



中国科技期刊卓越行动计划项目入选期刊

控制与决策

CONTROL AND DECISION



基于扫描上下文优化的紧耦合激光SLAM方法

汪湘川, 张辉, 陈波, 周熙栋

引用本文:

汪湘川,张辉,陈波,周熙栋. 基于扫描上下文优化的紧耦合激光SLAM方法[J]. *控制与决策*, 2024, 39(10): 3234–3242.

在线阅读 View online: <https://doi.org/10.13195/j.kzyjc.2023.1167>

您可能感兴趣的其他文章

Articles you may be interested in

基于DST融合多视图模糊推理赋值的三维目标检测

3D object detection based on DST fusion multi-view fuzzy reasoning assignment

控制与决策. 2021, 36(4): 867–875 <https://doi.org/10.13195/j.kzyjc.2019.0434>

基于双边分解与 L_1 暗通道的战场图像增强算法

A battlefield image enhancement algorithm based on bilateral decomposition and L_1 dark channel prior

控制与决策. 2021, 36(5): 1165–1172 <https://doi.org/10.13195/j.kzyjc.2019.1213>

基于自适应正态云模型的灰狼优化算法

Grey wolf optimization algorithm based on adaptive normal cloud model

控制与决策. 2021, 36(10): 2562–2568 <https://doi.org/10.13195/j.kzyjc.2020.0233>

一种高匹配性的多层代价地图生成算法

A high matching layered costmap generation algorithm

控制与决策. 2020, 35(12): 2883–2888 <https://doi.org/10.13195/j.kzyjc.2018.0721>

基于动态网格k邻域搜索的激光点云精简算法

Laser point cloud simplification algorithm based on dynamic grid k-nearest neighbors searching

控制与决策. 2020, 35(12): 2986–2992 <https://doi.org/10.13195/j.kzyjc.2019.0444>

基于扫描上下文优化的紧耦合激光SLAM方法

汪湘川¹, 张辉^{2†}, 陈波², 周熙栋²

(1. 长沙理工大学 电气与信息工程学院, 长沙 410114; 2. 湖南大学 机器人学院, 长沙 410082)

摘要: 高精度地图与定位是无人车实现自主导航作业的重要前提, 针对现有松耦合融合方法对观测信息利用不充分, 以及传统闭环检测方法匹配精度低等问题, 提出一种基于扫描上下文优化的紧耦合激光 SLAM 方法——optimized SC-LIO-SAM. 首先, IMU 通过预积分对点云进行去偏校正, 同时为激光里程计提供初始位姿估计; 激光里程计通过滑动窗口的方法将当前帧的特征点云与局部地图匹配, 随后基于扫描上下文的方法对特征点云进行编码生成点云描述符, 实现高效的闭环检测; 基于 LIO-SAM 的框架, 将 IMU 预积分因子、激光里程计因子、GPS 因子以及闭环因子插入全局因子图中, 通过基于贝叶斯树的增量平滑优化算法对全局点云优化更新. 为了验证所提方法的有效性, 采用 KITTI 数据集评估 optimized SC-LIO-SAM 的性能, 并与 LOAM、LEGO-LOAM 以及 LIO-SAM 对比, 结果表明, optimized SC-LIO-SAM 相比于 LOAM、LEGO-LOAM 以及 LIO-SAM 等算法, 定位精度显著提升. 最后将算法应用在开源数据集中, 验证了 optimized SC-LIO-SAM 能够构建全局一致的地图.

关键词: SLAM; 激光里程计; 扫描上下文; 点云描述符; 闭环检测; 因子图优化

中图分类号: U463.6; TN958.98

文献标志码: A

DOI: 10.13195/j.kzyjc.2023.1167

引用格式: 汪湘川, 张辉, 陈波, 等. 基于扫描上下文优化的紧耦合激光 SLAM 方法 [J]. 控制与决策, 2024, 39(10): 3234-3242.

Tightly coupled laser SLAM method base on scan context optimization

WANG Xiang-chuan¹, ZHANG Hui^{2†}, CHEN Bo², ZHOU Xi-dong²

(1. School of Electrical and Information Engineering, Changsha University of Science and Technology, Changsha 410114, China; 2. School of Robotics, Hunan University, Changsha 410082, China)

Abstract: High-precision mapping and positioning is an important prerequisite for autonomous navigation of unmanned vehicles, and in view of the insufficient utilization of observation information by existing loosely coupled fusion methods and the low matching accuracy of traditional closed-loop detection methods, a tightly coupled laser SLAM method based on scan context optimization, named optimized SC-LIO-SAM, is proposed. First, the IMU debiases the point cloud through pre-integration and provides initial pose estimation for the laser odometer. The laser odometer matches the feature point cloud of the current frame with the local map by sliding the window. Then, based on the scan context, the feature cloud is encoded to generate point cloud descriptors to achieve efficient closed-loop detection. Based on the LIO-SAM framework, the IMU pre-integration factor, laser odometry factor, GPS factor and closed-loop factor are inserted into the global factor graph, lastly the global node optimization is updated by using Bayesian tree. In order to verify the effectiveness of the proposed method, the performance of the optimized SC-LIO-SAM is evaluated by KITTI dataset and compared with LOAM, LEGO-LOAM and LIO-SAM, and the experimental results show that the positioning accuracy of the optimized SC-LIO-SAM is significantly improved compared with LOAM, LEGO-LOAM, LIO-SAM and the classical algorithm. Finally, the algorithm is applied to the open-source dataset to prove that the optimized SC-LIO-SAM can build a globally consistent map.

Keywords: SLAM; laser odometry; scan context; point cloud descriptor; closed-loop detection; factor map optimization

0 引言

无人车 (unmanned ground vehicle, UGV) 被广泛用于大型仓库、战区安防、灾区救援等大范围且

复杂的场景中, 高精度地图与定位是无人车实现自主导航作业的重要前提, 其需通过构建稠密的高精度点云地图, 并基于地图实现精确定位, 一个低成本

收稿日期: 2023-08-16; 录用日期: 2023-12-19.

基金项目: 科技创新 2030-“新一代人工智能”重大项目 (2021ZD0114503); 国家自然科学基金重大研究计划项目 (92148204); 国家自然科学基金项目 (62027810, 61971071); 湖南省科技创新领军人才项目 (2022RC3063); 湖南省杰出青年科学基金项目 (2021JJ10025); 湖南省重点研发计划项目 (2021GK4011, 2022GK2011); 长沙科技重大项目 (KH2003026); 机器人国家重点实验室联合开放基金项目 (2021-KF-22-17); 中国高校产学研创新基金项目 (2020HYA06006).

†通讯作者. E-mail: zhanghuihy@126.com.

且高效的解决方案是同步定位与建图(simultaneous localization and mapping, SLAM)^[1]。根据传感器的不同,SLAM方法通常分为两大类:激光SLAM和视觉SLAM。与相机相比,激光雷达在测量精度、测量距离、抗光照干扰等方面更具有优势,这使激光SLAM在定位时通常更加准确^[2]。激光雷达按照类型可以分为2D激光雷达和3D激光雷达,2D激光雷达只能提供某一个平面上的测量信息,导致目前的2D激光雷达大多被用于室内小型机器人的定位系统上^[3],而无人车的工作环境大多为室外场景。3D激光雷达能够提供高精度测量信息,因此本文主要基于3D激光雷达开展研究。

若仅依靠单一传感器进行位姿估计与建图,无人车的定位精度与建图一致性都无法适应复杂的室外场景。惯性测量单元(inertial measurement unit, IMU)短时间内可提供高频准确的位姿信息,但长期运行产生较大的累积误差会导致定位失败;全球定位系统(global position system, GPS)在宽敞的室外可以提供米级的定位^[4],但其在桥梁、隧道等拒止环境下信号缺失,定位误差巨大。同时,无人车在室外环境的长距离运行下,产生的位姿累积误差难以消除,进而导致定位失败。现有的主流闭环检测方法大都是基于欧氏距离的最近邻搜索,仅能大范围内粗略定位至距离最近场景,随着场景的越发复杂,计算量巨大且易导致闭环检测失败。为了解决上述问题,本文提出一种解决方案,首先使用IMU通过预积分对点云进行去偏校正,同时为激光里程计提供初始位姿估计,激光雷达通过滑动窗口的思想实现激光里程计;采用基于扫描上下文(scan context, SC)^[5]的点云描述符的位置识别方法作为闭环检测,修正偏移误差;GPS因子作为绝对测量值,与IMU预积分因子、激光里程计因子以及闭环因子一起插入全局因子图,进而构建全局一致的地图和实现精准的定位。

本文的主要贡献如下:

1) 在LIO-SAM框架下,提出一种基于扫描上下文优化的紧耦合激光SLAM方法,解决现有松耦合融合方法对观测信息利用不充分,以及传统闭环检测方法匹配精度低的问题。

2) 提出将特征点云基于扫描上下文生成点云描述符的方法,将对应的特征点云作为闭环检测模块的输入,缩短闭环检测所需的时间。

3) 设计一种自适应距离阈值的方法来识别是否构建闭环,降低扫描上下文的方法检测出假闭环的可能性,有效提高定位精度。

1 相关工作

激光里程计通过建立短时间内的点云数据关联,对无人车的位姿进行实时的计算。扫描匹配是利用连续点云进行位姿估计的核心方法,其中迭代最近点算法(iterative closest points, ICP)^[6-7]是最经典的算法。文献[8]将2D激光雷达安装在编码器和转台上获取环境信息,并通过ICP算法进行运动估计。文献[9]通过3D激光雷达和ICP提出了一种基于匀速运动模型点云扭曲的补偿方法,并对结果进行了分析。这两种方法都采用ICP算法直接对全部点云进行处理,计算量大且匹配效率低;同时,这两种方法缺少对扫描匹配误差累积的后端优化处理。文献[10]提出了多分辨率格网(multi-resolution, MRS)的地图表达方法和一种基于点云表面元模型的概率配准算法,并且提出了一种分层优化的后端图优化策略^[11]。但是该方法将构建的地图也作为变量节点加入到了后端优化中,计算量较大,很难在无人车上部署,且难以达到实时性的要求。

文献[12]提出了一种基于特征的帧间匹配方法(lidar odometry and mapping, LOAM),该方法已成为目前最经典的帧间匹配方法。该方法基于扫描点的平滑度提取特征点(边缘点和平面点),通过点到边和点到面的联合匹配方法估计激光雷达的姿态变换,自KITTI里程测量基准网站发布以来,一直被评为基于激光雷达的最佳方法^[13]。文献[14]指出LOAM在计算资源有限时性能会下降,进而提出了一种面向无人车的地面优化和轻量级LOAM方法(lightweight and ground-optimized LOAM, LEGO-LOAM)。该方法增加了地面点云分割模块,滤除了不可靠特征的地面点云,同时加入了闭环检测模块实现对累积误差的修正。但是这两种方法中IMU提供的位姿信息仅作为扫描匹配和点云去畸变的运动估计的先验信息,并没有作为观测约束加入到全局优化,属于IMU与激光雷达的松耦合融合,在大范围且拥有较多回环的室外环境下,极易出现匹配错误进而导致定位和地图构建的失败。文献[15]在文献[14]的基础上基于因子图制定了激光惯性里程计,可以将大量相对和绝对测量(包括闭环检测)作为因子纳入系统,提出了一种基于平滑和映射的紧密耦合激光雷达惯性里程计框架(tightly-coupled lidar inertial odometry via smoothing and mapping, LIO-SAM),采用一种高效的、基于本地滑动窗口的扫描匹配方法,通过选择性地将新关键帧注册到固定大小的先前子关键帧集来实现实时性能。该方法通过因子图优化实现了IMU与激光雷达

的紧耦合,特别适用于多传感器融合,但是其闭环检测模块采用的是基于欧几里得距离的ICP匹配方法,闭环匹配精度较低,并且随着时间的推移,计算量越发巨大.文献[16]提出了一种双目视觉辅助的激光惯导SLAM算法,采用双目视觉惯导里程计算法为激光扫描匹配模块提供视觉先验位姿,基于迭代最近点匹配算法与基于图像特征匹配算法融合的混合闭环检测策略,进一步提高了全局轨迹精度.该方法解决了纯激光SLAM算法在环境结构特征缺乏时的退化问题,但是其各个模块计算量较大,实时性难以满足无人车自主作业的要求.

多传感器数据紧耦合融合算法大体可分为滤波算法和平滑算法两大类^[17-18].基于滤波的算法源于贝叶斯估计理论,在室内或小范围场景应用中具有不错的效果,但由于只考虑无人车的当前位姿和当前环境观测信息,不具有回环检测能力,存在线性化以及更新效率低等问题^[19],这使得它在室外大场景下的表现效果比较差.平滑算法在SLAM问题中应用较多的是固定滞延平滑(fixed-lag smoothing)^[20],通过在时间轴上设置一个随时间滑动的固定窗口,每次只优化计算固定窗口内的变量,同时边缘化剩余变量.该算法在优化迭代时所有变量都将重新线性化,因此线性化累积误差小,保证了算法的精度;另外因为滑动窗口的大小固定,优化的变量个数基本不变,保证了算法的实时性.该算法的不足之处是变量边缘化时协方差矩阵变得稠密,增加了一定的计算负担,影响了计算效率^[21].文献[22]通过因子图(factor graph)来表示变量之间的关系,进而提出了一种增量式平滑优化算法,代表着当前最先进的优化方法,该算法将因子图保存在贝叶斯树^[23]中,当有新的变量因子添加到因子图中时,对因子图中被影响部分的变量节点进行优化更新,避免了大量的重复计算,占用

系统内存低.

2 所提出的SLAM方法

针对现有松耦合融合方法对观测信息利用不充分,以及传统闭环检测方法匹配精度低等问题,多传感器紧耦合SLAM方法的研究具有重要的现实意义.本文基于LIO-SAM^[15]的因子图框架,采用扫描上下文^[5]的点云描述符,提出一种基于扫描上下文优化的紧耦合激光SLAM方法,将IMU预积分因子、激光里程计因子、GPS因子以及闭环因子插入全局因子图中,通过基于贝叶斯树的增量平滑优化算法对全局节点优化更新,实现多源数据的紧耦合融合.实验结果表明本文提出的方法可以满足无人车自主作业的实时定位需求,构建全局轨迹一致的环境地图.

2.1 基于因子图优化的SLAM框架

世界坐标系定义为 W ,无人车本体坐标系定义为 B ,为了简洁方便,保持IMU坐标系与无人车坐标系重合.原点为初始化时无人车坐标系中心, z 轴方向与世界坐标系下的重力方向对齐.无人车的状态 x 可以通过下述表达式表示:

$$x = [R^T, p^T, v^T, b^T]^T. \quad (1)$$

其中: $R \in \text{SO}(3)$ 为三维旋转矩阵; p 为欧氏空间下的位置向量, $p \in \mathbb{R}^3$; v 为欧氏空间下的速度, $v \in \mathbb{R}^3$; b 为IMU的零偏,包括陀螺仪零偏 b_t^g 和加速度零偏 b_t^a , $b \in \mathbb{R}^6$;从无人车坐标系 B 到世界坐标系 W 的变换矩阵 $T \in \text{SE}(3)$,表示为 $T = [R|p]$.

本文所提出的基于扫描上下文优化的紧耦合激光SLAM系统框架如图1所示,系统接收来自3D激光雷达的原始点云数据、IMU输出的角速度和加速度数据以及GPS的绝对测量值.在上述假设和定义下,通过传感器获得观测信息,此时状态估计问题可以描述为一个最大后验概率(maximum a posteriori,

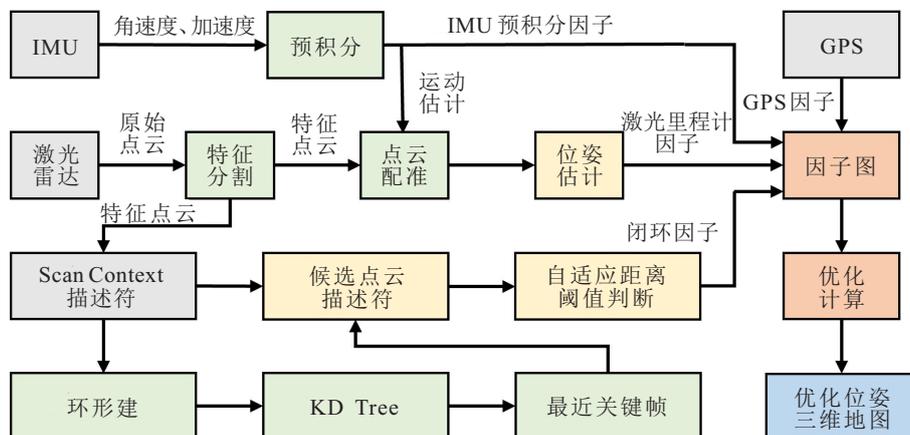


图1 系统整体框架

MAP)估计问题,采用因子图优化来解决这个问题,因为其于与贝叶斯网络相比更适合进行递推.在假设噪声为高斯测量模型的情况下,将最大后验概率问题转变为求解一个非线性最小二乘问题^[24].系统引入了4种不同类型的因子和一种变量来构建因子图,变量定义为无人车在特定时间的状态,属于因子图中的节点,4种因子分别是IMU预积分因子、激光里程计因子、GPS因子以及闭环因子.当无人车的位姿变化超过定义的阈值时,新的无人车状态节点 x 将被添加到因子图中,通过基于贝叶斯树的增量平滑优化算法对整个因子图优化计算一次,更新当前时刻的位姿估计,实现点云数据和IMU数据的紧耦合融合.后文将对上述4种不同因子的生成过程进行详细说明.

2.2 IMU预积分因子

IMU的观测模型由角速度和加速度测量构成,通过如下公式定义:

$$\hat{\omega}_t = \omega_t + b_t^\omega + n_t^\omega, \quad (2)$$

$$\hat{a}_t = R_t^{BW}(a_t - g) + b_t^a + n_t^a. \quad (3)$$

其中: $\hat{\omega}_t$ 和 \hat{a}_t 是无人车坐标系 t 时刻IMU的原始测量值, $\hat{\omega}_t$ 和 \hat{a}_t 受IMU零偏 b_t 和观测噪声 n_t 的影响, $\hat{\omega}_t \in \mathbb{R}^3$, $\hat{a}_t \in \mathbb{R}^3$, $b_t^\omega \in \mathbb{R}^3$, $n_t^\omega \in \mathbb{R}^3$, $b_t^a \in \mathbb{R}^3$, $n_t^a \in \mathbb{R}^3$; R_t^{BW} 是世界坐标系 W 到无人车坐标系 B 的旋转矩阵; g 是 W 中恒定的重力加速度.

然后,基于IMU测量的角速度和加速度推断无人车的运动.无人车在时间 $t + \Delta t$ 处的速度、位置和旋转变换可以由以下公式计算获得:

$$v_{t+\Delta t} = v_t + g\Delta t + R_t(\hat{a}_t - b_t^a - n_t^a)\Delta t, \quad (4)$$

$$p_{t+\Delta t} = p_t + v_t\Delta t + \frac{1}{2}g\Delta t^2 + \frac{1}{2}R_t(\hat{a}_t - b_t^a - n_t^a)\Delta t^2, \quad (5)$$

$$R_{t+\Delta t} = R_t \exp((\hat{\omega}_t - b_t^\omega - n_t^\omega)\Delta t). \quad (6)$$

由于IMU输出频率很高,状态估计时若直接将IMU $t + \Delta t$ 时刻对应的全部位姿作为变量节点插入因子图进行优化,显然是不切实际的^[22].因此采用预积分的方法,将高频输出的角速度和加速度测量值转变为状态间的位姿变换.时间点 i 与时间点 j 之间的预积分测量可通过以下公式计算:

$$\Delta v_{ij} = R_i^T(v_j - v_i - g\Delta t_{ij}), \quad (7)$$

$$\Delta p_{ij} = R_i^T(p_j - p_i - v_i\Delta t_{ij} - 1/2g\Delta t_{ij}^2), \quad (8)$$

$$\Delta R_{ij} = R_i^T R_j. \quad (9)$$

通过上述预积分,将所有IMU测量值转化为一个预积分观测量,自然地构成了因子图的一个约束因子——IMU预积分因子.

2.3 激光里程计因子

当系统接收到新的激光雷达扫描数据 P 时,首先进行特征提取,采取与文献[12]相同的提取方法,通过评估局部区域上点的粗糙度来提取边缘特征和平面特征,计算曲率

$$c = \frac{1}{|S| \cdot \|X_i\|} \left\| \sum_{j \in S, j \neq i} (X_i - X_j) \right\|. \quad (10)$$

其中: X_i 、 X_j 分别表示不同激光点的坐标; S 选取为10,表示该激光点位于同一激光线根据时间戳顺序选取前后各5个点.将 c 较大的点记为边缘点,将 c 较小的点记为平面点.将在 i 时刻从原始点云 P_i 提取的边缘特征和平面特征分别表示为 P_i^e 和 P_i^f ,此时所有特征点云组成激光雷达帧 F_i ,即 $F_i = \{P_i^e, P_i^f\}$.

为了服务于无人车作业,设计一个轻量级且实时运行的激光里程计,使用与文献[15]类似的方法,采取滑动窗口的思想,维护一个固定长度的栈.设置一个添加新关键帧的平移和旋转变换阈值,分别为1.5 m和 15° ,当无人车在 i 时刻与 $i + 1$ 时刻之间的位姿变换超过这个阈值时,则当前激光雷达帧 F_{i+1} 被认为是关键帧,进而与因子图中的无人车新位姿 x_{i+1} 相关联,同时两个关键帧之间的激光雷达帧将被丢弃.基于滑动窗口的激光里程计的算法步骤包括以下两步:

步骤1:关键帧提取.在时间轴上提取 n 个最新的子关键帧进行估计,子关键帧用 $\{F_{i-n}, \dots, F_i\}$ 表示,然后基于它们与世界坐标系相关联的变换矩阵 $\{T_{i-n}, \dots, T_i\}$ 将子关键帧投影到世界坐标系 W 下.变换后的子关键帧拼接为一个点云投影图 M_i ,由边缘特征点云投影图 M_i^e 与平面特征点云投影图 M_i^f 组成,激光雷达帧和点云投影图相互关联,关系如下所述:

$$M_i = \{M_i^e, M_i^f\}, \quad (11)$$

$$M_i^e = \dot{P}_i^e \cup \dot{P}_{i-1}^e \cup \dots \cup \dot{P}_{i-n}^e, \quad (12)$$

$$M_i^f = \dot{P}_i^f \cup \dot{P}_{i-1}^f \cup \dots \cup \dot{P}_{i-n}^f, \quad (13)$$

其中 \dot{P}_i^e 和 \dot{P}_i^f 是变换到世界坐标系 W 下的边缘特征和平面特征.同时,为了消除落在同一点云投影图的重复特征,对 M_i^e 和 M_i^f 进行下采样的操作处理.

步骤2:特征关联.首先将 $\{P_{i+1}^e, P_{i+1}^f\}$ 从无人车坐标系 B 变换到世界坐标系 W 下,得到 $\{\dot{P}_{i+1}^e, \dot{P}_{i+1}^f\}$.该初始变换是由高频的IMU预测运动 \tilde{T}_{i+1} 得到的,对于新获得的激光雷达帧 $\{\dot{P}_{i+1}^e, \dot{P}_{i+1}^f\}$ 中的每个特征点,在点云投影图 M_i^e 和 M_i^f 中寻找对应的边缘关联与平面关联.使用以下公式计算特征与其边缘或平面关联对应关系之间的距离:

$$D_e = \frac{|(P_{i+1,k}^e - P_{i,u}^e) \times (P_{i+1}^e - P_{i,v}^e)|}{|P_{i,u}^e - P_{i,v}^e|}, \quad (14)$$

$$D_f = \frac{|(P_{i+1,k}^f - P_{i,u}^f) \cdot ((P_{i,u}^f - P_{i,v}^f) \times (P_{i,u}^f - P_{i,w}^f))|}{|(P_{i,u}^f - P_{i,v}^f) \times (P_{i,u}^f - P_{i,w}^f)|}. \quad (15)$$

其中: $P_{i,u}^e \in \dot{P}_i^e$ 和 $P_{i,v}^e \in \dot{P}_i^e$ 是 $P_{i+1,k}^e \in \dot{P}_{i+1}^e$ 的最近邻点和次近邻点, $P_{i,u}^f \in \dot{P}_i^f$ 是 $P_{i+1,k}^f \in \dot{P}_{i+1}^f$ 的最近邻点, $P_{i,v}^f \in \dot{P}_i^f$ 是相邻线上的最近邻点, $P_{i,w}^f \in \dot{P}_i^f$ 是同一相邻线上的次近邻点. 上述特征匹配点都利用KD树搜索的方法得到. 随后, 使用两步Levenberg-Marquardt算法通过最小化距离的加权和来求解最优变换:

$$\min_{T_{i+1}} \left\{ \sum_{P_{i+1,k}^e \in \dot{P}_{i+1}^e} D_e + \sum_{P_{i+1,k}^f \in \dot{P}_{i+1}^f} D_f \right\}. \quad (16)$$

最终, 可以得到 X_i 与 X_{i+1} 之间的相对位姿变换 $\Delta T_{i,j+1}$, 也就是本文上述的激光里程计因子

$$\Delta T_{i,j+1} = T_i^T T_{i+1}. \quad (17)$$

同时, 因为变换后的 \dot{P}_i^e 和 \dot{P}_i^f 可以多次重复使用, 可以提高激光里程计的计算效率.

2.4 GPS因子

尽管IMU短时间内可提供高频准确的位姿信息, 结合激光里程计因子, 系统可以获得较为可靠的位姿估计和地图构建, 但系统在长时间作业中仍然存在漂移. 为了解决这个问题, 向系统加入GPS提供绝对测量值, 当系统接收到GPS数据时, 首先使用文献[25]中的方法转到局部笛卡尔坐标系. 当在因子图中添加新节点时, 将新的GPS因子与新节点相关联. 但并不是随意地向系统添加GPS因子, 因为GPS在卫星信号好的地方可以实现厘米级定位, 而在卫星信号差的地方只能实现单点定位, 且容易出现米级的跳变误差. 通过接收机显示能接收到信号的卫星星数来判断GPS信号好坏, 设置如下阈值来判断GPS数据是否有效:

$$\text{gps}_{\text{flag}} = \begin{cases} \text{fine, num} \geq 8; \\ \text{false, num} < 8. \end{cases} \quad (18)$$

其中: gps_{flag} 代表GPS数据是否有效, num 代表能接收到信号的卫星星数. 当GPS数据接收有效时, 只有当GPS的位姿协方差小于所估计的位姿协方差时, 才向系统中添加GPS因子.

2.5 扫描上下文优化的闭环因子

闭环检测模块检测无人车的轨迹是否形成闭合, 即无人车是否回到之前的位置. 本文所提方法的闭

环检测基于著名的扫描上下文框架[5], 为了简洁易懂, 扫描上下文的细节内容本文不再重复, 可以在文献[5]中找到具体内容, 此部分主要介绍所提出的方法与原始扫描上下文之间的不同.

原始扫描上下文通过原始点云数据形成全局描述符, 构建闭环, 通过对从激光里程计获得的边缘点云 P_i^e 与平面点云 P_i^f 编码来构建全局描述符, 作为闭环检测模块的输入. 特征点云 P_i^e 与 P_i^f 涵盖了原始点云数据几乎所有有用的信息, 通过使用特征点云代替原始点云, 可以减少冗余点云的影响, 从而提高闭环检测的准确性, 缩短闭环检测所需要的时间. 原始扫描上下文通过设置固定的阈值来确定和排除相似但距离甚远的点云对. 当阈值设置得较大时可能导致许多错误的回环, 出现大量假阳性的检测结果, 导致因子图优化时添加错误的边. 为了解决这个问题, 引入一种自适应距离阈值来取代传统的固定距离阈值, 当系统获得环路闭合检测结果时, 使用与环路闭合点云对相对应的位姿 T_i^W 与 T_{loop}^W 来计算两帧点云之间的距离, 有

$$T_i^{\text{loop}} = (T_{\text{loop}}^W)^{-1} T_i^W, \quad (19)$$

$$d = \sqrt{(T_i^{\text{loop}} \cdot x)^2 + (T_i^{\text{loop}} \cdot y)^2 + (T_i^{\text{loop}} \cdot z)^2}. \quad (20)$$

其中: T_i^{loop} 表示当前帧和通过激光里程计获取的当前帧位姿 T_i^W 与回环帧 T_{loop}^W 之间的位姿变换; $T_i^{\text{loop}} \cdot x$ 、 $T_i^{\text{loop}} \cdot y$ 、 $T_i^{\text{loop}} \cdot z$ 表示连接着当前帧与回环帧向量的 x 、 y 和 z 三个方向的分量, d 则表示该向量的大小. 若 d 大于阈值 $d_{\text{threshold}}$, 则认为该点云对未构成回环.

系统的累积误差随着无人车作业距离的增加而增加, 因此将阈值设计为与里程计关键帧相关联的函数, 有

$$d_{\text{threshold}} = 15 + k/n. \quad (21)$$

其中: k 为关键帧的数量, n 为根据激光里程计累积误差设计的参数, 参数15为通过设置不同参数确定的最佳阈值, $d_{\text{threshold}}$ 为引入的自适应距离阈值. 该阈值可以减少错误的闭环检测, 提高闭环检测的准确率, 进而提高因子图优化结果和整个SLAM算法的效率.

3 实验分析

3.1 基于KITTI数据集的实验评估

为验证所提出的 optimized SC-LIO-SAM (O-SC-LIO-SAM) 的有效性, 本文利用KITTI数据集[13]中的序列00和07进行系统的评估. 所有测试都是基于机器人操作系统(ROS)进行的, 系统安装在配备Intel(R) Pentium(R) CPU和8GB RAM以及Ubuntu 18.04平台的笔记本电脑上.

使用KITTI数据集来测试所提出的算法在户外场景中的性能. 所提出的方法在具有回环的场景下能够优化激光里程计的位姿估计, 同时, 为了兼顾温和的场景, 实验使用KITTI数据集中包含回环的序列00和无回环的序列07来评估所提出方法的定位精度和计算效率. 同时, 为了体现所提出方法的优越性, 通过使用相同的数据集, 将所提出的方法与LOAM^[12]、LEGO-LOAM^[14]、LIO-SAM^[15]等经典激光SLAM方法进行比较, 实验均在数据集×1的播放速率下进行.

图2显示了所提出的方法、比较的方法以及地面真值的轨迹差异, 图中GT代表地面真值(下文图3一致), 图2(b)和图2(d)分别对应图2(a)和图2(c)框选部分. 可以清楚地发现, 在具有回环场景的00数据集下, LOAM由于没有闭环检测模块, 出现大幅度漂移且没有形成完整闭环, LEGO-LOAM随着位移的增加表现出一定的轨迹偏差, LIO-SAM因为假闭环的存在导致了局部的漂移. 在场景较温和的07数据集下, 通过图2(d)可以看到本文算法以几乎与真实轨迹重合的表现优于其他对比的3种算法.

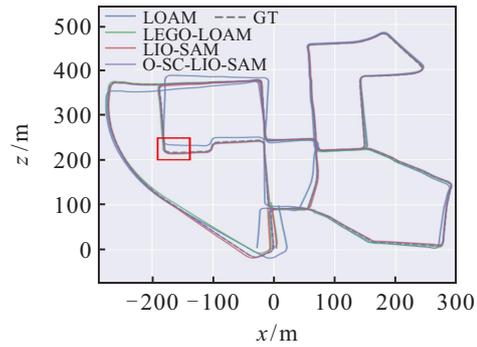
本文算法与LOAM、LEGO-LOAM、LIO-SAM具体精度对比由表1和表2体现. 其中: APE为绝对位姿误差, 用于评估整体轨迹的全局一致性; RPE为相对位姿误差, 用于验证局部旋转及平移的漂移量; max为最大误差值, min为最小误差值, mean为平均误差, rmse为均方根误差, std为标准差.

表1 KITTI数据集00序列误差比较 单位: m

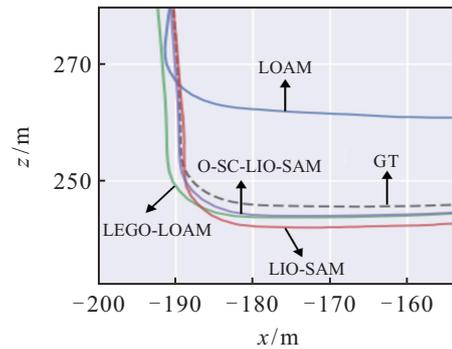
方法	误差类型	max	min	mean	rmse	std
LOAM	APE	27.49	2.63	10.44	12.33	6.56
	RPE	1.90	0.007	1.16	1.22	0.38
LEGO-LOAM	APE	14.55	2.85	4.16	4.77	2.32
	RPE	9.30	0.013	0.30	0.53	0.43
LIO-SAM	APE	9.99	2.58	4.56	3.83	1.60
	RPE	1.91	0.007	1.16	1.21	0.38
O-SC-LIO-SAM	APE	4.98	2.83	3.78	2.81	0.50
	RPE	1.70	0.02	0.30	0.42	0.29

表2 KITTI数据集07序列误差比较 单位: m

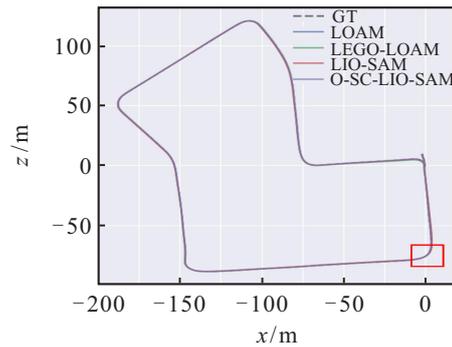
方法	误差类型	max	min	mean	rmse	std
LOAM	APE	2.71	2.44	2.54	2.54	0.07
	RPE	1.73	0.003	0.90	1.00	0.445
LEGO-LOAM	APE	3.50	2.84	3.00	3.01	0.16
	RPE	3.08	0.008	0.28	0.41	0.31
LIO-SAM	APE	3.07	1.69	2.51	2.55	0.41
	RPE	5.85	0.004	1.66	1.99	1.09
O-SC-LIO-SAM	APE	0.95	0.11	0.23	0.54	0.05
	RPE	0.85	0.001	0.16	0.33	0.12



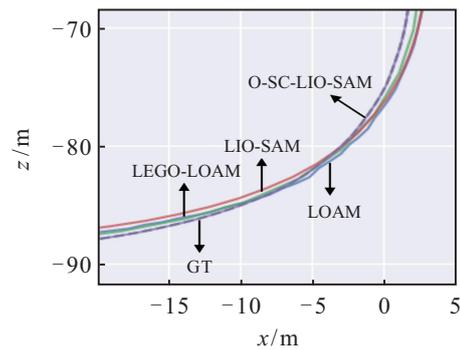
(a) KITTI 00 轨迹对比



(b) KITTI 00 轨迹细节



(c) KITTI 07 轨迹对比



(d) KITTI 07 轨迹细节

图2 KITTI数据集上的轨迹对比

具体而言, 在00数据集的测评中, 本文算法APE的平均误差相比于LOAM、LEGO-LOAM、LIO-SAM分别降低了63.79%、9.13%、17.11%; APE的均方根误差相比于LOAM、LEGO-LOAM、LIO-SAM分别降低了77.21%、41.10%、26.63%. 本文算法RPE的平均误差相比于LOAM、LIO-SAM都降低了74.14%, 与LEGO-LOAM持平; RPE的均

方根误差相比于 LOAM、LEGO-LOAM、LIO-SAM 分别降低了 65.57%、20.75%、65.29%。在 07 数据集的测评中,本文算法 APE 的平均误差相比于 LOAM、LEGO-LOAM、LIO-SAM 分别降低了 90.94%、92.33%、90.84%; APE 的均方根误差相比于 LOAM、LEGO-LOAM、LIO-SAM 分别降低了 78.74%、82.06%、78.82%。本文算法 RPE 的平均误差相比于 LOAM、LEGO-LOAM、LIO-SAM 分别降低了 82.22%、42.86%、90.36%; RPE 的均方根误差相比于 LOAM、LEGO-LOAM、LIO-SAM 分别降低了 67.00%、19.51%、84.31%。由此可见, O-SC-LIO-SAM 无论是定位的精度还是在大规模回环环境中的鲁棒性都要优于 LOAM、LEGO-LOAM 和 LIO-SAM 等算法。

所提出的方法在 KITTI 数据集 00 序列基准上的位置和方向变化如图 3 所示。O-SC-LIO-SAM 显著降低了平移定位误差,特别是二维位姿分量 (x, y, yaw) 非常接近真实地面的精度。GPS 因子的加入以及高效的闭环检测使得 O-SC-LIO-SAM 的位置和方向误差主要来源于高度、翻滚角和俯仰角的收敛精度,这对于无人车在平坦地形导航作业的影响很小。

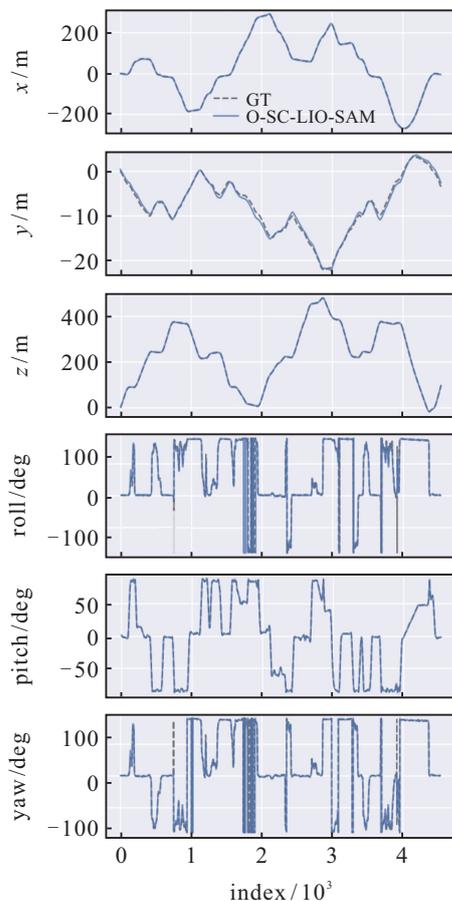


图3 KITTI数据集00序列位置和方向变化

为了验证 O-SC-LIO-SAM 的可部署性,在配备

Intel(R) Pentium(R) CPU 和 8 GB RAM 以及 Ubuntu 18.04 平台的计算机上,通过统计 00 序列数据集下各个算法的单帧数据处理时间比较运行效率;同时,因为 O-SC-LIO-SAM 在闭环检测模块进行了优化处理,计算每种方法在 00 序列下回环帧的计算时间,结果如表 3 所示。

表3 00序列下各个算法运行效率对比

方法	$t/(ms/frame)$	$t/(ms/loop\ frame)$
LOAM	100	-
LEGO-LOAM	70.5	133
LIO-SAM	127	239
O-SC-LIO-SAM	84.6	155

具体而言,在 00 数据集的测评中,本文算法单帧数据的处理时间相比于 LOAM 和 LIO-SAM 分别提高了 15.4% 和 33.4%,本文算法回环帧的计算时间相比于 LIO-SAM 提高了 35.1%, LOAM 因为没有闭环检测模块,因此没有回环帧的计算时间比较; LEGO-LOAM 是面向无人车的轻量型三维建图算法,整体运行效率略高于本文提出的算法。值得注意的是,LEGO-LOAM 闭环检测采用 GTSAM 库 ICP 处理回环帧易产生假闭环,本文算法在闭环检测模块需要计算闭环点对,因此消耗时间略长,但是能减少假闭环的可能。因此在具有回环的大场景下,本文所提出的方法既能拥有优秀的定位精度,同时也能满足其在无人车上部署的实时性要求。

3.2 基于 COONEO 开源数据集的实验验证

为验证所提出的 O-SC-LIO-SAM 的鲁棒性,将其应用在开源数据集上,同时与 LOAM、LEGO-LOAM、LIO-SAM 等算法进行对比。开源数据集采用的是 COONEO 团队发布的数据集^[26],是通过 NEOR mini 阿克曼移动底盘以及相关的传感器采集的深圳市南山区云之园的真实环境。

图 4 所示是三维地图构建的结果,图 4(a) 为 LOAM 算法得到的建图结果,图 4(b) 为 LEGO-LOAM 算法得到的建图结果,图 4(c) 为 LIO-SAM 得到的建图结果,图 4(d) 为本文提出的 O-SC-LIO-SAM 算法得到的建图结果。

由通过 4 种激光 SLAM 算法得到的三维地图与云之园实景对比可以看出, LOAM 算法因为缺乏闭环检测模块,回到起点时无法消除里程计累积误差,且场景点云稀疏,不能构建一致性地图; LEGO-LOAM 算法采用 GTSAM 库实现了简单的回环检测,但由图 4(b) 的红色方框处可以看出,系统无法实现严格的闭环,在较高建筑物处仍然存在一定的漂移,即

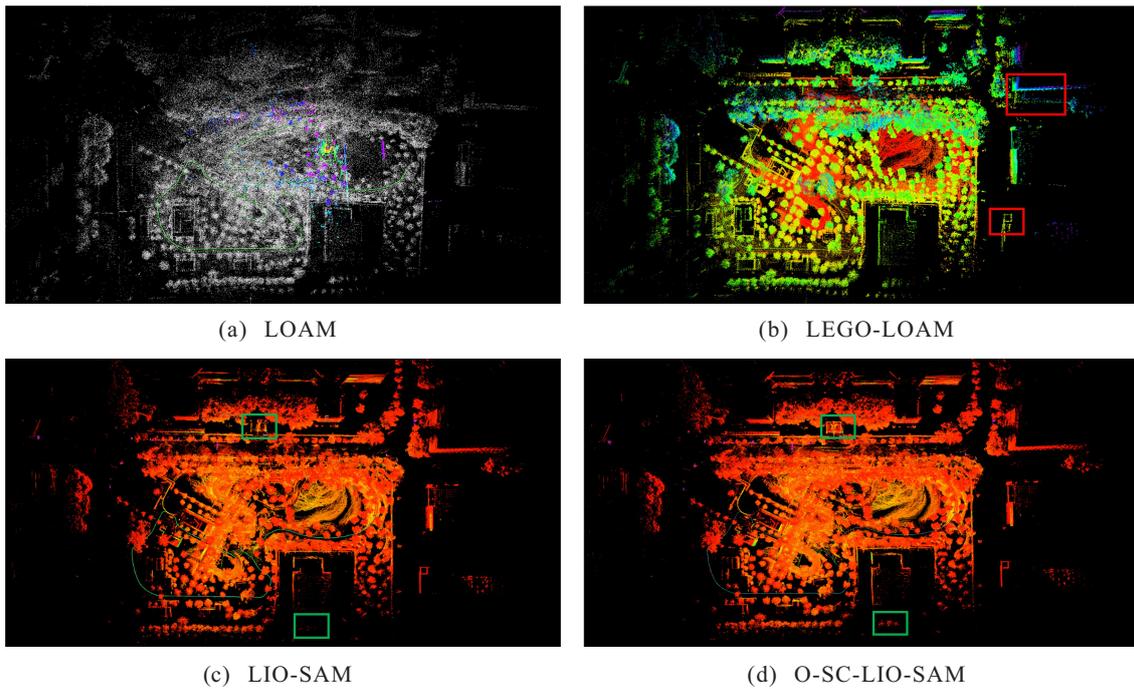


图4 4种算法地图构建对比

构图的偏移;LIO-SAM算法通过因子图实现了多传感器的紧耦合,能构建轮廓较为分明的三维地图.本文算法在地图构建中,一方面采用LIO-SAM的框架基于贝叶斯树的增量平滑优化算法实现因子图的全局优化,另一方面基于扫描上下文对闭环检测模块进行了优化执行严格的闭环检测.从图4(c)和图4(d)的绿色方框处可以看出,本文算法构建的三维地图在局部优于LIO-SAM算法.实验结果表明,本文提出的O-SC-LIO-SAM算法可以构建全局一致的三维地图.

4 结论

本文针对现有松耦合融合方法对观测信息利用不充分,以及传统闭环检测方法匹配精度低等问题,提出了一种基于扫描上下文优化的紧耦合激光SLAM方法.该方法采用LIO-SAM框架,基于贝叶斯树的增量平滑优化算法实现因子图的全局优化,可以有效地消除系统随时间产生的累积误差,同时基于扫描上下文对闭环检测模块进行优化,对激光里程计模块获取的特征点云进行编码形成点云描述符,通过自适应阈值的方法判断是否构成闭环,缩短了闭环检测所需的时间,减少了假闭环的可能性.在KITTI数据集上的实验结果表明,所提出的算法具有较高的定位精度,同时其在00数据集上的结果体现了所提算法在大回环场景下的鲁棒性;在COONEO开源数据集上真实环境建图结果证明,所提出的算法能够构建全局一致的三维地图.另外,本文算法构建的三维地图未包含环境的语义信息,从无人车作业的角度来看,

未来的工作是在此方法基础上加入视觉里程计.

参考文献(References)

- [1] Cadena C, Carlone L, Carrillo H, et al. Past, present, and future of simultaneous localization and mapping: Toward the robust-perception age[J]. *IEEE Transactions on Robotics*, 2016, 32(6): 1309-1332.
- [2] Wang H, Wang C, Chen C L, et al. F-LOAM: Fast LiDAR odometry and mapping[C]. 2021 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS). New York: ACM, 2021: 4390-4396.
- [3] 刘铮轩, 王亮, 李和平, 等. 融合双目视觉和2D激光雷达的室外定位[J]. *控制与决策*, 2023, 38(7): 1861-1868.
(Liu Z X, Wang L, Li H P, et al. Fusion of stereo vision and 2D LiDAR for outdoor localization[J]. *Control and Decision*, 2023, 38(7): 1861-1868.)
- [4] Drawil N M, Amar H M, Basir O A. GPS localization accuracy classification: A context-based approach[J]. *IEEE Transactions on Intelligent Transportation Systems*, 2013, 14(1): 262-273.
- [5] Kim G, Kim A. Scan context: Egocentric spatial descriptor for place recognition within 3D point cloud map[C]. 2018 IEEE/RSJ International Conference on Intelligent Robots and Systems. Madrid, 2018: 4802-4809.
- [6] Besl P J, McKay N D. A method for registration of 3-D shapes[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 1992, 14(2): 239-256.
- [7] Pomerleau F, Colas F, Siegwart R, et al. Comparing ICP

- variants on real-world data sets[J]. *Autonomous Robots*, 2013, 34(3): 133-148.
- [8] Surmann H, Nüchter A, Lingemann K, et al. 6D SLAM—Preliminary report on closing the loop in six dimensions[J]. *IFAC Proceedings Volumes*, 2004, 37(8): 197-202.
- [9] Moosmann F, Stiller C. *Velodyne slam*[C]. 2011 IEEE Intelligent Vehicles Symposium. Baden-Baden, 2011: 393-398.
- [10] Droschel D, Schwarz M, Behnke S. Continuous mapping and localization for autonomous navigation in rough terrain using a 3D laser scanner[J]. *Robotics and Autonomous Systems*, 2017, 88(C): 104-115.
- [11] Droschel D, Behnke S. Efficient continuous-time SLAM for 3D lidar-based online mapping[C]. *IEEE International Conference on Robotics and Automation (ICRA)*. Brisbane, 2018: 5000-5007.
- [12] Zhang J, Singh S. Low-drift and real-time lidar odometry and mapping[J]. *Autonomous Robots*, 2017, 41(2): 401-416.
- [13] Geiger A, Lenz P, Urtasun R. Are we ready for autonomous driving? The KITTI vision benchmark suite[C]. *2012 IEEE Conference on Computer Vision and Pattern Recognition*. Providence, 2012: 3354-3361.
- [14] Shan T X, Englot B. LeGO-LOAM: Lightweight and ground-optimized lidar odometry and mapping on variable terrain[C]. *2018 IEEE/RSJ International Conference on Intelligent Robots and Systems*. Madrid, 2018: 4758-4765.
- [15] Shan T X, Englot B, Meyers D, et al. LIO-SAM: Tightly-coupled lidar inertial odometry via smoothing and mapping[C]. *2020 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)*. New York: ACM, 2020: 5135-5142.
- [16] 刘辉, 张雪波, 李如意, 等. 双目视觉辅助的激光惯导 SLAM 算法[J]. *控制与决策*, 2024, 39(6): 1787-1800. (Liu H, Zhang X B, Li R Y, et al. Stereo vision aided lidar-inertial SLAM[J]. *Control and Decision*, 2024, 39(6): 1787-1800.)
- [17] Forster C, Carlone L, Dellaert F, et al. On-manifold preintegration for real-time visual-inertial odometry[J]. *IEEE Transactions on Robotics*, 2017, 33(1): 1-21.
- [18] Balazadegan S Y, Hosseinyalamdary S, Gao Y. Visual-LiDAR odometry aided by reduced IMU[J]. *ISPRS International Journal of Geo-Information*, 2016, 5(1): 3.
- [19] 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 Z G, Cao J W, Di S F. Overview of 3D lidar SLAM algorithms[J]. *Chinese Journal of Scientific Instrument*, 2021, 42(9): 13-27.)
- [20] Leutenegger S, Lynen S, Bosse M, et al. Keyframe-based visual-inertial odometry using nonlinear optimization[J]. *International Journal of Robotics Research*, 2015, 34(3): 314-334.
- [21] 李帅鑫, 李广云, 王力, 等. LiDAR/IMU紧耦合的实时定位方法[J]. *自动化学报*, 2021, 47(6): 1377-1389. (Li S X, Li G Y, Wang L, et al. LiDAR/IMU tightly coupled real-time localization method[J]. *Acta Automatica Sinica*, 2021, 47(6): 1377-1389.)
- [22] Indelman V, Williams S, Kaess M, et al. Factor graph based incremental smoothing in inertial navigation systems[C]. *2012 15th International Conference on Information Fusion*. Singapore, 2012: 2154-2161.
- [23] Kaess M, Johannsson H, Roberts R, et al. iSAM2: Incremental smoothing and mapping using the Bayes tree[J]. *The International Journal of Robotics Research*, 2012, 31(2): 216-235.
- [24] Dellaert F, Kaess M. Factor graphs for robot perception[J]. *Foundations and Trends in Robotics*, 2017, 6(1/2): 1-139.
- [25] Moore T, Stouch D. A generalized extended Kalman filter implementation for the robot operating system[C]. *Intelligent Autonomous Systems 13*. Cham: Springer, 2016: 335-348.
- [26] 酷牛. NEOR mini 自采数据集 LIO-SAM 建图[Z]. 深圳: 酷牛, 2022. (COONEO. NEOR mini mapped using self-harvesting dataset with LIO-SAM[Z]. Shenzhen: COONEO, 2022.)

作者简介

汪湘川(2000—), 男, 硕士生, 从事移动机器人定位与建图的研究, E-mail: wxwxc200087@163.com;

张辉(1983—), 男, 教授, 博士, 从事图像识别和深度学习等研究, E-mail: zhanghuihy@126.com;

陈波(1997—), 男, 博士生, 从事多机器人区域覆盖搜索的研究, E-mail: cbc233@gs.zzu.edu.cn;

周熙栋(1998—), 男, 博士生, 从事移动机器人路径规划和定位等研究, E-mail: 741170053@qq.com.