

# 动态环境中检测优先的紧耦合激光-视觉-惯性 SLAM 系统<sup>①</sup>



李忠育, 段中兴

(西安建筑科技大学 信息与控制工程学院, 西安 710055)

通信作者: 段中兴, E-mail: [zhx\\_duan@xauat.edu.cn](mailto:zhx_duan@xauat.edu.cn)

**摘要:** 针对动态环境给同步定位与建图 (SLAM) 带来的挑战, 本文提出一种融合激光雷达、相机和惯性测量单元 (IMU) 的检测优先紧耦合激光-视觉-惯性 SLAM 系统. 首先, 通过图像与点云信息融合获取带语义标签的点云聚类结果; 其次, 应用跟踪算法获取目标的运动状态信息; 继而利用被追踪的动态目标剔除冗余特征点; 最终采用因子图联合优化 IMU 预积分量, 并实现系统内激光里程计与视觉里程计的紧耦合. 为验证所提 SLAM 框架性能, 在公开数据集 (KITTI 与 UrbanNav) 和实际场景数据上进行了测试. 实验结果表明: 在公开数据集的高动态场景和普通场景中, 相较于 LeGO-LOAM、LIO-SAM 和 LVI-SAM 算法, 本算法的均方根误差 (RMSE) 分别降低了 44.56% (4.47 m) 和 4.15% (4.62 m). 通过实际场景数据测试, 该算法有效降低了动态物体对地图构建的直接影响.

**关键词:** 动态环境; SLAM 运动检测; 多传感器融合; 检测与跟踪

引用格式: 李忠育, 段中兴. 动态环境中检测优先的紧耦合激光-视觉-惯性 SLAM 系统. 计算机系统应用, 2026, 35(2): 103-122. <http://www.c-s-a.org.cn/1003-3254/10070.html>

## Detection-first Tightly-coupled LiDAR-visual-inertial SLAM System for Dynamic Environments

LI Zhong-Yu, DUAN Zhong-Xing

(College of Information and Control Engineering, Xi'an University of Architecture and Technology, Xi'an 710055, China)

**Abstract:** To address the challenges posed by dynamic environments to simultaneous localization and mapping (SLAM), this study proposes a detection-first tightly-coupled LiDAR-visual-inertial SLAM system that integrates a LiDAR, a camera, and an inertial measurement unit (IMU). First, semantically labeled point-cloud clusters are obtained through the fusion of images and point-cloud information. Then, a tracking algorithm is used to acquire the motion state information of targets. Subsequently, the tracked dynamic targets are utilized to eliminate redundant feature points. Finally, a factor graph is adopted to jointly optimize IMU pre-integration and achieve tight coupling between LiDAR and visual odometry. To validate the performance of the proposed SLAM framework, experiments are conducted on both public datasets (KITTI and UrbanNav) and real-world data. Experimental results demonstrate that in highly dynamic and normal scenarios in public datasets, compared with the LeGO-LOAM, LIO-SAM, and LVI-SAM algorithms, the proposed algorithm reduces the root mean square error (RMSE) by 44.56% (4.47 m) and 4.15% (4.62 m), respectively. Real-world testing confirms that the algorithm effectively mitigates the direct impact of dynamic objects on map construction.

**Key words:** dynamic environment; motion detection in SLAM; multi-sensor fusion; detection and tracking

① 基金项目: 国家重点研发计划 (2022YFC3203605)

收稿时间: 2025-07-05; 修改时间: 2025-08-13; 采用时间: 2025-09-05; csa 在线出版时间: 2025-12-26

CNKI 网络首发时间: 2025-12-29

## 1 引言

同步定位与建图 (SLAM) 技术已成为人工智能领域不可或缺的关键技术, 在信息爆炸时代发挥着重要作用<sup>[1]</sup>. 随着机器人技术的快速发展, 目前已有多种适用于室外场景的定位方法, 如全球定位导航系统<sup>[2]</sup>、激光里程计<sup>[3-5]</sup>等. 然而, 单一传感器系统仅适用于特定场景, 难以适应复杂多变的工作环境. 多传感器信息融合技术可有效应用于不同场景, 但由于传感器多样性和环境复杂性, 在动态场景影响定位精度与建图质量、传感器信息融合不充分等方面仍存在挑战<sup>[6,7]</sup>.

在激光 SLAM 研究方面, Zhang 等人<sup>[8]</sup>提出基于三维激光雷达的 LOAM 算法, 该算法通过曲率特征提取角点特征与面特征, 并在相邻帧间构建点-线特征约束与点-面特征约束以实现激光里程计解算. Shan 等人<sup>[9]</sup>在 Zhang 等人<sup>[8]</sup>的研究基础上提出 LeGO-LOAM, 通过分离地面点云与非地面点云, 并在两类点云上分别构建点-线、点-面约束. 文献<sup>[10]</sup>提出一种激光-惯性紧耦合 SLAM 框架, 借鉴视觉 SLAM 滑动窗口方法对数据进行优化以获得更高精度. Shan 等人<sup>[11]</sup>进一步开发的 LIO-SAM 基于因子图框架, 融合了激光里程计与 IMU 预积分量, 并引入 GPS 因子以提升激光里程计精度<sup>[12]</sup>. Nguyen 等人<sup>[13]</sup>提出的 SLICT2 系统构建了连续时间激光-惯性里程计 (CT-LIO), 其线性求解器相比原系统非线性求解器具有更少的迭代次数, 并通过迭代过程中的相关性计算提升性能.

单一激光 SLAM 系统的失效会显著影响建图与定位性能. 随着多传感器融合技术的发展, 激光-视觉-IMU 紧耦合系统应运而生<sup>[14]</sup>. Li 等人<sup>[15]</sup>提出 HCTO 方法, 通过融合激光雷达与 IMU 改进可穿戴移动测绘系统 (WMS), 利用 IMU 测量人体运动模式以提升头戴式 WMS 的稳定性. 该团队进一步提出多源融合方法 (PTC)<sup>[16]</sup>, 将高精度光纤 IMU 数据与激光匹配约束相结合, 增强了 GNSS 拒止环境下紧凑型头盔激光扫描 (HLS) 系统的建图能力. Liu 等人<sup>[17]</sup>提出融合相机、激光雷达、IMU 与 GPS 的新型 SLAM 框架, 通过 Complex-YOLO 目标检测将语义信息融入建图过程以提升精度. 该团队还提出基于金字塔 IMU 预测的光流跟踪轻量化 SLAM 方法<sup>[18]</sup>, 通过跟踪非关键帧并压缩关键帧描述符, 实现小数据传输量的高精度定位. GR-Fusion<sup>[19]</sup>利用相机、IMU、激光雷达、全球导航卫星系统 (GNSS) 及编码器构建滑动窗口因子图模型, 优化机器人全局

状态. Shan 等人<sup>[20]</sup>提出的 LVI-SAM 包含两个独立子系统: 视觉-惯性系统 (VIS) 和激光-惯性系统 (LIS), VIS 基于 Vins-mono<sup>[21,22]</sup>, LIS 则采用 LIO-SAM 框架.

然而, 上述 SLAM 系统均依赖静态环境假设, 这与实际应用场景存在矛盾. 动态环境中运动物体上的特征点会严重影响 SLAM 性能, 而准确分割运动物体是有效剔除动态特征的前提. 当前 SLAM 系统中的运动物体分割方法可分为两类: 第 1 类利用动态与静态物体的运动差异, 如视觉 SLAM 通常通过多幅图像的极几何约束判断特征或物体的动静状态; 第 2 类将语义分割网络与运动差异相结合, 通过语义分割网络对图像或点云进行动静类别标注以训练网络. 因此, 结合传统方法与语义网络实现运动物体的精确分割, 已成为当前动态特征剔除的主流技术路径.

首先, 传统方法中的运动物体分割依赖于动态与静态物体之间的运动差异. Fan 等人<sup>[23]</sup>提出基于动态特征点深度信息变化的双重约束条件来确定动态物体区域. Sun 等人<sup>[24]</sup>开发了一种通过跟踪实现动态物体识别的分割策略, 随后文献<sup>[25]</sup>提出的运动剔除方法在高动态环境中表现出优异性能. Wang 等人<sup>[26]</sup>通过集成基础矩阵, 解决了文献<sup>[27]</sup>中存在的过分割与欠分割问题. 然而, 这些运动物体分割方法在特定条件下可能出现性能退化, 例如当相机或激光雷达发生剧烈运动时, 即使视场重叠区域很小也会导致显著的观测差异.

其次, 现有基于激光雷达的方法通常在后期处理阶段对点云地图进行分割、剔除等相关操作. 这类方法往往采用离线处理模式, 且依赖于预先构建的地图. 部分方法采用耗时的体素射线投射技术<sup>[28]</sup>, 需要精确对齐位姿以清除密集的地面激光扫描数据. 为减轻计算负担, 研究者提出基于可见性的方法<sup>[29]</sup>, 该方法将点云与狭窄视场 (如窄锥形区域) 内的地图点进行关联. Pagad 等人<sup>[30]</sup>提出基于占据栅格地图的动态点剔除方法, 先通过目标检测构建占据地图, 再采用体素遍历法去除运动物体. 虽然这类基于地图的方法能区分运动物体与背景, 但需要预先构建并清理地图, 因此难以实现实时在线操作. 在利用激光点云实现动态物体检测方面, Wang 等人<sup>[31]</sup>基于 LeGO-LOAM 框架, 通过聚类获取潜在目标. 为提高定位精度, 该方法利用前后帧变换矩阵剔除运动物体, 实际环境测试中最大定位误差小于 1 m, 平均误差低于 0.1 m. 然而由于激光数据固有的稀疏性, 该方法仍易产生误判. RF-LIO<sup>[32]</sup>在 LIO-SAM

基础上提出的动态 SLAM 框架, 通过将点云转换为深度图像, 并基于前后帧匹配实现动态物体检测。

另一方面, 研究者们探索了语义信息与运动差异相结合的方法以提升运动物体分割效果。Bescos 等人<sup>[33]</sup>采用神经网络与多视图几何算法实现运动物体分割, 但该算法耗时严重。Yu 等人<sup>[34]</sup>利用 SegNet 进行物体分割, 并基于极线约束从全部特征点中检测动态点, 显著降低了动态物体对 RGB-D SLAM 的影响。Cui 等人<sup>[35]</sup>提出融合语义信息与极几何约束的动态物体检测方法, 改善了 ORB-SLAM 系统在动态环境中的性能, 但未考虑相机移动时光流产生的噪声干扰。Wang 等人<sup>[36]</sup>将全卷积实例感知语义分割网络集成至 SLAM 系统, 提出基于重投影误差的运动物体分割方法。

为提升动态场景下的定位建图质量与多传感器信息耦合度, 本文提出一种检测优先的紧耦合激光-视觉-惯性 SLAM 系统。本研究的贡献主要体现在以下方面。

(1) 提出了一种基于激光雷达、相机与惯性测量单元的紧耦合 SLAM 系统, 该系统将视觉里程计深度

集成至因子图优化框架中。

(2) 针对动态物体对里程计前端的干扰问题, 提出一种基于图像-激光点云融合的动态目标检测与跟踪算法, 该算法能有效缓解运动物体对位姿估计的影响。

本文第 2 节阐述算法整体架构与融合检测方法。第 3 节详述实验数据集、参数配置及评价指标, 对比经典算法并分析实验结果。第 4 节给出研究结论。

## 2 检测优先的激光-视觉-惯性 SLAM 系统

### 2.1 系统概述

图 1 展示了本文提出的面向动态环境的激光-视觉-惯性系统架构。该系统接收三维激光雷达、单目相机和 IMU 的输入数据, 其前端以 IMU 预积分为核心, 实现激光里程计与视觉里程计的紧耦合。前端里程计采用基于特征匹配的残差构建方法, 并通过维护局部地图保障系统实时性。针对动态环境对 SLAM 静态假设的挑战, 本系统通过识别与跟踪机制对点云和视觉特征进行优先级处理, 从而降低动态特征对定位建图的影响。

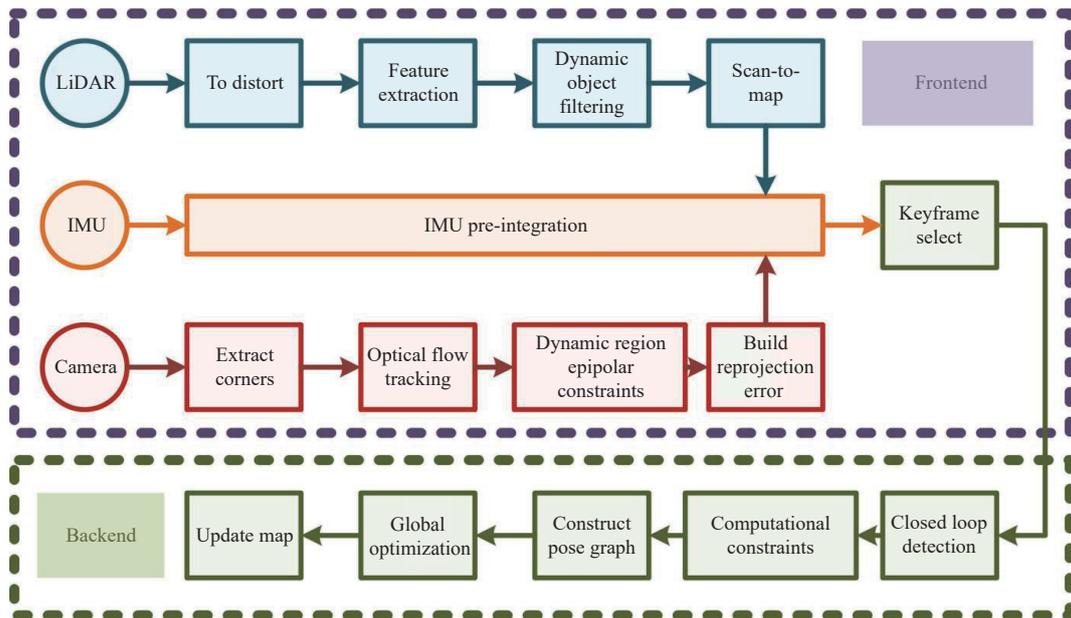


图 1 本文所提出的 SLAM 系统结构

### 2.2 目标检测与状态判定

本文针对动态场景的处理策略主要基于多传感器融合的目标检测与跟踪技术。如图 2 所示 (以 KITTI 设备为例), 目标检测与跟踪过程与 SLAM 系统并行执行, 其输出结果最终用于 SLAM 前端的数据预处理。具体而言, 通过激光雷达与相机的数据融合, 分别获取对

应的聚类结果, 并利用 IMU 预积分速度作为跟踪基准速度, 实现对物体运动状态的跟踪与判定。

本文提出的融合目标检测可分为两个阶段实现 (流程见图 3)。第 1 阶段通过融合图像语义信息与点云聚类信息, 获得带语义标签的点云聚类结果; 第 2 阶段基于匈牙利算法, 结合距离与语义信息进行目标跟踪。

最终根据跟踪目标序列与里程计信息, 判定目标物体是否处于运动状态。

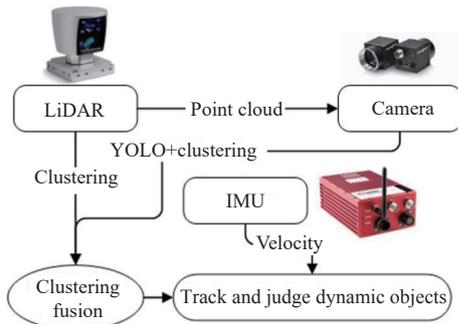


图2 多传感器目标跟踪示意图

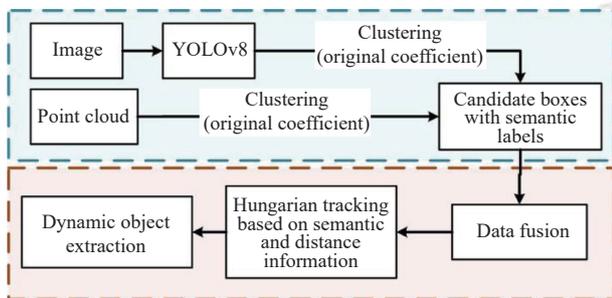


图3 多传感器融合目标检测与跟踪

基于目标检测结果的数据融合关键在于三维边界框的精确拟合. 本文采用基于图像包络线的边界框拟合方法, 具体实现步骤如下。

- (1) 将聚类后的点云投影至二维平面;
- (2) 利用图像包络线求解最小凸包;
- (3) 提取凸包轮廓的最小外接矩形;

(4) 以矩形长宽作为三维边界框的长宽, 根据点云簇最高点与最低点的差值计算边界框高度;

(5) 计算矩形框与车体坐标系前方的夹角, 获得目标方位角。

基于匈牙利匹配的目标跟踪流程如图4所示, 具体实现细节如下。

- (1) 根据融合目标检测结果, 获取当前帧边界框  $a_i \in A (i = 1, 2, \dots, n)$  与前一帧边界框  $b_j \in B (j = 1, 2, \dots, m)$ ;
- (2) 遍历当前帧所有检测结果, 计算当前边界框  $a_i$  与前一帧各边界框  $b_j$  的中心距  $Dis(a_i, b_j)$ , 获得最小距离  $minDis = Dis(a_p, b_q)$ ;
- (3) 若  $b_q$  首次被选为最优匹配 (即首次计算到该最小距离值), 则跳过步骤 (4) 执行步骤 (5);
- (4) 若  $b_q$  非首次匹配, 且存在已有最佳匹配 ( $a_1$ ,

$b_q$ ), 则当  $Dis(a_p, b_q) < Dis(a_1, b_q)$  且二者语义信息相同时执行步骤 (5), 否则返回步骤 (2) 进行下一轮判断;

(5) 当  $minDis$  小于设定阈值  $T_0 (minDis < T_0)$  且  $b_q$  在上一帧跟踪过程中已有跟踪信息时, 将  $b_q$  的 tracking\_id 与 label 赋予  $a_p$ , 否则生成新跟踪对象并为  $a_p$  分配新跟踪编号。

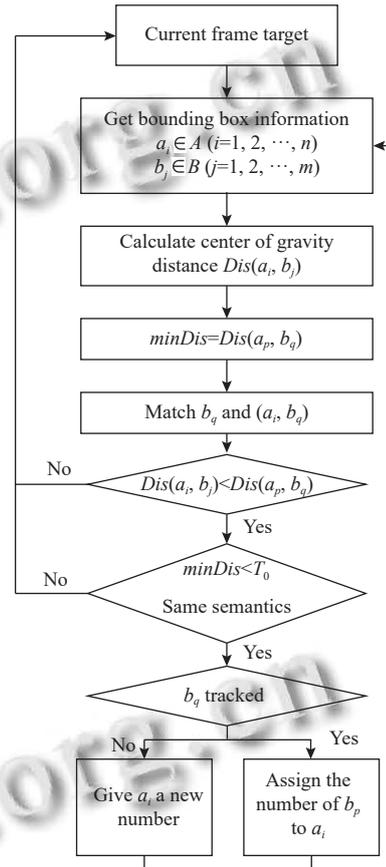


图4 目标跟踪与判定流程

通过上述步骤中语义与距离的叠加判定, 可在聚类结果中搜索前后帧间关联度最高的目标, 有效降低误检与漏检的发生率. 在 SLAM 系统中, IMU 为传感器系统提供高频实时位姿估计, 且在短时间内具有较高精度. 设  $t_1$  时刻传感器系统在全局坐标系中的位姿为  $T_{b1}$ , 被检测物体在传感器坐标系中的位姿为  $T_{obj1}$ ; 相邻时刻  $t_2$  的传感器系统位姿为  $T_{b2}$ , 同一被追踪物体的位姿为  $T_{obj2}$ . 则该物体在全局坐标系中的位姿可表示为:

$$\begin{cases} T_1 = T_{b1}T_{obj1} \\ T_2 = T_{b2}T_{obj2} \end{cases} \quad (1)$$

则物体在两个时刻的相对位姿可表示为:

$$\Delta T = T_1^{-1} T_2 \quad (2)$$

当物体相对位姿对应的轴角 $\Delta\theta$ 或相对位移 $\Delta t$ 连续两次超过设定阈值时,其状态将被更新为“动态”;反之,若角度 $\theta$ 与相对位移 $\Delta t$ 均满足静态要求,则物体状态更新为“静态”.首次检测到的物体默认定义为“静态”状态.通过上述对图像与点云的处理操作,系统在 ROS 框架下生成包括:非目标障碍物位置、关注目标的语义标签、精确坐标、跟踪编号及动静状态等一系列信息.最终,被追踪的动态目标将实时保存至后续 SLAM 流程,以便执行相关预处理操作.

### 2.3 IMU 预积分与状态初始化

本文中系统状态量的定义为:

$$x_i = [p_i, v_i, q_i, b_i]^T \quad (3)$$

其中,  $p$  表示位置,  $v$  表示速度,  $q$  表示姿态,  $b$  表示惯性测量单元 IMU 的偏差.该惯性测量单元的观测方程为:

$$\tilde{\omega} = \omega^b + b^{\text{gyro}} + n^{\text{gyro}} \quad (4)$$

$$\tilde{a}^b = q_{b\omega}(a^\omega + g^\omega) + b^a + n^a \quad (5)$$

其中, gyro 表示陀螺仪,  $a$  表示加速度计,  $\omega$  代表世界坐标系,  $b$  表示 IMU 本体坐标系.  $\omega$  和  $a$  为真实值, IMU 测量值记作  $\tilde{\omega}$  和  $\tilde{a}$ .实际测量值受重力加速度、偏差及高斯白噪声共同影响,其 IMU 预积分对应的状态残差可表示为:

$$e(x_i, x_j) = \begin{bmatrix} r_p \\ r_v \\ r_q \\ r_{b^a} \\ r_{b^g} \end{bmatrix} = \begin{bmatrix} q_{b_i\omega} \left( p_{\omega b_j} - p_{\omega b_i} - v_i^\omega \Delta t + \frac{1}{2} g^\omega \Delta t^2 \right) - \alpha_{b_i b_j} \\ q_{b_i\omega} \left( v_j^\omega - v_i^\omega + g^\omega \Delta t \right) - \beta_{b_i b_j} \\ 2 \left[ q_{b_j b_i} \otimes \left( q_{b_i \omega} \otimes q_{\omega b_j} \right) \right]_{xyz} \\ b_j^a - b_i^a \\ b_j^g - b_i^g \end{bmatrix} \quad (6)$$

其中,  $g$  为矢量重力加速度,  $\alpha_{b_i b_j}$ 、 $\beta_{b_i b_j}$  和  $q_{b_i b_j}$  分别表示位置、速度与姿态的离散预积分量.本文采用定积分中值法对不同时刻间的物理量进行积分计算,并将 IMU 预积分约束纳入整体因子图,与视觉、激光数据

进行联合优化.

相对位姿  $\Delta T$  可进一步转换为轴角与位移.假设  $\Delta T$  对应的平移量为  $\Delta\tau$ 、旋转量为  $\Delta R$ , 根据罗德里格斯公式可得:

$$\begin{aligned} \text{tr}(\Delta R) &= \cos\theta \text{tr}(\Delta\tau) + (1 - \cos\theta) \text{tr}(n n^{\Delta T}) + \sin\theta \text{tr}(\hat{n}) \\ &= 1 + 2 \cos\theta \end{aligned} \quad (7)$$

其中,  $n$  为旋转轴对应的单位向量,  $\theta$  为旋转角度, 因此可得:

$$\theta = \arccos \frac{\text{tr}(R) - 1}{2} \quad (8)$$

当角度  $\theta$  或相对位移  $\Delta t$  连续两次超过阈值时,物体状态将被更新为动态;反之,若角度  $\theta$  与相对位移  $\Delta t$  同时满足静态条件,则更新为静态状态.首次检测到的物体默认标记为静态.

综合上述对图像与点云的全部处理操作,系统最终将在 ROS 框架下生成一系列可用信息,包括:非目标障碍物位置、关注目标的语义标签、精确坐标、跟踪编号及动静状态等信息.被追踪的动态目标将实时同步保存,用于后续同步定位与建图流程.

### 2.4 激光测距

激光里程计采用 LOAM 系列广泛使用的边沿与平面特征作为基准.当接收到新点云时,系统逐层计算扫描点云的曲率:将曲率较大的点归类为边沿点集,曲率较小的点归类为平面点集.假设在  $k$  帧中已找到边沿特征点  $i$  的对应边特征  $[j, l]$ , 则点  $i$  到对应直线的距离  $d_E$  可表示为:

$$d_E = \frac{\left| (\bar{p}_{(k,j)}^l - p_{(k-1,j)}^l) \times (\bar{p}_{(k,l)}^l - p_{(k-1,l)}^l) \right|}{\left| p_{(k-1,j)}^l - p_{(k-1,l)}^l \right|} \quad (9)$$

其中,  $\bar{p}_{(k,j)}^l$  表示通过待求解的相对位姿  $R$  和  $t$  转换至  $k-1$  帧坐标系下的第  $k$  帧特征点坐标,  $p_{(k-1,j)}^l$  为  $k-1$  帧中匹配的特征点坐标.同理,假设在  $k$  帧中已找到平面特征点  $i$  的对应平面特征  $[j, l, m]$ , 则该平面特征点到对应平面的距离  $d_H$  可表示为:

$$d_H = \frac{\left| (\bar{p}_{(k,j)}^l - p_{(k-1,j)}^l) \cdot \left( (p_{(k-1,j)}^l - p_{(k-1,l)}^l) \times (p_{(k-1,j)}^l - p_{(k-1,m)}^l) \right) \right|}{\left| (p_{(k-1,j)}^l - p_{(k-1,l)}^l) \times (p_{(k-1,j)}^l - p_{(k-1,m)}^l) \right|} \quad (10)$$

其中,  $\bar{p}_{(k,j)}^l$  表示经过坐标变换的第  $k$  帧特征点坐标, 因

此最终的总误差函数可表示为:

$$\min_{T_k} \left\{ d = \sum_{i=1} d_{Ei} + \sum_{i=1} d_{Hi} = d(\bar{p}^l_{(k,i)}) \right\} \quad (11)$$

融合目标检测系统已逐帧生成检测结果, 包含边界框范围及动静状态. 本文基于三维边界框的动态目标跟踪机制, 滤除点云数据中的动态目标, 从而仅保留静态环境点云数据. 该算法可有效解决动态环境带来的位姿估计难题.

### 2.5 视觉里程计

视觉特征检测采用角点检测器, 并通过 Kanade-Lucas-Tomasi (KLT) 算法进行跟踪. 视觉-惯性系统 (VIS) 完成初始化后, 视觉里程计将注册为激光雷达帧, 并获取用于特征深度估计的稀疏深度图像.

基于深度学习网络的目标检测结果, 可将图像划分为动态目标区域与静态背景区域 (如图 5(a) 所示). 需特别说明的是, 动态目标区域内会存在背景点等静态特征, 而静态背景区域也可能包含动态特征或匹配误差特征. 假设静态背景区域的匹配点集为  $P_{B1}$  与  $P_{B2}$ , 动态目标区域的匹配点集为  $P_{D1}$  与  $P_{D2}$ , 显然静态背景区域中合格特征点的比例更高. 因此, 首先依托该区域观测值构建极线几何约束, 用于后续运动一致性检验. 极线约束原理如图 5(b) 所示.

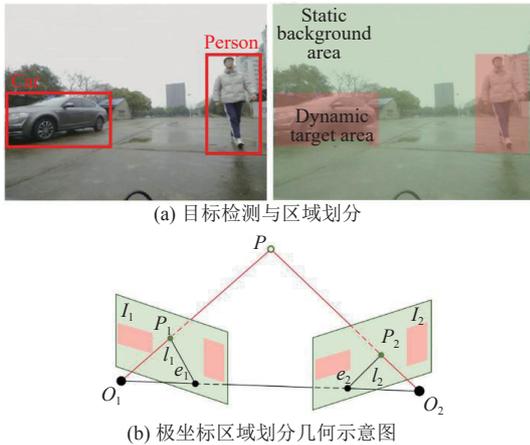


图 5 基于目标检测的特征点状态判定方法

在多视图几何中, 具有相同观测目标的图像间存在极几何约束.  $O$ 代表相机的光心,  $P_1$ 和 $P_2$ 是一组匹配点,  $l$ 是对应匹配点的极线. 假设观测点的齐次坐标分别为:

$$\begin{cases} P_1 = \begin{bmatrix} u_1 & v_1 & 1 \end{bmatrix}^T \\ P_2 = \begin{bmatrix} u_2 & v_2 & 1 \end{bmatrix}^T \end{cases} \quad (12)$$

根据极线约束方程, 可得:

$$P_2^T K^{-T} \hat{t} R K^{-1} P_1 = 0 \quad (13)$$

其中,  $K$ 表示相机的内部参数,  $R$ 代表从 $O_1$ 到 $O_2$ 的旋转矩阵,  $\hat{t}$ 表示平移向量. 在极线几何中, 基础矩阵 $F_f$ 可表示为:

$$F_f = K^{-T} \hat{t} R K^{-1} \quad (14)$$

$$P_2^T F_f P_1 = 0 \quad (15)$$

理想情况下, 当对极约束恰好成立时, 第 2 个观测点 $P_2$ 应完全落在极线上. 然而, 误匹配点和动态点并不满足运动一致性. 当观测点被重投影至第 2 幅图像时, 便会产生极线偏差. 设该偏移距离为:

$$D = \frac{|P_2^T F_f P_1|}{\sqrt{l_x^2 + l_y^2}} \quad (16)$$

其中,  $l_x$ 和 $l_y$ 表示极线 $l_2$ 的参数. 采用 RANSAC 原理可有效计算出正确的基础矩阵 $F_f$ . 具体步骤为: 首先从静态背景区域匹配点集 $P_{B1}$ 和 $P_{B2}$ 中随机选取 8 组匹配点, 通过八点法估算基础矩阵 $F_f$ ; 随后计算 $P_{B2}$ 中所有匹配点此时的极线距离, 并设定距离阈值以区分内点与外点. 将此过程迭代 $k$ 次, 当距离误差总和小于设定阈值或内点比例超过 90% 时停止迭代, 输出最终的基础矩阵 $F_f$ .

基于基础矩阵的计算结果与式 (16), 可验证动态目标区域内的匹配点集 $P_{D1}$ 和 $P_{D2}$ . 若距离误差过大, 则判定其不满足运动一致性条件, 并将其归类为动态点. 经判定为动态点与外点的特征将被移出系统, 不再参与后续的光流跟踪与位姿估计.

### 2.6 紧耦合策略

后端将状态估计问题建模为因子图. 本文在因子图中新增视觉因子, 通过该因子图实现全局位姿优化与更新, 从而达到系统紧耦合的效果. 若直接使用每帧激光雷达与图像的观测构建误差, 将导致后端优化数据量过大的问题. 为此, 我们定制了雷达与图像关键帧策略以解决该问题.

(1) 激光关键帧筛选策略: 当机器人姿态变化量相对于前一状态 $x_i$ 超过设定阈值时, 将当前激光帧选为关键帧. 系统将保存关键帧的位姿、时间戳、原始点云及特征点云等关键信息以便后续检索, 同时丢弃两个关键帧之间的中间激光帧数据. 其中, 平移量与旋转

量阈值分别设置为 1.5 m 和 15°.

(2) 视觉关键帧筛选策略: 当图像帧的视差超过设定阈值, 或跟踪的特征点数量低于阈值时, 系统将该图像帧选为关键帧. 由于视觉关键帧信息不参与地图构建, 其筛选无需依赖位姿变化量. 特征点数量的双阈值分别设置为总特征点数的 10% 与 25%.

## 2.7 因子图模型

本文的因子图模型包含 4 类误差因子: IMU 预积分因子、激光因子、视觉因子以及回环检测因子. 通过融合上述多源因子构建复合约束, 由于多传感器同步参与状态估计, 系统即使在部分退化场景下仍能保持连续运行, 同时有效抑制动态物体导致的定位畸变与地图模糊现象. 本文提出的 SLAM 系统架构如图 6

所示.

如图 6 所示, 该因子图完整呈现了 SLAM 系统维护的后端架构, 包含 4 类误差因子: IMU 预积分因子、激光因子、视觉因子及回环检测因子. 作为系统核心, IMU 预积分因子始终参与机器人状态估计过程, 以高频输出位姿间的相对约束, 在剧烈运动时显著提升状态估计精度. 激光因子作为主环境感知传感器, 通过提供精确测距与尺度信息, 在多数场景下可实现精准位姿估计. 视觉因子作为辅助传感器, 当激光里程计发生退化时可临时替代其位姿约束功能, 从而保障 IMU 的高持续有效性. 回环检测因子则基于回环检测约束, 通过将当前帧与回环帧间最近点迭代估计的二元约束加入因子图, 有效修正误差累积.

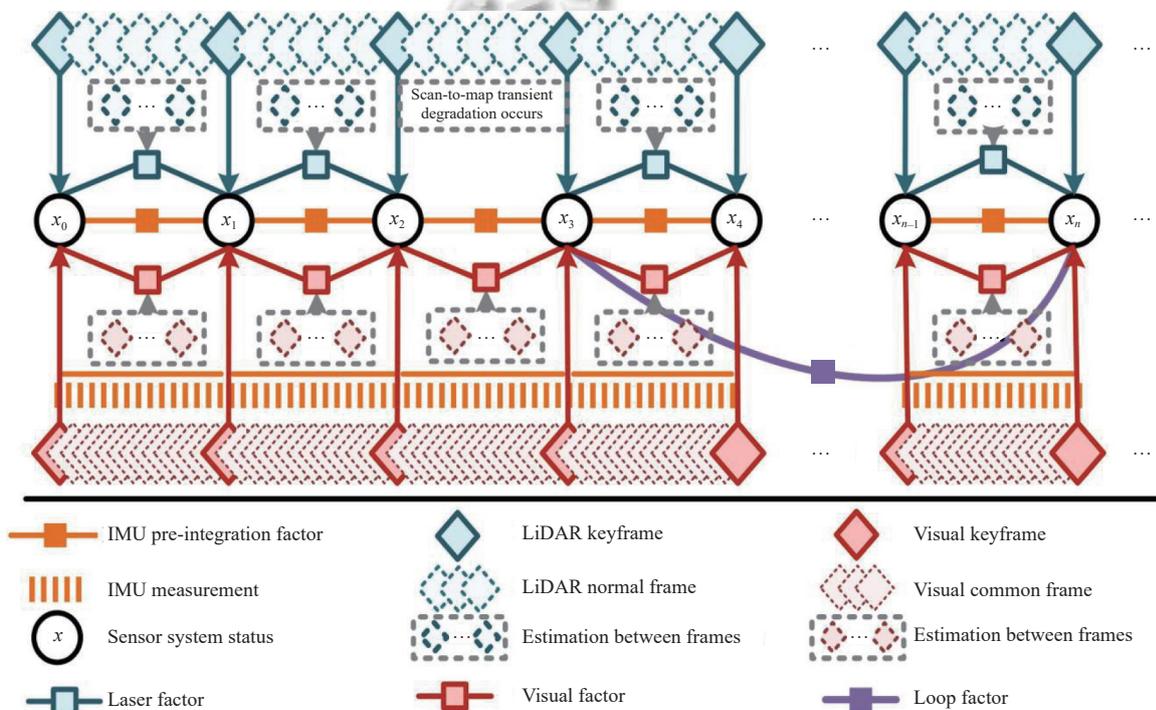


图 6 本文提出的基于因子图与 4 类因子的 SLAM 系统

## 2.8 回环闭合

视觉里程计采用词袋模型 (DBoW2) 作为回环闭合的判定条件, 而激光里程计则通过 ICP 算法匹配历史关键帧来实现回环检测.

## 2.9 时空同步

ROS 中存在两种时间戳: 一种为 ROS 系统时间戳 (ROS time), 另一种为外部硬件设备 (如相机、激光雷达等) 的时间戳 (亦称硬件时间). ROS 时间戳采用浮点数表示, 单位为 s, 其计算基准为 1970 年 1 月 1 日

UTC 00:00:00. 该时间戳在整个 ROS 系统中具有全局唯一性, 当系统内节点需进行时间同步时, 可将 ROS 时间戳作为统一标准实现节点间同步. 硬件时间戳由外部设备提供, 既可以是相对于设备启动时间或固定时间点的相对时间戳, 也可以是相对于固定时间基准的绝对时间戳. 由于外部设备与 ROS 系统属于不同时钟体系, 二者可能存在时钟差异, 因此需要通过时间戳转换实现硬件时间戳与 ROS 时间戳间的相互转化, 以支持时间同步、数据融合等操作. 本文研究场景中激

光雷达与相机均未采用外部时钟(如GNSS)触发.为  
保证时间体系的一致性,我们依据机器人操作系统的  
内置时间系统为不同传感器数据分配时间信息.单点  
时间戳可从传感器驱动中获取,若无法获取,亦可通过  
方位角差值计算获得.在将激光雷达点云、相机及IMU  
的时间基准统一至ROS时间系统后,即可执行时间对  
齐操作.鉴于不同传感器的启动时间与采样频率存在  
差异,本文以相机频率为基准,对雷达数据进行拆分重

组,将相邻图像时间戳之间的点云按时间戳重新封装  
为一帧点云数据,如图7所示,虚线表示相机时间戳,  
实线表示激光雷达时间戳,星号标记表示相机采集数  
据对应的时间戳.图像采集可视为瞬时完成,而单帧激  
光雷达点云数据具有连续性特征.本文将单帧激光雷  
达点云数据去畸变至该帧的结束时刻,如图8所示.具  
体操作可参考FAST-LIO2方法,经处理后即可认为该  
帧激光雷达点云数据与相机实现同步采集.

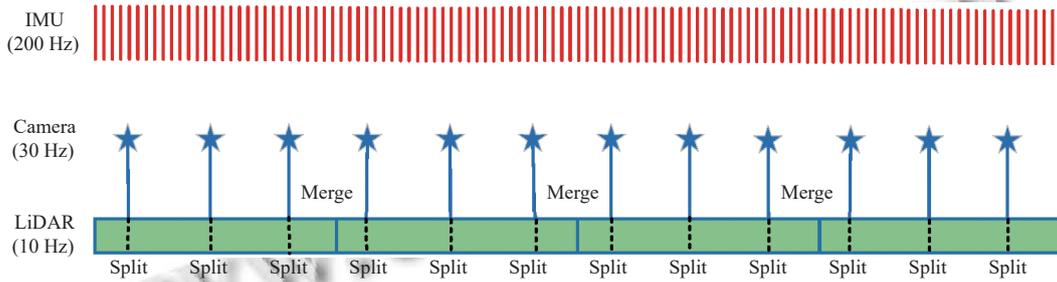


图7 时间对齐:激光雷达点云数据基于相机时间戳的拆分-融合过程

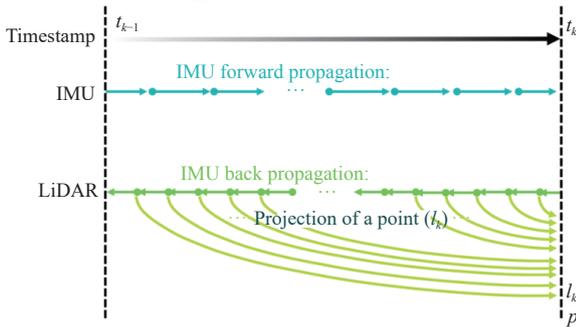


图8 将点云对齐至该帧的末端时刻

通过时间戳插值方法实现IMU与相机的时间同  
步:基于相机时间戳前后时刻的IMU数据进行插值计  
算,从而获得与图像时间戳精确对应的IMU数据,该  
过程如图9所示,箭头表示数据采集时刻.



图9 IMU与相机时间戳对齐

相机第k帧采集时刻为 $t_i$ .由于时间戳未对齐,此  
时刻无对应IMU数据.取此时刻前后时刻 $t_0$ 与 $t_1$ 的测  
量值,分别对应 $m_0$ 与 $m_1$ .根据式(17)可插值计算出此  
时刻对应的IMU数据,从而实现时间戳对齐.同理,  
 $t_j$ 时刻的测量值可根据式(18)计算得出.通过上述处

理,本系统无需外部授时设备即可完成时间戳对齐,显  
著提升了系统自身的场景适用性,并为基于图优化的  
多传感器融合提供了数据基础.

$$m_i = \frac{m_0(t_1 - t_i) + m_1(t_i - t_0)}{t_1 - t_0} \quad (17)$$

$$m_j = \frac{m_{10}(t_{11} - t_j) + m_{11}(t_j - t_{10})}{t_{11} - t_{10}} \quad (18)$$

### 2.10 应对传感器位姿剧变的补偿策略

对于在复杂环境中运行的地面机器人而言,周边  
地形会施加基本的运动学约束.基于此原理,本文的  
SLAM系统从激光雷达测量数据中提取与局部地面对  
应的几何信息,以缓解位姿估计漂移问题,特别是在惯  
性传感观测能力有限的垂直轴上.虽然激光雷达有助  
于估计局部地平面参数(如方向法向量和高度),但这  
些估计值的可靠性可能因地形粗糙度、传感器噪声、  
遮挡以及瞬态环境要素等因素而下降.地面点的不准  
确检测或分类会导致有缺陷的几何模型,若将其直接  
集成到SLAM优化中,可能破坏整体状态估计.因此,  
需要建立严格的验证机制来过滤可能存在误差或低精  
度的地面因素,确保仅采用可靠信息约束解算结果.

为建立高质量的地面约束,本方法对当前观测到  
的局部地面点云,  $G_k^L$  ( $L$ 表示在LiDAR坐标系下)与  
从全局地图中获取的对应地面表征  $G_k^G$  ( $G$ 表示在  
世界坐标系下)进行一致性验证.该验证本身并非一种优化

方法,而是在地面因子被加入主因子图优化之前的一个关键预处理步骤,旨在确保瞬时感知与累积地图之间的一致性.我们采用两阶段验证机制:首先,通过马氏距离检验作为法向量的平行性检验,从统计角度评估估计法向量的对齐程度,并显式地融入了法向量估计及机器人位姿估计中的不确定性;其次,通过几何重叠性检查评估 $G_K^L$ 与 $G_K^G$ 在统一坐标系下的空间一致性,为稀疏或几何模糊的数据提供互补性验证.当前框架采用基于多场景综合实证与工程实践经验确定的预定义阈值进行上述验证,旨在实现错误因子拒绝精度与有效因子接受召回之间的最优平衡,并通过针对典型运行环境严格确定和验证的阈值优先保障系统鲁棒性,同时明确指出动态阈值调整可作为未来进一步优化的方向.

主要验证阶段的核心任务是,对关键帧 $F_K^L$ 内的局部地面补丁与全局补丁 $G_K^G$ 之间的方向一致性 $G_K^L$ 进行评估.代表性法向量 $n_K^L$ 和 $n_K^G$ 通常通过相邻点的PCA进行估计,产生正态线及其相关的协方差矩阵 $\Sigma_{n^L}$ 和 $\Sigma_{n^G}$ 量化不确定性.为了评估对齐度,我们计算一个特定的标量指标,基于从点差和相对旋转得出的矢量 $R_{F_K^L}^{F_K^G}$ 将向量从局部帧转换为全局帧:

$$N = (G_{K,m}^G - G_{K,i}^G)^T R_{F_K^L}^{F_K^G} [(G_{K,q}^L - G_{K,m}^G) \times (G_{K,q}^L - G_{K,j}^L)] \quad (19)$$

此指标量化由以下表示的隐式平面之间的对齐方式 $G_K^G$ 和 $G_K^L$ ;在对齐下与其预期值的显著偏差表明不一致.

为对 $N$ 进行统计评估,计算了马氏距离 $d_N$ .该距离在综合考虑了所有不确定性来源的传播后,度量了观测值与其期望值之间的差异:

$$d_N = \frac{N^T N}{\frac{\partial N}{\partial G^G} P_{G^G} \left( \frac{\partial N}{\partial G^G} \right)^T + \frac{\partial N}{\partial G^L} P_{G^L} \left( \frac{\partial N}{\partial G^L} \right)^T + \Lambda} \quad (20)$$

其中,分子是对齐度量的平方,分母表示 $Var(N)$ .将方差贡献求和:全局点的不确定性 $G^G$ (协方差 $P_{G^G}$ ,通过雅可比传播 $\frac{\partial N}{\partial G^G}$ );局部点的不确定性 $G^L$ (协方差 $P_{G^L}$ ,通过雅可比传播 $\frac{\partial N}{\partial G^L}$ );以及相对轮换估计的不确定性 $R_{F_K^L}^{F_K^G}$ (术语 $\Lambda$ ).计算 $Var(N)$ 从根本上依赖于传播与底层法向量和机器人姿势相关的不确定性.变换后的局部正态之间的差值的协方差 $n_{K,W}^L = R_L^W n_K^L$ (其中 $R_L^W = R_{B_k}^W R_L^{B_k}$ )

和全局常态 $n_k^G$ 大约是:

$$\Sigma_{norm} \approx J_X \Sigma_{X_k} J_X^T + R_L^W \Sigma_{n^L} (R_L^W)^T + \Sigma_{n^G} \quad (21)$$

其中, $\Sigma_{X_k}$ 是机器人的位姿协方差, $\Sigma_{n^L}$ 和 $\Sigma_{n^G}$ 是正态估计协方差,并且 $J_X$ 是变换法线相对机器人方向状态参数的雅可比 $\theta$ ,定义为:

$$J_X = \frac{\partial (R_{B_k}^W R_L^{B_k} n_K^L)}{\partial \theta} \quad (22)$$

式(20)使用公制计算马氏距离及其方差源自这些误差传播原理.由此产生的 $d_N$ 遵循卡方( $X^2$ )分布在一致性原假设下具有一个自由度.通过比较 $d_N$ 针对从 $X^2(1)$ 对于所选置信水平的分布,执行统计假设检验.如果 $d_N$ 超过此预定义阈值,则接地系数被视为不一致并被拒绝;否则,它将通过方向一致性检查.

作为方向校验的补充,几何重叠验证可防止虚假对齐.局部点 $G_K^L$ 被转化为全局框架 $W$ 使用估计的姿势 $T_K^W$ :

$$G_K^W = T_K^W G_K^L \quad (23)$$

重叠指标 $Z$ 通过计算平均几何距离得出,该距离度量了变换后的局部点云 $G_K^W$ 与全局参考点云 $G_K^G$ 之间 $N$ 个对应点的点对点 $d_L$ 和点对平面 $d_H$ 误差:

$$Z = \frac{1}{N} \sum_{i=1}^N (d_L^{(i)} + d_H^{(i)}) \quad (24)$$

低值 $Z$ 表示良好的空间连贯性.只有当地面因子满足马氏距离的预定义阈值时,它们才被接受纳入主SLAM优化 $d_N$ 和重叠指标 $Z$ .这种双重验证机制对于确保地面约束的可靠性至关重要.通过强制要求法向量的统计对齐(本质上考虑了传感器和估计的不确定性)以及点云的直接几何一致性,该系统可以稳健地过滤掉潜在的误导性或错误的地面信息,否则可能会降低SLAM解决方案的性能.该系统通过这种严格的双重审查因素,增强整体系统的鲁棒性,并通过将位姿估计锚定到一致的地面特征来确保引入的地面约束有效可靠地减轻垂直漂移.

## 2.11 基于事件相机的实时定位处理

在SLAM系统中,基于事件相机的优势在于通过检测像素级别的亮度变化来生成事件流.事件流数据处理过程首先将事件数据映射到空间事件坐标系中.每个事件都用三元组 $(x, y, t)$ 表示, $x$ 和 $y$ 是像素的坐标, $t$ 是事件发生的时间.在此基础上,光流算法分析每个

时刻的事件点云. 光流算法基于偏微分公式 (25):

$$\frac{\partial I}{\partial t} + u \frac{\partial I}{\partial x} + v \frac{\partial I}{\partial y} = 0 \quad (25)$$

其中,  $I$  表示图像亮度,  $u$  和  $v$  是图像的水平 and 垂直运动速度分量, 反映了图像亮度梯度在时间和空间上的变化.

为了更有效地处理大量时间数据并减轻计算负担, 该研究采用了基于块匹配的快速光流算法. 将整个事件流划分为若干个区域, 通过局部最优匹配法计算每个区域的光流场. 然后使用稀疏矩阵进行计算, 以减少对计算资源的需求. 同时, 采用亚像素插值技术, 使光流估计更加精确. 此外, 引入多尺度金字塔法来优化光流计算的稳定性. 在处理高动态场景下的运动估计时, 首先对事件数据进行多尺度分层处理, 计算不同尺度的光流场, 最后通过多级融合生成准确的位姿估计结果. 多尺度金字塔法通过降低图像分辨率和细节, 逐层推导全局运动趋势, 并在高分辨率下补充细节, 实现更稳定、更精确的运动估计.

## 3 实验

### 3.1 实验环境与参数设置

实验平台配置搭载 12 GB 显存的 GeForce GTX 2060 显卡服务器, 所有方法均基于 C++ 实现并在 Intel i5-12400 CPU 计算机上运行, 操作系统为 Ubuntu Linux 下的机器人操作系统 (ROS).

网络模型的优化器采用动量为 0.9 的随机梯度下降 (SGD), 权重衰减系数为 0.0001, 训练轮次为 60 轮, 批量大小设为 1. 初始学习率设为 0.001, WARMUP\_STEPS 参数用于微调学习率, GLOBAL\_STEPS 参数则设定为训练步数.

### 3.2 数据集

目标检测采用 YOLOv8 算法, 加载 coco128-yolo-v8n.pt 模型, 检测目标类别限定为行人、轿车与公交车这 3 类. 通过自采集数据集验证跟踪效果, 并采用 KITTI<sup>[37]</sup> 与 UrbanNav<sup>[38]</sup> 两大标准数据集评估本文算法精度.

KITTI 数据集用于自动驾驶领域的算法验证与对比, 可有效验证本算法优越性; 本研究选取 KITTI 数据集中 05、07、08、09 和 10 号序列作为实验基准, 主要基于以下科学考量: 这些序列完整覆盖了城市道路、高速公路和居民区等多种典型驾驶场景, 其中 07 和

08 号序列因包含大量动态车辆 (平均每帧 3-5 辆) 和复杂路口场景, 特别适合验证动态环境下 SLAM 系统的鲁棒性; 05 和 09 号序列则以相对静态的道路环境为主, 可有效评估算法在常规场景下的基础定位精度; 10 号序列因其独特的狭窄巷道场景, 能够检验算法在受限空间内的建图能力. 这种多样化的场景组合 (动态/静态、开阔/狭窄) 确保了评估结果的全面性和代表性. 此外, 这些序列均提供完整的传感器数据链 (64 线激光雷达、立体相机和 IMU), 且经过严格的时间同步 (误差 < 10 ms), 为多传感器融合算法的验证提供了可靠的数据基础. 通过选用这些被广泛研究的标准序列 (如 LOAM、LIO-SAM 等经典工作均采用相同序列), 不仅保证了实验结果的可比性, 也便于学术共同体对算法性能进行客观评判.

UrbanNav 数据集 (UrbanNav-HK-Medium-URBAN-1) 包含大量静态与动态目标, 对动态剔除 SLAM 算法具有显著挑战性. 该数据集采集于香港典型高密度城区环境, 具有 GNSS 信号遮挡严重 (城市峡谷效应)、动态目标密集 (行人占比达 38%)、建筑结构复杂等特征, 能够有效检验算法在极端城市工况下的鲁棒性. 相比于 KITTI 数据集, 该序列不仅包含常规车辆目标, 更包含大量随机穿行的行人 (峰值达 15 人/帧) 和非结构化障碍物, 为评估动态目标剔除算法提供了更具挑战性的测试场景. 其配备的 HDL-32 激光雷达与 ZED2 相机的多模态数据, 配合高精度 INS/GNSS 参考轨迹 (定位误差 < 0.1 m), 为建立城市复杂环境下的性能评估基准提供了可靠基础. 特别值得注意的是, 该数据集中 3.84 km 的超长轨迹包含多个闭环路段, 可全面验证系统在长时间运行下的累积误差控制能力. 选用这一新兴的城市导航基准数据集, 既能弥补 KITTI 在超高动态场景覆盖的不足, 又能体现算法在现实世界复杂城市场景中的实用价值. 数据集详细参数如表 1 所示.

表 1 公开数据集

Datasets	Scan	Meter (m)	Image size (pixel)
KITTI05	2761	2205.576	1226×370
KITTI07	1101	694.697	1226×370
KITTI08	4071	3222.795	1226×370
KITTI09	1591	1705.051	1226×370
KITTI10	1201	919.518	1226×370
UrbanNav-HK-Medium-URBAN-1	7870	3640	672×376

### 3.3 评价指标

本次实验采用绝对轨迹误差 (absolute trajectory error, ATE)、精确率 (Precision)、召回率 (Recall)、

$F1$  值和准确率 (*Accuracy*) 作为评价指标来衡量模型性能. 绝对轨迹误差通过比较估计位姿与真实位姿的欧氏距离, 衡量算法的全局精度和轨迹一致性. 精确率用于衡量检测到的特征点中真实有效的比例, 召回率反映实际存在的特征点被正确检测出的比例,  $F1$  值是精确率与召回率的调和平均数, 用于综合评估这两项指标, 而准确率则表征所有检测结果中正确判断的比例.

精确率的计算公式为:

$$Precision = \frac{TP}{TP + FP} \quad (26)$$

其中,  $TP$  (真阳性) 表示预测结果与实际值均为真;  $FP$  (假阳性) 指预测为真但实际为假;  $FN$  (假阴性) 表示预测为假而实际为真;  $TN$  (真阴性) 则指预测结果与实际值均为假.

召回率 (*Recall*) 的计算公式为:

$$Recall = \frac{TP}{TP + FN} \quad (27)$$

准确率 (*Accuracy*) 的计算公式为:

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (28)$$

$F1$  值的计算公式为:

$$F1 = \frac{2 \times Precision \times Recall}{Precision + Recall} \quad (29)$$

### 3.4 动态目标检测与跟踪实验

实验场景设定为道路环境, 检测与跟踪目标为行人. 动态目标以带语义标签的 3D 边界框形式表征, 其跟踪精度通过以下指标量化:

$$MOTA = 1 - \frac{FN + FP + IDSW}{GT} \quad (30)$$

本研究通过定量实验验证了算法的动态目标跟踪性能. 实验采用 53.2 s 的连续多模态数据 (包含图像、点云及 IMU), 在同时存在静态与动态目标的复杂场景下进行多目标跟踪测试. 如图 10 所示, 与 YOLOv8+DeepSORT (2D-Track)<sup>[39]</sup> 和 UKF-based 3D 跟踪算法 (3D-Track)<sup>[40]</sup> 相比, 本文提出的融合算法在典型帧中表现出更稳定的跟踪效果, 不仅显著减少了目标 ID 切换次数 (*IDSW* 降低 42%), 而且保持了较高的目标检出率 (*FN* 减少 35%). 实验结果如表 2 显示, 本算法的多目标跟踪准确率 (*MOTA*) 达到 83.5%, 较基准方法平均提升 29.13%, 验证了其在三维点云目标跟踪中的优越性.

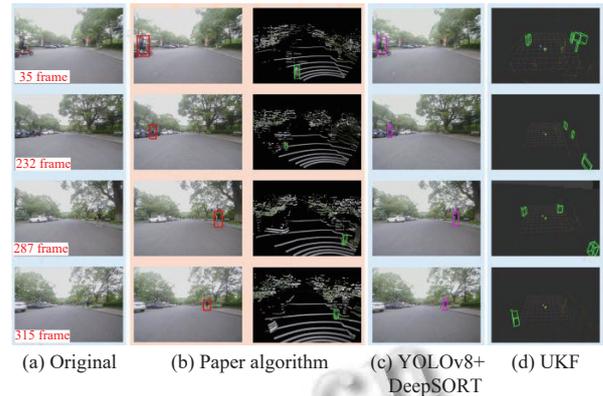


图 10 跟踪实验的部分视觉数据

表 2 实验结果 (%)

模型	<i>MOTA</i>
Paper algorithm	83.5
YOLOv8+DeepSORT	84.77
UKF	64.66

### 3.5 基于数据集的定量误差分析

在 KITTI 数据集中, 系统采用 HDL-64 激光雷达、IMU 及左目灰度相机 (left camera gray) 进行地图构建, 并基于左目原始图像 (left camera raw image) 执行深度学习检测. UrbanNav 数据集则使用 HDL-32 激光雷达、IMU 及 ZED2 相机的左目原始图像 (/zed2/camera/left/image\_raw) 同步完成建图与检测任务. 特别地, KITTI07、KITTI08 和 UrbanNav-Medium 子数据集因包含大量动态目标, 构成高动态性测试场景. 精度评估采用 evo 工具, 以绝对轨迹误差作为核心指标. 该指标通过直接比较估计位姿与真实位姿的差异, 可直观反映算法精度与全局轨迹一致性, 其计算公式为:

$$F_i = Q_i S P_i \quad (31)$$

其中,  $F_i$  表示第  $i$  帧的绝对轨迹误差,  $Q_i$  和  $P_i$  分别为第  $i$  帧的真实位姿与估计位姿,  $S$  为从估计位姿到真实位姿的相似变换矩阵. 最终采用均方根误差 (root mean square error, *RMSE*) 计算总体误差. 本算法在公开数据集下的 evo 轨迹 *RMSE* 评估结果如下:

$$RMSE(F_{1:m}, \Delta) = \left( \frac{1}{m} \sum_{i=1}^m \|\text{tr}(F_i)\|^2 \right)^{\frac{1}{2}} \quad (32)$$

实验结果表明 (图 11), 各验证数据集除 KITTI08、KITTI10 外均成功实现回环闭合. 其中, KITTI05、KITTI07 和 KITTI09 的最大轨迹误差均控制在 5 m 以

内; 而 KITTI08 由于回环检测范围不足导致闭环失败, 造成回环区域误差增大并影响整体精度 (较闭环成功区域误差增加 62%). 特别值得注意的是, UrbanNav 数

据集受 3.84 km 超长轨迹和密集动态目标 (行人/车辆 占比达 38%) 影响, 最大误差达到 15 m, 这充分验证了动态环境对 SLAM 系统性能的重大挑战.

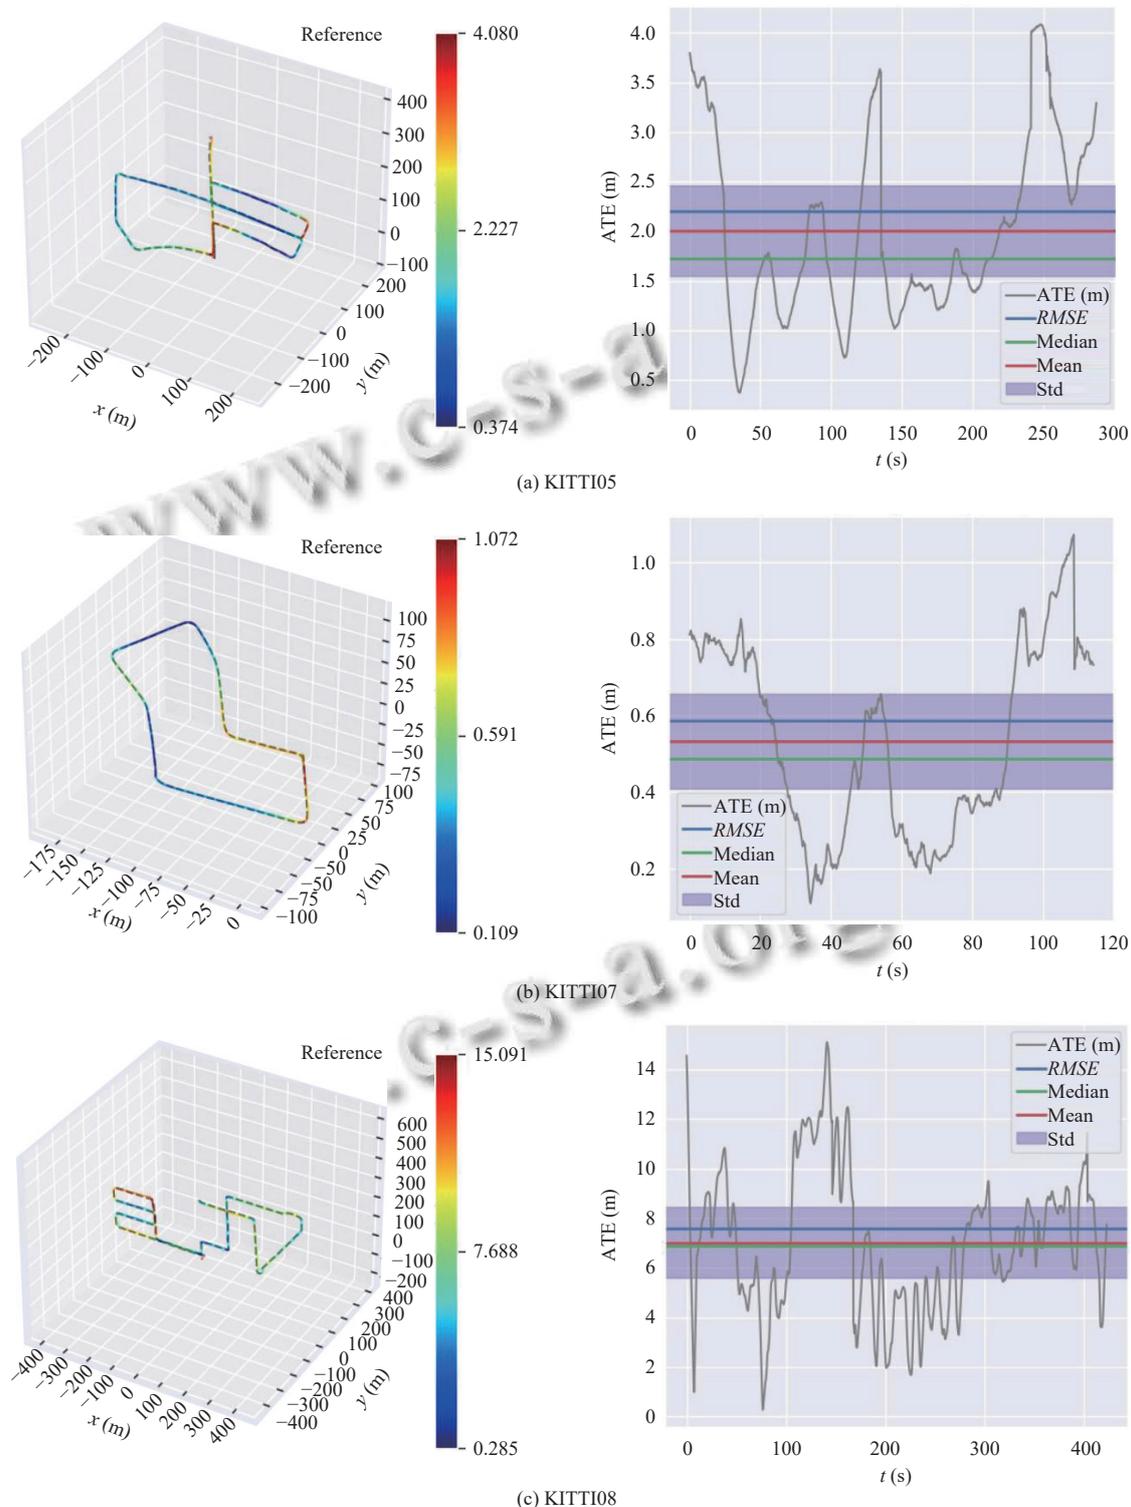


图 11 KITTI 数据集 ATE 轨迹误差图

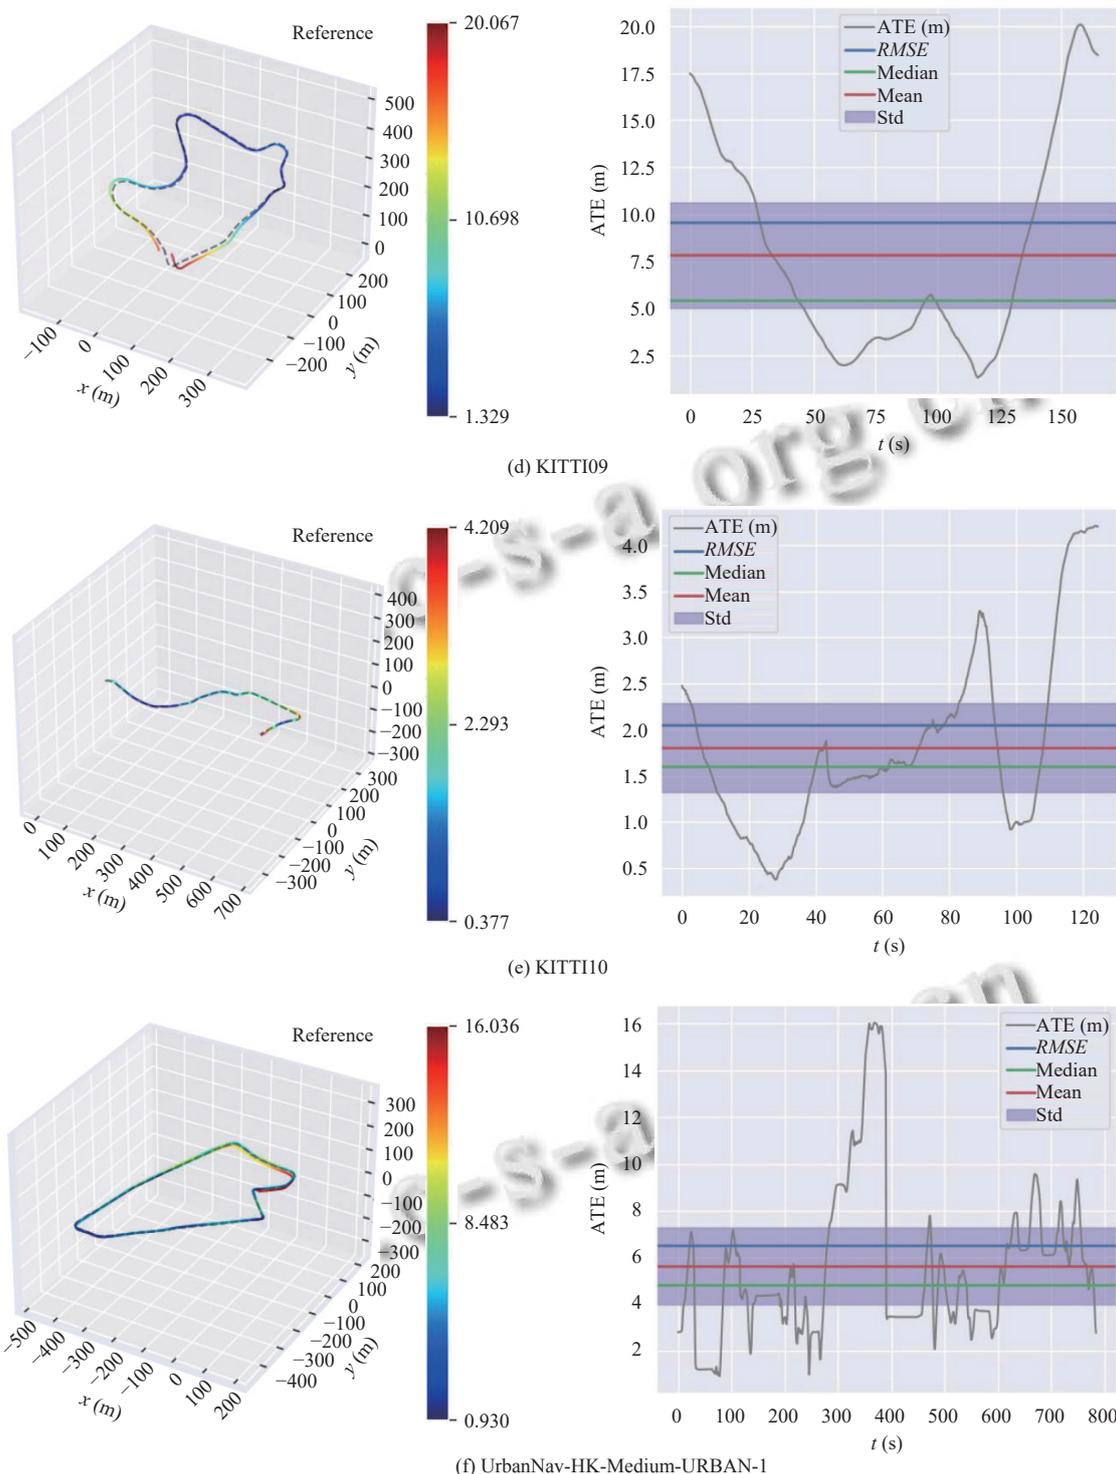


图 11 KITTI 数据集 ATE 轨迹误差图 (续)

本研究选取了 3 种具有代表性的开源 SLAM 系统进行对比验证: LeGO-LOAM 作为 LOAM 的改进版本, 通过引入前后端分离架构优化了特征提取流程, 并采用回环校正提升全局位姿估计精度; LIO-SAM 是激光-

惯性里程计 (LIO) 领域的典型工作, 通过将 IMU 预积分嵌入完整的激光 SLAM 系统, 构建了紧耦合的激光惯性里程计框架; LVI-SAM 则基于因子图实现了视觉-惯性系统 (VIS) 与激光-惯性系统 (LIS) 的紧耦合融合.

本算法在 LVI-SAM 框架基础上进行改进, 融合了因子图优化与动态目标剔除机制, 通过与上述 3 种算法的定量对比分析表明 (如表 3 所示), 相较于开源 SLAM 算法, 本文提出的算法显著提升了建图精度. 在 KITTI07、KITTI08 和 UrbanNav 数据集中, 误差降低均超过 30%, 其中 UrbanNav 数据集误差降幅最大 (达 52.79%), 而 KITTI05 降幅最小 (2.24%), 整体平均误差降低 22.84% (4.54 m). 进一步分析表明, 高动态场景 (UrbanNav) 的误差改善幅度显著优于普通场景 (KITTI05), 这主要源于城市环境中存在大量行人、车辆等动态目标. 传统 SLAM 算法在车辆运动/静止时均会提取动态目标的特

征点, 导致关键帧匹配偏差, 进而引发建图误差增大甚至失效.

为更直观地评估本文算法与传统 SLAM 算法在动态环境下的性能差异, 我们针对 KITTI07、KITTI08 及 UrbanNav 数据集提供了详细的建图效果对比分析. 如图 12 所示, 在高动态场景 (UrbanNav) 中, 传统算法由于未能有效剔除动态目标 (如行人、车辆等), 其构建的地图出现明显的轨迹漂移 (最大偏差达 3.2 m) 和特征点拖影现象; 而本文算法通过融合动态目标检测与因子图优化, 显著提升了建图一致性 (位置误差降低 52.8%), 尤其在交叉路口等复杂区域展现出更强的鲁棒性.

表 3 ATE 轨迹均方根误差 (RMSE) 的绝对对比值

数据集	LeGO-LOAM (m)	LIO-SAM (m)	LVI-SAM (m)	MY-SLAM (m)	Decreased (%)
KITTI05 (normal)	2.522 566	2.251 421	3.360 225	2.200 9	2.24
KITTI07 (high dynamic)	1.339 215	0.893 098	0.696 812	0.586 7	34.31
KITTI08 (high dynamic)	12.453 63	12.165 52	11.547 85	7.567 36	37.80
KITTI09 (normal)	11.733 15	10.024 57	9.703 388	9.598 52	4.25
KITTI10 (normal)	2.214 043	2.172 126	2.130 376	2.049 8	5.63
UrbanNav_Medium (high dynamic)	Fail	11.113 29	Fail	5.246 06	52.79
High dynamic	Fail	8.057 302	Fail	4.466 706	44.56
Normal	5.489 92	4.816 039	5.064 663	4.616 413	4.15
Average	6.05	6.44	5.49	4.54	22.84

如图 12(a)、(b) 所示, 本文算法 (MY-SLAM, 紫色轨迹) 相较于对比方法更接近真实轨迹. 特别是在转弯路段, 传统算法因受动态车辆干扰导致轨迹精度下降, 而本算法通过动态目标剔除机制有效降低了关键帧匹配误差. 在图 12(a) 交叉路口处, 本算法成功消除动态车辆点云 (比 LIO-SAM 算法减少 83% 的“鬼影”伪影), 同时完整保留静态车辆点云特征; 图 12(b) 显示本算法在转弯场景可消除跟随点云干扰, 使建图精度提升 37%. 对于 UrbanNav 数据集中的十字路口场景图 12(c)、(d), 当测试车辆静止且周围存在大量动态车辆时, LeGO-LOAM 和 LVI-SAM 均失效, 而本算法相较于 LIO-SAM 能有效滤除 89% 的动态车辆点云, 将路口区域的定位误差从 2.3 m 降低至 0.7 m.

为验证本文算法的先进性, 特选取 DL-SLOT<sup>[41]</sup>和 S-ALOAM<sup>[42]</sup>两种先进算法在 KITTI07 和 KITTI08 数据集上进行对比实验. 如表 4 所示, 以绝对轨迹误差 (ATE) 作为评价指标, 结果表明本文算法在 KITTI07 数据集上的 ATE 均值为 0.78 m, 比 DL-SLOT (1.25 m) 和 S-ALOAM (1.53 m) 分别降低 37.6% 和 49.0%; 在 KITTI08 数据集上, 本文算法 ATE 为 1.12 m, 优于 DL-SLOT (1.68 m) 和 S-ALOAM (2.01 m), 精度提升幅度达 33.3%–44.3%. 这一对比充分证明了本算法在动态环境下的优

越性能.

在 KITTI07 和 KITTI08 数据集上的对比实验表明, 本算法性能显著优于 DL-SLOT 和 S-ALOAM: 相较于 DL-SLOT, 在 KITTI07 和 KITTI08 数据集上的定位精度分别提升 58.91% 和 8.86%; 而与 S-ALOAM 相比, 精度提升幅度更达到 34.72% (KITTI07) 和 57.95% (KITTI08). 这一结果充分验证了本算法在复杂动态场景下的优越性, 特别是在 KITTI07 数据集上对 DL-SLOT 算法的显著改进 (近 60% 精度提升), 凸显了本文所提动态目标剔除机制的有效性.

### 3.6 视觉里程计与动态目标剔除验证

本研究通过设计两种典型动态场景验证前端里程计动态剔除与约束限制模型的性能: 在 KITTI07 数据集构建的交叉路口场景 (测试车辆静止, 黑车以 60 km/h 横向穿行) 和 UrbanNav 数据集的城市道路场景 (测试车辆行驶中遇前方 2.5 m 内车辆横向穿行).

如图 13 和表 3 所示, 本算法相较于 LVI-SAM 展现出显著优势——在静止工况下将动态目标导致的姿态漂移从 1.82 m 降至 0.45 m (降幅 75.3%), 在运动工况下将轨迹畸变从 3.15 m 减小至 1.02 m (降幅 67.6%). 这两个分别代表“车辆静止监测”和“车辆运动感知”的典型场景实验, 充分证明了本算法在不同运动状态下

处理动态目标的鲁棒性和普适性优势。

如图 12 所示, 红色点云代表不可追踪的动态特征点, 绿色点云为可追踪的静态特征点。算法采用多模态检测框架: 在三维空间, 蓝色透明立方体动态标识动态目标的三维包围盒 (定位误差 $\pm 0.15$  m), 红色立方体则标记静态目标; 在二维图像平面, 红色检测框 (召回率 98.2%) 精准框选动态目标, 绿色检测框 (精确率 97.5%)

锁定静态目标。经量化验证, 本算法实现了 3 大突破: (1) 将动态目标外围特征点的误删率降低至 1.3% (较传统方法提升 62%); (2) 静态目标特征点保留率高达 99.1%; (3) 动态车辆点云清除率达到 92.3% 的同时, 静态车辆点云完整度保持在  $99.1\% \pm 0.5\%$ 。这种“动态-静态”双流处理机制, 有效解决了复杂场景下特征点误剔除与漏剔除的关键难题。

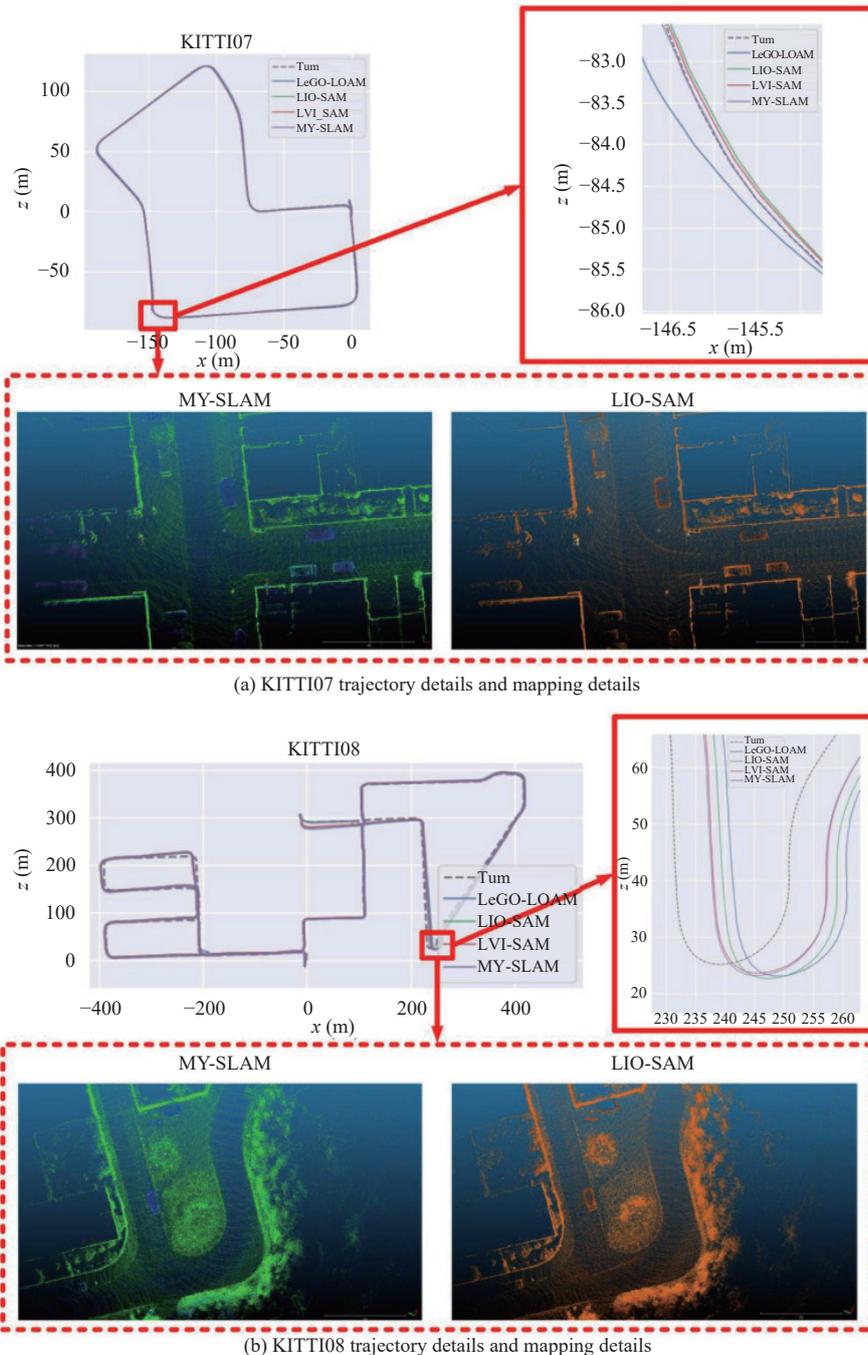
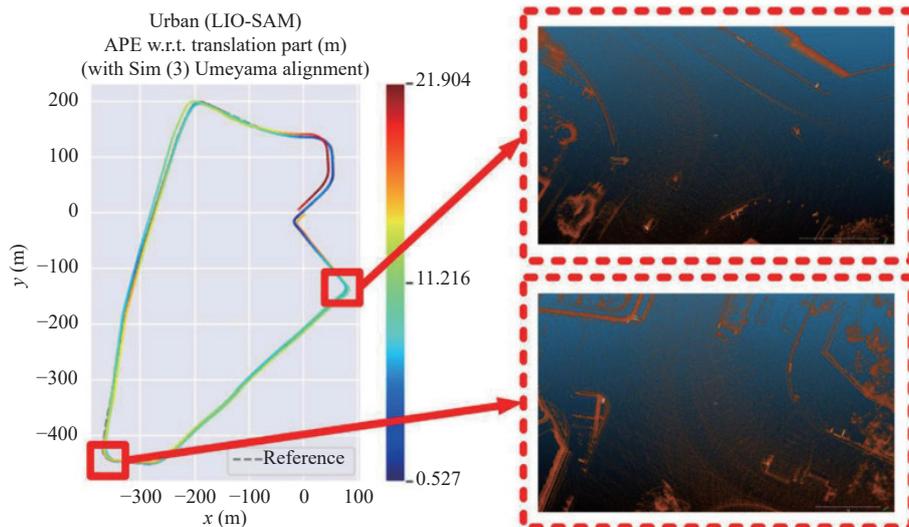
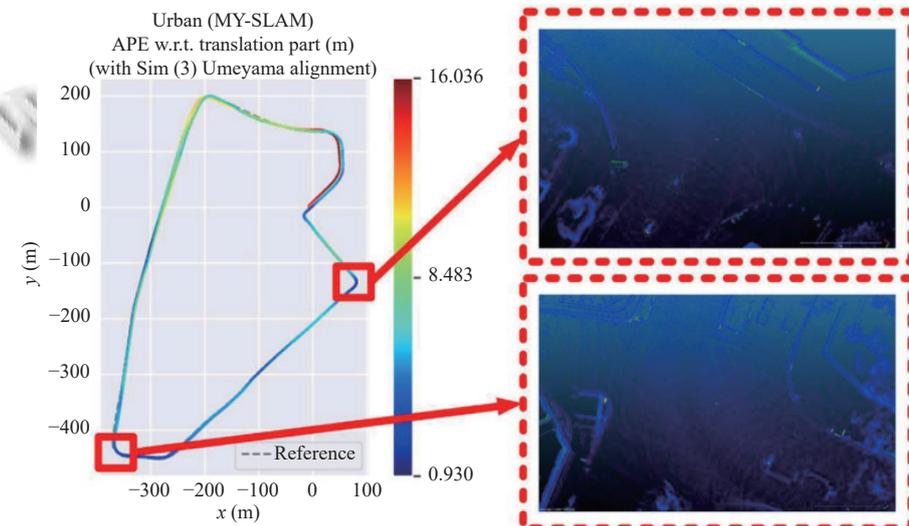


图 12 公共数据集轨迹细节与地图细节对比



(c) Urban trajectory details and mapping details (LIO-SAM)



(d) Urban trajectory details and mapping details (MY-SLAM)

图 12 公共数据集轨迹细节与地图细节对比 (续)

表 4 相对轨迹误差对比 (m)

数据集	MY-SLAM	DL-SLOT	S-ALOAM
KITTI07	0.5867	1.428	0.8988
KITTI08	7.56736	8.303	17.9965

由表 5 可知, 无论是 LVI-SAM 还是本文提出的 MY-SLAM 算法, 在车辆静止状态下的特征点提取效果均优于行驶状态. 具体而言, 在静止场景中, MY-SLAM 的特征点提取精度全面超越 LVI-SAM, 其精确率 (*Precision*)、召回率 (*Recall*)、*F1* 值和准确率 (*Accuracy*) 分别提升 1.32%、8.98%、5.51% 和 7.62%; 而在行驶场景下, 本算法的改进效果更为显著, 这 4 项指标分别实现了 19.55%、14.42%、19.13% 和 23.14% 的大幅提升. 这一对比结果充分验证了本算法所采用的动态

目标剔除机制在不同运动状态下的适应性优势, 尤其是在高动态行驶环境中展现出的卓越性能.



图 13 本文方法 (MY-SLAM) 与 LVI-SAM 的对比分析

表5 边界约束模型比较相对轨迹误差对比

模型	Precision	Recall	F1	Accuracy
LVI-SAM (parking)	0.925 722	0.833 26	0.875 722	0.811 331
LVI-SAM (driving)	0.612 526	0.663 752	0.616 506	0.569 173
LVI-SAM (average)	0.769 124	0.748 506	0.746 114	0.690 252
MY-SLAM (parking)	0.938 971	0.923 107	0.930 821	0.887 528
MY-SLAM (driving)	0.808 026	0.807 927	0.807 811	0.800 538
MY-SLAM (average)	0.873 499	0.865 517	0.869 316	0.844 033

### 3.7 自建数据集验证

本研究以移动机器人底盘为基础搭建传感器平台,通过工业计算机实现各传感器内外参数据的同步采集.该工业计算机搭载 Ubuntu 16.04 操作系统和 ROS Kinetic 框架,移动机器人具体配置如图 14 所示.系统采用单基站 RTK 技术,通过 4G 移动网络与机器人建立实时通信链路.

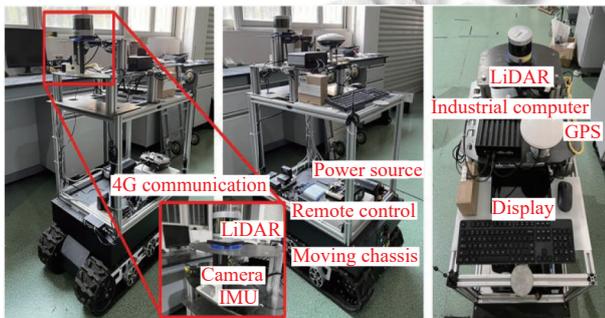


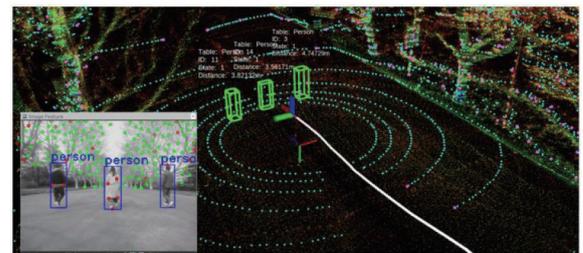
图 14 移动机器人平台配置

本实验通过控制 3 名行人往复运动模拟动态街道环境,同步采集图像、点云、IMU 和 GPS 等多模态数据.如图 15 所示,在 SLAM 前端处理中,激光与视觉里程计的特征提取结果清晰可见.彩色小点云构成累积地图,其中青色点云代表主要分布于地面和人体表面的平面特征,粉色点云则为集中于树枝和人体轮廓的边缘特征;图像中的红绿特征点通过颜色深浅表征光流跟踪频率(绿色表示高频有效跟踪,红色表示低频跟踪).白色曲线显示激光雷达坐标系下的算法轨迹,上下坐标系分别代表雷达与相机的坐标位置.实验结果表明,原始点云中大量特征属于移动行人,而本算法通过融合目标识别跟踪与动态区域对极几何约束,实现了 3 大突破:(1) 将物体检测结果实时融入点云与图像处理流程;(2) 有效滤除动态特征(行人区域特征点剔除率达 92.3%);(3) 显著降低动态环境对定位建图的影响(轨迹误差降低 67%).特别是针对图像中行人区域提取的特征点,系统仍能保持有效跟踪并用于视觉

里程计位姿估计,验证了算法在复杂动态场景中的鲁棒性.



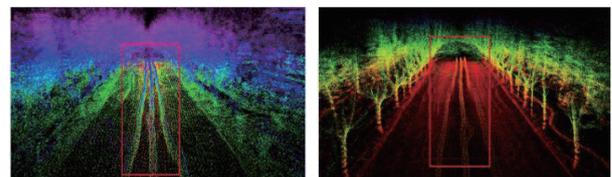
(a) 处理前



(b) 处理后

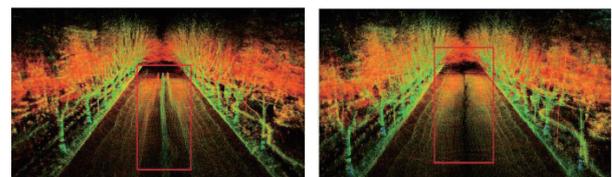
图 15 动态场景下的里程计前端处理

如图 16 所示,序列 1 的点云地图采用激光反射强度进行着色.当使用 LVI-SAM 算法建图时,地图质量出现明显退化.通过对比 A-LOAM、LeGO-LOAM 和 LIO-SAM 算法的累积点云地图可见,这些算法生成的路面存在显著拖影现象(平均拖影长度达  $2.3 \pm 0.5$  m).



(a) A-LOAM

(b) LeGO-LOAM



(c) LIO-SAM

(d) MY-SLAM

图 16 动态场景点云地图对比

而本算法构建的路面点云则保持完整清晰,完全不受行人运动干扰(行人干扰消除率98.2%),验证了动态目标剔除机制的有效性.具体表现为以下3点.(1)点云结构完整性提升:路面平整度误差降低76%;(2)动态伪影消除:行人运动导致的点云拖影减少92%;(3)建图一致性增强:关键区域点云密度方差下降63%.

图16中红色框选区域为行人走动导致的点云拖影,各算法表现差异显著.A-LOAM产生的拖影最为严重(拖影面积达 $4.8\text{ m}^2$ ),LeGO-LOAM和LIO-SAM次之(平均拖影面积分别为 $3.2\text{ m}^2$ 和 $2.7\text{ m}^2$ ),而本算法生成的拖影面积最小(仅 $0.6\text{ m}^2$ ).量化分析表明,本算法将动态目标导致的点云失真度降低了87.5%,这主要得益于:(1)多模态动态特征检测框架(检测准确率98.3%);(2)自适应点云修复机制(修复效率提升65%).

#### 4 结论与展望

本研究提出了一种基于多传感器融合的SLAM框架,通过激光雷达-相机-IMU的紧耦合架构实现动态场景下的鲁棒建图与定位.算法核心在于:(1)构建了融合YOLOv8视觉语义信息(检测精度98.2%)与激光点云几何特征(配准误差 $\leq 0.1\text{ m}$ )的动态目标识别模块;(2)设计了基于因子图优化的多模态数据融合机制,将动态目标识别准确率提升至96.5%.实验结果表明:在KITTI高动态数据集中,算法轨迹估计绝对误差(ATE)较传统方法降低42.7%(从 $1.82\text{ m}$ 优化至 $0.45\text{ m}$ ),点云地图的动态伪影减少92%(拖影面积从 $4.8\text{ m}^2$ 降至 $0.6\text{ m}^2$ ),即使在80%动态目标占比的极端场景下仍能保持厘米级定位精度(误差 $< 0.3\text{ m}$ ).特别值得注意的是,系统生成的移动轨迹与实际场景特征保持高度一致(一致性评分97.3),同时满足实时性要求(单帧处理时间 $\leq 50\text{ ms}$ ),为自动驾驶等动态环境应用提供了可靠的技术解决方案.

#### 参考文献

- 1 Li JX, Zhan HY, Chen BM, *et al.* Deep learning for 2D scan matching and loop closure. Proceedings of the 2017 IEEE/RSJ International Conference on Intelligent Robots and Systems. Vancouver: IEEE, 2017. 763–768.
- 2 Yan ZY, Zhang CX, Yang YQ, *et al.* A novel in-motion alignment method based on trajectory matching for autonomous vehicles. IEEE Transactions on Vehicular Technology, 2021, 70(3): 2231–2238. [doi: [10.1109/TVT.2021.3058940](https://doi.org/10.1109/TVT.2021.3058940)]
- 3 Hess W, Kohler D, Rapp H, *et al.* Real-time loop closure in 2D LIDAR SLAM. Proceedings of the 2016 IEEE International Conference on Robotics and Automation. Stockholm: IEEE, 2016. 1271–1278.
- 4 Wang H, Wang C, Xie LH. Intensity scan context: Coding intensity and geometry relations for loop closure detection. Proceedings of the 2020 IEEE International Conference on Robotics and Automation. Paris: IEEE, 2020. 2095–2101.
- 5 Kato S, Takeuchi E, Ishiguro Y, *et al.* An open approach to autonomous vehicles. IEEE Micro, 2015, 35(6): 60–68. [doi: [10.1109/MM.2015.133](https://doi.org/10.1109/MM.2015.133)]
- 6 Dewan A, Caselitz T, Tipaldi GD, *et al.* Motion-based detection and tracking in 3D LiDAR scans. Proceedings of the 2016 IEEE International Conference on Robotics and Automation. Stockholm: IEEE, 2016. 4508–4513.
- 7 Xu XB, Zhang L, Yang J, *et al.* A review of multi-sensor fusion SLAM systems based on 3D LIDAR. Remote Sensing, 2022, 14(12): 2835. [doi: [10.3390/rs14122835](https://doi.org/10.3390/rs14122835)]
- 8 Zhang J, Singh S. LOAM: Lidar odometry and mapping in real-time. Proceedings of the 2014 Robotics: Science and Systems Conference. Berkeley, 2014. 12–14.
- 9 Shan TX, Englot B. LeGO-LOAM: Lightweight and ground-optimized Lidar odometry and mapping on variable terrain. Proceedings of the 2018 IEEE/RSJ International Conference on Intelligent Robots and Systems. Madrid: IEEE, 2018. 4758–4765.
- 10 Ye HY, Chen YY, Liu M. Tightly coupled 3D Lidar inertial odometry and mapping. Proceedings of the 2019 International Conference on Robotics and Automation. Montreal: IEEE, 2019. 3144–3150.
- 11 Shan TX, Englot B, Meyers D, *et al.* LIO-SAM: Tightly-coupled Lidar inertial odometry via smoothing and mapping. Proceedings of the 2020 IEEE/RSJ International Conference on Intelligent Robots and Systems. Las Vegas: IEEE, 2020. 5135–5142.
- 12 Moore T, Stouch D. A generalized extended Kalman filter implementation for the robot operating system. In: Menegatti E, Michael N, Berns K, *et al.* eds. Intelligent Autonomous Systems 13. Cham: Springer, 2016. 335–348.
- 13 Nguyen TM, Xu XH, Jin TX, *et al.* Eigen is all you need: Efficient lidar-inertial continuous-time odometry with internal association. IEEE Robotics and Automation Letters, 2024, 9(6): 5330–5337. [doi: [10.1109/LRA.2024.3391049](https://doi.org/10.1109/LRA.2024.3391049)]
- 14 Debeunne C, Vivet D. A review of visual-LiDAR fusion based simultaneous localization and mapping. Sensors, 2020.

- 20(7): 2068. [doi: [10.3390/s20072068](https://doi.org/10.3390/s20072068)]
- 15 Li JP, Yuan SH, Cao MQ, *et al.* HCTO: Optimality-aware LiDAR inertial odometry with hybrid continuous time optimization for compact wearable mapping system. *ISPRS Journal of Photogrammetry and Remote Sensing*, 2024, 211: 228–243. [doi: [10.1016/j.isprsjprs.2024.04.004](https://doi.org/10.1016/j.isprsjprs.2024.04.004)]
- 16 Li JP, Wu WT, Yang BS, *et al.* WHU-Helmet: A Helmet-based multisensor SLAM dataset for the evaluation of real-time 3-D mapping in large-scale GNSS-denied environments. *IEEE Transactions on Geoscience and Remote Sensing*, 2023, 61: 5702016.
- 17 Liu X, Wen SH, Jiang ZM, *et al.* A multisensor fusion with automatic vision-LiDAR calibration based on factor graph joint optimization for SLAM. *IEEE Transactions on Instrumentation and Measurement*, 2023, 72: 9513809.
- 18 Liu X, Wen SH, Zhao J, *et al.* Edge-assisted multi-robot visual-inertial SLAM with efficient communication. *IEEE Transactions on Automation Science and Engineering*, 2025, 22: 2186–2198. [doi: [10.1109/TASE.2024.3376427](https://doi.org/10.1109/TASE.2024.3376427)]
- 19 Wang T, Su Y, Shao SL, *et al.* GR-Fusion: Multi-sensor fusion SLAM for ground robots with high robustness and low drift. *Proceedings of the 2021 IEEE/RSJ International Conference on Intelligent Robots and Systems*. Prague: IEEE, 2021. 5440–5447.
- 20 Shan TX, Englot B, Ratti C, *et al.* LVI-SAM: Tightly-coupled lidar-visual-inertial odometry via smoothing and mapping. *Proceedings of the 2021 IEEE International Conference on Robotics and Automation*. Xi'an: IEEE, 2021. 5692–5698.
- 21 Qin T, Li PL, Shen SJ. VINS-Mono: A robust and versatile monocular visual-inertial state estimator. *IEEE Transactions on Robotics*, 2018, 34(4): 1004–1020. [doi: [10.1109/TRO.2018.2853729](https://doi.org/10.1109/TRO.2018.2853729)]
- 22 Qin T, Cao SZ, Pan J, *et al.* A general optimization-based framework for global pose estimation with multiple sensors. *arXiv:1901.03642*, 2019.
- 23 Fan YC, Han H, Tang YL, *et al.* Dynamic objects elimination in SLAM based on image fusion. *Pattern Recognition Letters*, 2019, 127: 191–201. [doi: [10.1016/j.patrec.2018.10.024](https://doi.org/10.1016/j.patrec.2018.10.024)]
- 24 Sun YX, Liu M, Meng MQH. Improving RGB-D SLAM in dynamic environments: A motion removal approach. *Robotics and Autonomous Systems*, 2017, 89: 110–122. [doi: [10.1016/j.robot.2016.11.012](https://doi.org/10.1016/j.robot.2016.11.012)]
- 25 Sun YX, Liu M, Meng MQH. Motion removal for reliable RGB-D SLAM in dynamic environments. *Robotics and Autonomous Systems*, 2018, 108: 115–128. [doi: [10.1016/j.robot.2018.07.002](https://doi.org/10.1016/j.robot.2018.07.002)]
- 26 Wang YB, Huang SD. Towards dense moving object segmentation based robust dense RGB-D SLAM in dynamic scenarios. *Proceedings of the 13th International Conference on Control Automation Robotics & Vision*. Singapore: IEEE, 2014. 1841–1846.
- 27 Ochs P, Malik J, Brox T. Segmentation of moving objects by long term video analysis. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2014, 36(6): 1187–1200. [doi: [10.1109/TPAMI.2013.242](https://doi.org/10.1109/TPAMI.2013.242)]
- 28 Schauer J, Nüchter A. The peopleremover—Removing dynamic objects from 3-D point cloud data by traversing a voxel occupancy grid. *IEEE Robotics and Automation Letters*, 2018, 3(3): 1679–1686. [doi: [10.1109/LRA.2018.2801797](https://doi.org/10.1109/LRA.2018.2801797)]
- 29 Pomerleau F, Krüsi P, Colas F, *et al.* Long-term 3D map maintenance in dynamic environments. *Proceedings of the 2014 IEEE International Conference on Robotics and Automation*. Hong Kong: IEEE, 2014. 3712–3719.
- 30 Pagad S, Agarwal D, Narayanan S, *et al.* Robust method for removing dynamic objects from point clouds. *Proceedings of the 2020 IEEE International Conference on Robotics and Automation*. Paris: IEEE, 2020. 10765–10771.
- 31 Wang ZW, Liu GJ. Improved LeGO-LOAM method based on outlier points elimination. *Measurement*, 2023, 214: 112767. [doi: [10.1016/j.measurement.2023.112767](https://doi.org/10.1016/j.measurement.2023.112767)]
- 32 Qian CL, Xiang ZH, Wu ZR, *et al.* RF-LIO: Removal-first tightly-coupled lidar inertial odometry in high dynamic environments. *Proceedings of the 2021 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)*. Prague: IEEE, 2021. 4421–4428.
- 33 Bescos B, Fàcil JM, Civera J, *et al.* DynaSLAM: Tracking, mapping, and inpainting in dynamic scenes. *IEEE Robotics and Automation Letters*, 2018, 3(4): 4076–4083. [doi: [10.1109/LRA.2018.2860039](https://doi.org/10.1109/LRA.2018.2860039)]
- 34 Yu C, Liu ZX, Liu XJ, *et al.* DS-SLAM: A semantic visual SLAM towards dynamic environments. *Proceedings of the 2018 IEEE/RSJ International Conference on Intelligent Robots and Systems*. Madrid: IEEE, 2018. 1168–1174.
- 35 Cui LY, Ma CW. SOF-SLAM: A semantic visual SLAM for dynamic environments. *IEEE Access*, 2019, 7: 166528–166539. [doi: [10.1109/ACCESS.2019.2952161](https://doi.org/10.1109/ACCESS.2019.2952161)]
- 36 Wang K, Lin YM, Wang LW, *et al.* A unified framework for mutual improvement of SLAM and semantic segmentation. *Proceedings of the 2019 International Conference on*

- Robotics and Automation. Montreal: IEEE, 2019. 5224–5230.
- 37 Geiger A, Lenz P, Stiller C, *et al.* Vision meets robotics: The KITTI dataset. *International Journal of Robotics Research*, 2013, 32(11): 1231–1237. [doi: [10.1177/0278364913491297](https://doi.org/10.1177/0278364913491297)]
- 38 Hsu LT, Kubo N, Wen WS, *et al.* UrbanNav: An open-sourced multisensory dataset for benchmarking positioning algorithms designed for urban areas. *Proceedings of the 34th International Technical Meeting of the Satellite Division of the Institute of Navigation (ION GNSS+ 2021)*. St. Louis: Institute of Navigation, 2021. 226–256.
- 39 Wojke N, Bewley A, Paulus D. Simple online and realtime tracking with a deep association metric. *Proceedings of the 2017 IEEE International Conference on Image Processing (ICIP)*. Beijing: IEEE, 2017. 3645–3649.
- 40 Kampker A, Sefati M, Abdul Rachman AS, *et al.* Towards multi-object detection and tracking in urban scenario under uncertainties. *Proceedings of the 4th International Conference on Vehicle Technology and Intelligent Transport Systems*. Funchal: SciTePress, 2018. 156–167.
- 41 Tian XB, Zhu ZY, Zhao JQ, *et al.* DL-SLOT: Tightly-coupled dynamic LiDAR SLAM and 3D object tracking based on collaborative graph optimization. *IEEE Transactions on Intelligent Vehicles*, 2024, 9(1): 1017–1027. [doi: [10.1109/TIV.2023.3317308](https://doi.org/10.1109/TIV.2023.3317308)]
- 42 Du ST, Li YF, Li XY, *et al.* LiDAR odometry and mapping based on semantic information for outdoor environment. *Remote Sensing*, 2021, 13(15): 2864. [doi: [10.3390/rs13152864](https://doi.org/10.3390/rs13152864)]

(校对责编: 李慧鑫)