距离观测超过阈值 th_{range} (本文设置为 150 m), 也不进行 UWB 因子融合。

此外, 为了获取 UWB 基站在世界坐标系下的先验位置, 本文首先利用实时动态定位 (real-time kinematic, RTK) 模式下的组合导航设备来获取 UWB 基站的经纬高 $P_{Anchor_i}^{LLA}$, 以及车辆在初始关键帧时刻的经纬高 $P_{B_0}^{LLA}$ 和航偏角 yaw_0 。然后, 以 $P_{B_0}^{LLA}$ 为原点, 将 $P_{Anchor_i}^{LLA}$ 转换到地理东北天 (east-north-up, ENU) 系下, 得到 $P_{Anchor_i}^{ENU}$ 。为了进行数据融合, 还需要将基站位置从 ENU 系转到世界坐标系下, 而世界系是根据起始的车体系建立的左前上坐标系 (左 - x , 前 - y , 上 - z), 因此有:

$$\mathbf{P}_{Anchor_i}^W = \mathbf{R}_{ENU}^W \mathbf{P}_{Anchor_i}^{ENU} + \mathbf{t}_{ENU}^W \quad (9)$$

式中: \mathbf{R}_{ENU}^W 和 \mathbf{t}_{ENU}^W 表达式为:

$$\mathbf{R}_{ENU}^W = \begin{bmatrix} -\cos yaw_0 & \sin yaw_0 & 0 \\ \sin yaw_0 & \cos yaw_0 & 0 \\ 0 & 0 & 1 \end{bmatrix} \quad (10)$$

$$\mathbf{t}_{ENU}^W = \begin{bmatrix} 0 \\ 0 \\ z_{Anchor_i}^{LLA} - z_{B_0}^{LLA} \end{bmatrix} \quad (11)$$

式中: $z_{Anchor_i}^{LLA}$ 和 $z_{B_0}^{LLA}$ 是根据 RTK 模式下的组合导航设备得到的 UWB 基站和车体在起始时刻的高度。

本文认为各传感器的观测噪声符合零均值的高斯分布,因此在建立了关于 IMU 预积分和 UWB 观测的残差函数后,将其转化为最小二乘模型以进行局部因子图优化,最小二乘模型表达式为:

$$\mathbf{X}^* = \operatorname{argmin}_{\mathbf{X}} \sum_i \|f_i\|_{\Sigma_i}^2 \quad (12)$$

式中: \mathbf{X}^* 表示待优化的位姿; f_i 表示公式(7)和(8)中的残差函数; Σ_i 表示各传感器数据的协方差。

本文利用 GTSAM 工具库对上述模型进行优化,该工具库基于贝叶斯树对因子图中的状态进行优化求解,贝叶斯树仅对受到新的观测因子影响的状态节点进行更新,大大提高了因子图工作的效率。

1.2 基于 UWB 扩展描述子的回环检测及全局优化

1) 生成对点云的描述子

本文的扩展描述子在 Link3D 描述子的基础上扩展 UWB 描述得到,分别将点云和 UWB 的信息生成对应的描述子,然后合成扩展描述子。首先使用 Link3D 的方法生成点云的描述子。可得到公式为:

$$\mathbf{V}_{PointCloud} = [d_1, d_2, \dots, d_n] \quad (13)$$

2) 生成对 UWB 信息的描述子

由于 UWB 具有信号稳定,不含累计误差等优点,故本文对 UWB 的信息进行采集编码,使之成为描述子的一部分,从而增强系统的鲁棒性,增加回环检测的检出率和降低误检率。UWB 的输入信号分为标签到基站的距离值、标签到基站的信号强度等,本文依托这两个信息进行处理。

首先对输入的 UWB 信号进行距离归一化和强度归一化处理,其表达式为:

$$d_{norm} = \frac{d - d_{min}}{d_{max} - d_{min}} \quad (14)$$

$$RSSI_{norm} = \frac{RSSI - RSSI_{noise}}{RSSI_{max} - RSSI_{noise}} \quad (15)$$

式中: d_{min} 为 UWB 标定测量范围的最小值; d_{max} 为 UWB 标定测量范围的最大值; $RSSI_{max}$ 为信号强度标定测量最大值; $RSSI_{noise}$ 为信号强度量测的硬件噪声基底。

对上述归一化后的 UWB 测距信息进行距离分段量化,将归一化距离划分为 16 个区间(4 bit 二进制编码);对信号强度进行强度动态处理,使用对数压缩,

$$RSSI_{compressed} = \lg(RSSI_{norm} + 1) \quad (16)$$

为消除瞬时波动的影响,采用窗口大小为 3 帧的高斯滤波(结果同上采用 4 bit 的二进制编码)。将距离编码与

强度编码进行基础拼接合并为 8 bit 的基础描述子,至此已完成对 UWB 信息的特征编码。本文采用多基站组合,同时根据基站的先验位置和递推位姿引入基站的粗略方向角(只区分前后左右 4 个方向仅需 2 bit),空间上下文增强后的 UWB 特征描述子长度为 10 bit,选取距离当前车载体最近的 3 个基站组合成长度为 30 bit 的总描述子。

为便于存储和后续回环检测时的匹配,对上述的 UWB 总描述子使用局部敏感哈希(locality-sensitive Hashing, LSH)将 30-bit 映射到 32-bit 哈希码,如式(17)所示。

$$Hash = LSH(Base64Code) \quad (17)$$

将 UWB 信息特征与前述点云特征描述子拼接并输出,如式(18)所示,以[哈希码,基站 ID,时间戳]的三元组存入特征库,即:

$$\mathbf{V}_{Fused} = [\mathbf{V}_{UWB}, \mathbf{V}_{PointCloud}, ID_{Anchor}, Time] \quad (18)$$

3) UWB 辅助的回环检测及全局优化

当 LiDAR 到达关键帧时,从起始帧到上一关键帧之间的描述子都将被存储在哈希表中,利用扩展描述子匹配当前场景是否在历史中出现过。本文的回环检测设计为两级,即粗检索与精验证。依托于纯点云的回环检测在某些相似或连续同质化环境下会失效,因此本文引入了 UWB 来辅助回环检测,基于 UWB 基站绝对位置的时不变,因此当回环发生时,当前帧与历史帧的 UWB 信息总有较高的相似性(标签到每个基站的距离),基于前述的扩展描述子,可快速检索与当前位置相距最近的 3 个基站 ID,再对两帧之间的 UWB 距离描述子部分与信号强度描述子部分采用加权^[26]欧式距离衡量相似度,如式(19)所示。

$$S_{UWB} = \sum_{i=1}^N \omega_i (\alpha \cdot (d_i - d'_d)^2 + \beta \cdot (s_i - s'_i)^2) \quad (19)$$

式中: α β 是测距信号和强度的权重; ω_i 是锚点权重,

$$\omega_i = \frac{1}{\sigma_{s_i}^2 + \varepsilon}, \text{ 且 } \varepsilon > 0.$$

使用 K 维树(K-dimensional tree, KD-Tree)加速搜索,返回 Top5 个最相似的候选帧。

对第 1 级粗检索选出的 5 个候选帧进行第 2 级精验证。首先计算当前帧与候选帧的 Link3D 描述子的相似度,如式(20)所示。

$$S_{Link3D} = \text{cosine_similarity}(D_{Link3D}, D'_{Link3D}) \quad (20)$$

若 $S_{Link3D} > \theta_{Link3D}$, 则进入下一步对的几何对齐。利用 Link3D 描述子构建的单词来检索判断该单词是否在候选帧中出现过,进而通过哈希表确定其对应的历史地点。不断遍历当前帧中的所有单词,并统计其相应历史地点的出现频率,若其最高出现频率大于频率阈值 th_f , 则认为其对应的关键帧是回环帧 P_{loop} 。约束匹配在识别到历史回环帧 P_{loop} 后,利用当前帧和候选帧的扩展描述子进行帧间索引配对。从这两帧中各选取一个描述子,不断比对这两个描述子在每个维度的汉明距离,若该距

离小于相似性阈值 th_{sim} , 则相似性分数加 1。比对完成后, 若相似性分数高于阈值 th_{score} , 则认为该匹配有效, 记录当前分数和索引并进行下一次匹配, 直到选出分数最高的匹配对为止。需要注意的是, 当两帧之间的描述子配对成功后, 可能会出现一帧的一个描述子索引与另一帧的多个描述子索引建立匹配的情况, 此时, 应选取相似性分数最高的匹配对。两帧之间的描述子建立匹配关系, 也即两帧的质心点建立了匹配关系, 本文根据两帧之间质心点的约束关系和 ICP 原理以及 UWB 信息来建立残差函数和代价函数, 分别如式 (21) ~ (23) 所示, 并采用非线性优化的方法来迭代求解最优变换位姿 ΔT , 即:

$$f_i = \Delta T P_{cur}^i - P_{loop}^i \quad (21)$$

$$f_{UWB} = d_{meas} - \|t_{anchor} - T_i t_{tag}\| \quad (22)$$

$$\min_{\Delta T} F = \frac{1}{2} \sum_{i=1}^n \|f_i\|_2^2 + \frac{1}{2} \sum_{i=1}^m \|f_{UWB}\|_2^2 \quad (23)$$

式中: P_{cur}^i 和 P_{loop}^i 分别表示当前帧和回环帧的质心点; n 表示匹配对的数量; m 表示当前位置接收到有效信号的基站数量。优化完成后, 当前关键帧的最优位姿 T_{cur} 为:

$$T_{cur} = \Delta T T_{cur0} \quad (24)$$

$$\Delta T_{loop}^{cur} = T_{loop}^{-1} T_{cur} \quad (25)$$

2 实验验证

本文实验所用系统部署于搭载 Ubuntu 20.04 操作系统的平台, 所用 CPU 型号为 Intel Core i7-6600U, 基于机器人操作系统 (Robot Operating System, ROS) 框架使用 C++ 进行算法开发。由于本文主要在城市环境下对多源融合激光 SLAM 开展性能评估, 且除 LiDAR/IMU 数据外, 还需额外采集 UWB 数据, 因此并未选用公开数据集进行实验验证, 而是采集了自车数据, 并将其命名为 MyDataset1。其车载平台采集如图 2 所示。



图 2 车载平台

Fig. 2 Vehicle platform

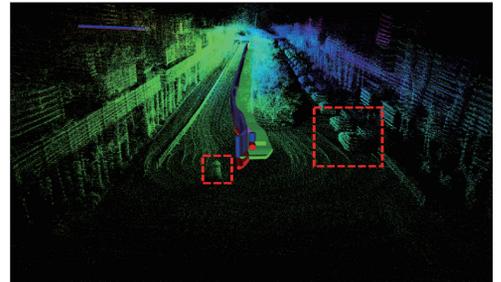
采集地点为南京市东南大学四牌楼校区附近如图 3 所示, 其中星形表示 UWB 基站布设路线全长 2.32 km, 车辆从起点出发, 环绕一圈后回到起点附近。



图 3 数据采集路线与实验场景

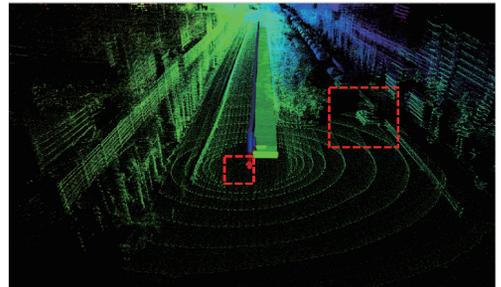
Fig. 3 Data collection route and experimental scenario

数据采集所处路段存在动态目标频繁的场景如图 4 所示, 易造成 LiDAR 里程计的位姿估计不准, 还容易给点云建图造成不好的影响。



(a) 首次经过同一路口动态场景点云图

(a) First time passing through the same intersection, dynamic scene point cloud map



(b) 二次经过同一路口动态场景点云图

(b) Second time passing through the same intersection, dynamic scene point cloud map

图 4 动态场景点云对比图

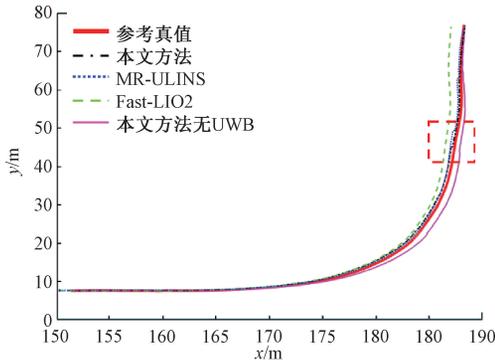
Fig. 4 Dynamic scene point cloud comparison diagram

2.1 基于 IMU/LiDAR/UWB 的紧耦合里程计实验

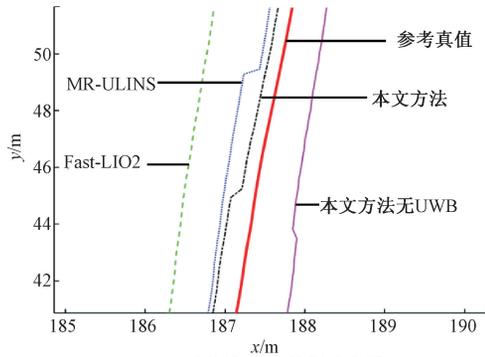
根据前述 UWB 观测模型中的设定, 在确定了 UWB 基站在世界系下的位置 $P_{Anchor_i}^W$ 后, 便可将 UWB 观测因子

融入到因子图中。本文进行了对比实验、消融实验来验证增加 UWB 因子的有效性。

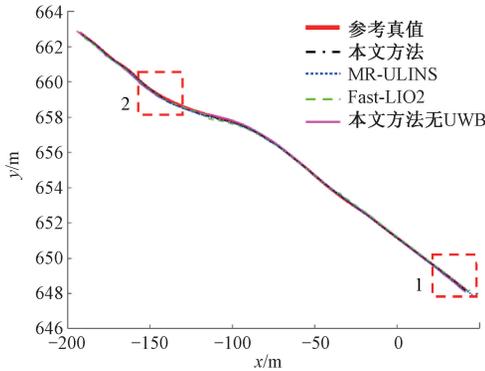
利用 MyDataset1 绘制的轨迹如图 5 所示。



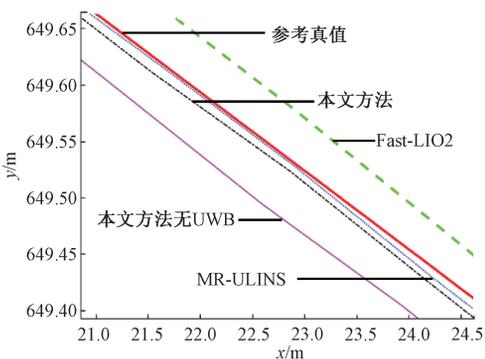
(a) 运动轨迹 I
(a) Motion trajectory I



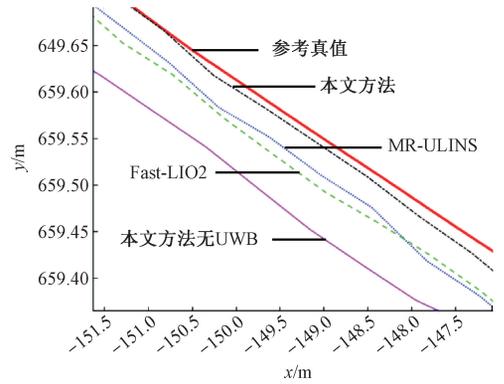
(b) 运动轨迹 I 的虚线框放大图
(b) Enlarged dashed box of motion trajectory I



(c) 运动轨迹 II
(c) Motion trajectory II



(d) 运动轨迹 II 的虚线框 I 放大图
(d) Enlarged image of dashed box I of motion trajectory II



(e) 运动轨迹 II 的虚线框 2 放大图
(e) Enlarged image of dashed box 2 of motion trajectory II

图 5 利用 MyDataset1 得到的轨迹对比

Fig. 5 Comparison of trajectories obtained using MyDataset1

图 5(a) 和 (c) 为两段不同轨迹, 图 5(b)、(d) 和 (e) 分别为两条轨迹图的虚线框放大图, 由图可知, 在相同的初始条件下, 直线行驶且里程较短时几种方法的差异不大, 但是随着弯道出现, 动态交通参与者的增多, 差异开始显著。

Fast-LIO2 采用前端“把每一帧原始点云直接配准到全局地图”, 不做特征提取; 后端“紧耦合迭代卡尔曼滤波 (iterated extended Kalman filter, IEKF)”把 IMU 与雷达观测融合在一起, 并用增量 K-D 树 (iKD-Tree) 维护地图, 由于“所有点都参与匹配”, 算法在静态场景能利用墙面、栏杆等细微几何, 精度高、计算快; 但一旦场景里出现大量动态物体, 无法区分“自身运动”与“外界运动”, 因而把动态点产生的伪位移当成载体运动, 精度会明显下降。

MR-ULINS 本质上是一套“3D-LiDAR + IMU”紧耦合的 SLAM/里程计算法。虽然也使用了紧耦合, 但是它以 IMU 预积分给出的高频运动预测为初值, 把当前激光扫描投影到局 (或全局) 静态地图上做扫描匹配 (正态分布变换 (normal distributions transform, NDT) 或其改进型), 再用因子图把 IMU 约束、雷达里程计约束、地平面约束联合优化, 从而输出机器人位姿与地图。整个过程默认“场景静止”——即点云配准误差最小化的最优解对应的是传感器自身运动, 而不是外界物体运动。在动态环境下, 这一“静态假设”被大量破坏, 致使精度下降。

本文增加了消融实验进行对比, 消融实验采用本文方法但仅使用 LiDAR/IMU 而不融合 UWB 数据, 因此在动态环境下, 也存在与上述两种方法一样的问题, 动态物体的增多导致前端匹配正确率下降, 进而导致精度较差。本文所使用的里程计方法, 因为引入了 UWB 的先验位置和距离信息作为约束, 对动态干扰进行了一定程度的修正, 得到的轨迹更贴近参考真值, 由此也可体现出 UWB 参与的里程计对动态环境下轨迹的累计误差有较好的

消除。

本文使用绝对轨迹误差 (absolute trajectory error, ATE) 来量化评估参考真值与不同算法得到的轨迹之间的误差,其表达式为:

$$ATE_{trans} = \sqrt{\frac{1}{N} \sum_{i=1}^N \|trans(\mathbf{T}_{gt,i}^{-1} \mathbf{T}_{esti,i})\|_2^2} \quad (26)$$

式中: $\mathbf{T}_{gt,i}$ 表示 i 时刻的参考位姿,由 RTK 模式下的组合导航设备来获得; $\mathbf{T}_{esti,i}$ 表示 i 时刻由不同算法得到的估计位姿; $trans(\cdot)$ 表示只取位姿的平移部分进行误差分析,这是因为旋转出现的误差也会在平移中表达出来。具体误差统计结果如表 1 所示。

表 1 绝对轨迹误差对比

Table 1 Comparison of absolute trajectory error

绝对轨迹误差	MyDataset1	
	x/m	y/m
本文方法	1.256	0.468
MR_ULINS	2.495	0.963
FAST-LIO2	10.015	2.368
本文方法无 UWB	12.673	4.545

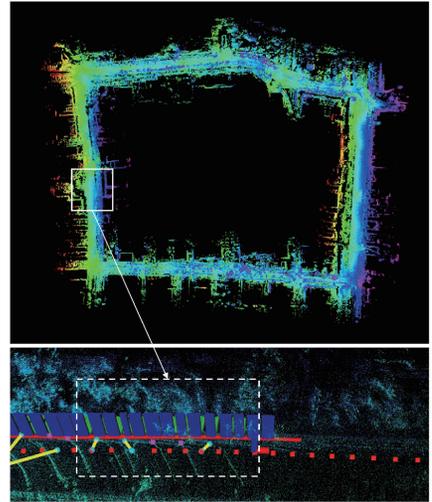
2.2 基于 UWB 协同的回环及优化实验

在进行实验时,本文仍然以 MyDataset1 对应的场景为基础,车辆在环绕一圈后又回到起点附近;如图 4 所示,从起始位置所在区域的点云图可知,该区域的动态干扰较多,易造成回环检测失效。

车辆从起始位置出发,此时车辆开始将有效测距范围内最近 3 个 UWB 基站的测距信息等记录并依照关键帧的时刻进行时空对齐后生成对应的描述子;由于 UWB 基站均匀分布在实验全路段,车辆会不间断地接收到 UWB 的信息,并逐一如上记录。当车辆环绕一圈再次进入到初始位置附近时距离最近的 UWB 基站应具有高度的一致性,车辆接收到的 UWB 信息也会有高度的相似性,利用本文上述方法对 UWB 部分描述子进行相似度计算,计算当前帧与候选帧之间的欧式距离,选出 TOP5 的候选帧作为经过初级粗检索的结果。该方法仅需匹配 UWB 基站 ID,以及对应的距离信息,相比较直接使用点云的配准会更为便捷。对候选帧进行二级精验证,即对当前帧与候选帧的点云部分的描述子进行配准,选取得分最高的一个候选帧即为历史帧回环帧。

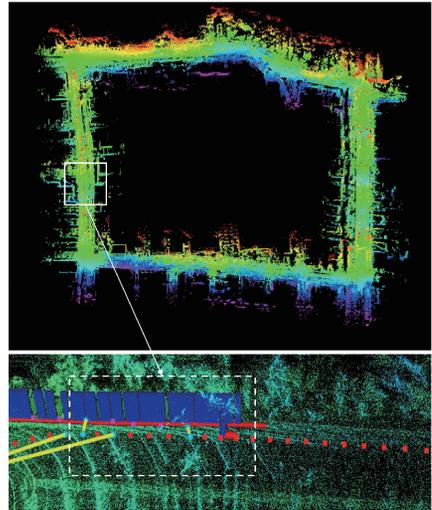
确定回环帧后,计算当前帧的位姿估计值,然后将当前帧的修正值与历史回环帧的值进行比较计算得到质心位移和旋转角,记为回环因子 $\Delta \mathbf{T}$ 后,加入到因子图中进行协同优化,最终得到的关于 MyDataset1 的回环处点云图如图 6 所示,本文方法的建图较为清晰,而 SC-LIO-SAM 的方法则有较多的重影,这是因为动态物体在地图

里被多帧留存造成的视觉拖影。



(a) 本文方法的轨迹点云

(a) Trajectory point cloud of the method described in this article



(b) SC-LIO-SAM方法的轨迹点云

(b) Trajectory point cloud of SC-LIO-SAM method

图 6 利用 MyDataset1 得到的轨迹点云对比

Fig. 6 Comparison of trajectory point clouds obtained using MyDataset1

全局轨迹以及回环处轨迹放大图如图 7 所示,从回环处虚线框区域的放大可知,在进行协同回环优化后,其得到的轨迹更加贴近参考真值,而未使用 UWB 的方法 KISS-ICP-Loop 则未能成功识别此处回环,这是因为该方法仅依赖 ICP 全局回环,需要长重合路径才能触发有效回环,消融实验则采用本文方法但 UWB 不参与,因此在动态干扰环境下也未能成功识别回环。虽然 SC-LIO-SAM 也识别了回环,但是其精度与本文方法有所差距,这证明了本文方法的有效性。

同时本文对 4 种方法的查准率-查全率曲线 (precision-recall, PR) 进行了绘制如图 8 所示,PR 曲线

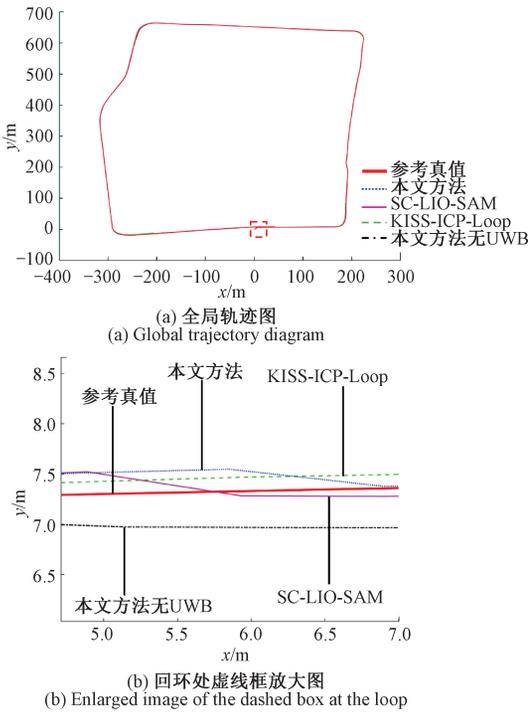


图 7 利用 MyDataset1 得到回环轨迹

Fig. 7 Obtain the loop trajectory using MyDataset1

可以更直观地评估回环检测算法的好坏,整条曲线偏向右上方的程度越大,代表对应的方法性能越好。由图 8 可知本文方法无 UWB 参与的消融实验性能较差,这是因为回环点所处地域有较多的动态干扰,无 UWB 参与下无法有效地去除这些动态点造成的干扰,当车辆拥挤行进缓慢时,易将周围的车辆以及部分行人误判为相对静止的物体,从而影响描述子的构建,致使该方法的性能下降。而 SC-LIO-SAM 在中低召回区闭环可靠性高,但高召回区因动态鬼影与重复几何易导致精度下降,因此略逊于本文方法。KISS-ICP-Loop 的整体性能则略逊于 SC-LIO-SAM 与本文方法,这是因为该方法的本质是将回环检测当成二分类。虽然在高置信区几乎零 FP,但在高召回区也会因为几何歧义出现性能下降的问题。本文方法在回环时则采用两级验证的方式,借助 UWB 的无时漂和先验信息,提高了回环的检出率和准确率,进一步引入 UWB 的历史信息共同构建约束,使回环修正的结果更优,因此对应的 PR 曲线也表示出其性能优于其他对比方法。

分别统计 3 种方法的 ATE 如表 2 所示,可以直观地发现本文引入了 UWB 历史信息描述子后,相较其余两种方法其全局优化后的 ATE 有所提升,这是因为引入 UWB 后可观性增强, LiDAR/IMU 在动态场景下易出现航向不可观,导致方位误差的增长,而 UWB 锚点提供了独立于外观与几何的绝对距离量测,在因子图中直接对位

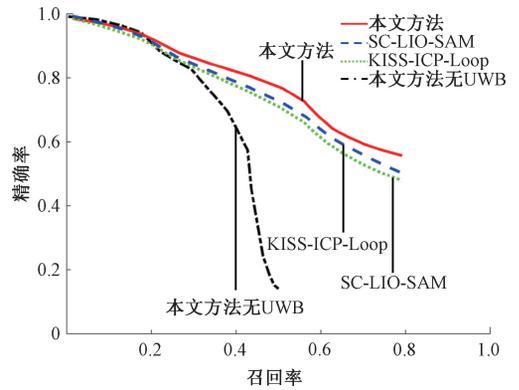


图 8 本文方法与其他方法的 PR 曲线图

Fig. 8 PR curve plot of proposed compared to other methods

置向量产生一维可观约束,从而把方位漂移由“累积型”转为“有界型”,同时紧耦合的框架将 UWB 残差与 LiDAR 残差置于同一误差估计,当某帧出现了动态遮挡时,UWB 残差仍保持非零梯度,可以有效防止优化落入局部极小。

表 2 优化后的绝对轨迹误差对比

Table 2 Comparison of absolute trajectory error after optimization

绝对轨迹误差	MyDataset1	
	x/m	y/m
本文方法	0.081	0.101
SC-LIO-SAM	0.364	0.281
KISS-ICP-Loop	0.512	0.433
本文方法无 UWB	0.735	0.566

3 结 论

本研究提出了一种基于 LiDAR/IMU/UWB 紧耦合的多源融合 SLAM 方法,针对城市环境动态干扰导致的 LiDAR SLAM 定位精度下降问题,核心目标是在动态干扰场景下实现高精度、低漂移的定位。通过构建因子图优化框架,深度融合 IMU 预积分模型和 UWB 距离观测因子,显著提升了在退化场景下的位姿估计鲁棒性。同时,设计了一种结合 UWB 信息的扩展描述子,增强了回环检测在特征稀疏或同质化环境中的准确性。

实验结果表明,该方法在动态干扰场景下能够显著降低 ATE,与 MR-ULINS 及 FAST-LIO2 相比均有提升。此外,通过引入 UWB 辅助的回环检测及全局优化策略与 SC-LIO-SAM 及 KISS-ICP-Loop 相比,进一步减少了由于动态干扰和累积误差带来的定位偏差。

研究表明,UWB协同的LiDAR SLAM是提升SLAM系统在城市动态环境中鲁棒性和精度的有效途径。未来的工作将从两个方向展开:1)深化技术层面,开发动态目标识别与剔除、传感器故障自检测等机制,从根本上提升系统的内在鲁棒性;2)拓展应用场景,在更长里程、更多样化(如高架、隧道)和更具挑战性(如雨雪天气、密集遮挡)的城市环境中进行测试与优化,以验证并进一步提升本文方法在逼近真实世界极限条件下的综合性能与实用性。

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 3D LiDAR SLAM algorithms[J]. Chinese Journal of Scientific Instrument, 2021, 42(9): 13-27.
- [2] 张少将. 基于多传感器信息融合的智能车定位导航系统研究[D]. 哈尔滨: 哈尔滨工业大学, 2020.
ZHANG SH J. Research on multi-sensor information fusion based localization and navigation system for intelligent vehicle[D]. Harbin: Harbin Institute of Technology, 2020.
- [3] HUANG L Y. Review on LiDAR-based SLAM techniques[C]. 2021 International Conference on Signal Processing and Machine Learning, 2021: 163-168.
- [4] XU X B, ZHANG L, YANG J, et al. A review of multi-sensor fusion SLAM systems based on 3D LiDAR[J]. Remote Sensing, 2022, 14(12): 2835.
- [5] CHENG J, ZHANG L Y, CHEN Q H, et al. A review of visual SLAM methods for autonomous driving vehicles[J]. Engineering Applications of Artificial Intelligence, 2022, 114: 104992.
- [6] MACARIO BARROS A, MICHEL M, MOLINE Y, et al. A comprehensive survey of visual SLAM algorithms[J]. Robotics, 2022, 11(1): 24.
- [7] SINGANDHUPE A, LA H M. A review of SLAM techniques and security in autonomous driving[C]. 2019 Third IEEE International Conference on Robotic Computing, 2019: 602-607.
- [8] 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-sensors[J]. Chinese Journal of Scientific Instrument, 2024, 45(7): 121-131.
- [9] WANG W Q, YOU X, ZHANG X, et al. LiDAR-based SLAM under semantic constraints in dynamic environments[J]. Remote Sensing, 2021, 13(18): 3651.
- [10] PFREUNDSCHUH P, HENDRIKX H F C, REIJGWART V, et al. Dynamic object aware LiDAR SLAM based on automatic generation of training data[C]. 2021 IEEE International Conference on Robotics and Automation, 2021: 11641-11647.
- [11] JIE L, JIN ZH, WANG J P, et al. A SLAM system with direct velocity estimation for mechanical and Solid-State LiDARs[J]. Remote Sensing, 2022, 14(7): 1741.
- [12] WANG N, LYU H M, ZHENG ZH Q, et al. Leveraging semantic graphs for efficient and robust LiDAR SLAM[J]. ArXiv preprint arXiv:2503.11145, 2025.
- [13] JIA Y P, WANG T, CAO F K, et al. TRLO: An efficient LiDAR odometry with 3-D dynamic object tracking and removal[J]. IEEE Transactions on Instrumentation and Measurement, 2025, 74: 1-10.
- [14] WANG ZH B, ZHANG ZH H, KANG X, et al. DORLINS: Dynamic objects removal LiDAR-inertial SLAM based on ground pseudo occupancy[J]. IEEE Sensors Journal, 2023, 23(20): 24907-24915.
- [15] QIAN CH L, XIANG ZH H, WU ZH R, et al. RF-LIO: Removal-first tightly-coupled LiDAR inertial odometry in high dynamic environments[C]. 2021 IEEE/RSJ International Conference on Intelligent Robots and Systems, 2021: 4421-4428.
- [16] 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: 4003-4009.
- [17] WANG T, SU Y, SHAO SH L, et al. GR-Fusion: Multi-sensor fusion SLAM for ground robots with high robustness and low drift[C]. 2021 IEEE/RSJ International Conference on Intelligent Robots and Systems, 2021: 5440-5447.
- [18] 胡悦, 李旭, 徐启敏, 等. 卫星拒止环境下基于因子图的智能车可靠定位方法[J]. 仪器仪表学报, 2021, 42(11): 79-86.
HU Y, LI X, XU Q M, et al. Reliable positioning method of intelligent vehicles based on factor graph in GNSS-denied environment[J]. Chinese Journal of Scientific Instrument, 2021, 42(11): 79-86.
- [19] LIU Y, JIAN ZH ZH, ZHENG SH T, et al. Range-SLAM: Ultra-wideband-based smoke-resistant real-time localization and mapping[J]. ArXiv preprint arXiv: 2409.09763, 2024.
- [20] PAN T X, SONG J J, LI K, et al. A SLAM method for

indoor degradation environment based on LiDAR/IMU/UWB fusion[C]. 2024 IEEE International Conference on Control Science and Systems Engineering, 2024: 436-441.

- [21] KUANG Y J, HU T F, OUYANG M J, et al. Tightly coupled LiDAR/IMU/UWB fusion via resilient factor graph for quadruped robot positioning [J]. Remote Sensing, 2024, 16(22): 4171.
- [22] WANG X Y, GAO F ZH, HUANG J C, et al. UWB/LiDAR tightly coupled positioning algorithm based on ISSA optimized particle filter[J]. IEEE Sensors Journal, 2024, 24(7): 11217-11228.
- [23] SUN J, SUN W, ZHANG G W, et al. CT-UIO: Continuous-time UWB-inertial-odometer localization using non-uniform B-spline with fewer anchors[J]. ArXiv preprint arXiv:2502.06287, 2025.
- [24] ZHANG T SH, YUAN M, WEI L F, et al. MR-ULINS: A tightly-coupled UWB-LiDAR-inertial estimator with multi-epoch outlier rejection [J]. IEEE Robotics and Automation Letters, 2024, 9(12): 11786-11793.
- [25] NGUYEN T M, YUAN SH H, CAO M Q, et al. VIRAL SLAM: Tightly coupled camera-IMU-UWB-LiDAR SLAM[J]. ArXiv preprint arXiv:2105.03296, 2021.
- [26] 乔卉卉, 赵二贤, 郝如江, 等. 基于注意力机制与多源信息融合的变工况轴承故障诊断[J]. 仪器仪表学报, 2024, 45(9): 120-130.
- QIAO H H, ZHAO ER X, HAO R J, et al. Attention mechanism and multi-source information fusion-based method forbearing fault diagnosis under variable operating conditions[J]. Chinese Journal of Scientific Instrument, 2024, 45(9): 120-130.

作者简介



徐启敏 (通信作者), 2011 年于东南大学获得学士学位, 2014 年于东南大学获得硕士学位, 2018 年于东南大学获得博士学位, 现为东南大学副教授, 主要研究方向为多源融合定位、智能感知。

E-mail: jimmy. xqm@seu. edu. cn

Xu Qimin (Corresponding author) received his B. Sc. ,

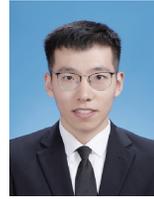
M. Sc. , and Ph. D. degrees all from Southeast University in 2011, 2014 and 2018 respectively. He is currently an associate professor in Southeast University. His main research interests include Multi source fusion positioning and Intelligent perception.



姚钰欢, 2021 年于南京邮电大学获得学士学位, 现为东南大学硕士研究生, 主要研究方向为多源融合定位。

E-mail: yolo_yao@seu. edu. cn

Yao Yuhuan received his B. Sc. degree from Nanjing University of Posts and Telecommunications in 2021. He is a master's student in Southeast University. His main research interest includes multi source fusion positioning.



赵鑫, 2020 年于中北大学获得学士学位, 2024 年于东南大学获得硕士学位, 现为智元机器人 SLAM 算法工程师, 主要研究方向为定位与建图、传感器标定。

E-mail: zhaoxin24_alex@163. com

Zhao Xin received his B. Sc. degree from North University of China in 2020, received his M. Sc. degree from Southeast University in 2024, He is currently a SLAM algorithm engineer in Zhiyuan Robot. His main research interests include positioning and mapping, and sensor calibration.



胡悦, 2015 年于合肥工业大学获得学士学位, 2018 年于合肥工业大学获得硕士学位, 2024 年于东南大学获得博士学位, 现为国防科技大学第六十三研究所助理研究员, 主要研究方向为多模态融合感知与计算、智能无人系统。

E-mail: hyfut@163. com

Hu Yue received his B. Sc. and M. Sc. degrees both from Hefei University of Technology in 2015 and 2018, and his Ph. D. degree from Southeast University in 2024. He is currently an assistant researcher in The 63rd Research Institute of National University of Defense Technology. His main research interests include multimodal fusion perception and computing and intelligent unmanned system.