

DOI:10.19651/j.cnki.emt.2108310

# 基于滤波与图优化的定位与建图系统<sup>\*</sup>

华智<sup>1,2,3</sup> 宋吉来<sup>1,2,4</sup> 杜振军<sup>4</sup> 徐方<sup>1,2,4</sup> 刘明敏<sup>4</sup>

(1. 中国科学院沈阳自动化研究所机器人学国家重点实验室 沈阳 110016; 2. 中国科学院机器人与智能制造创新研究院 沈阳 110169; 3. 中国科学院大学 北京 100049; 4. 沈阳新松机器人自动化股份有限公司 沈阳 110168)

**摘要:** 针对室外大场景环境建图精度不高,地图出现重影和漂移等问题,提出一种融合滤波与图优化理论实时定位与建图系统。该系统由点云数据预处理、基于滤波紧耦合惯性里程计和后端位姿图优化等3部分构成。首先,点云数据预处理采用随机采样一致性算法分割地面,并提取地面模型参数构建后端优化中的地面约束因子。然后,前端紧耦合惯性里程计采用迭代误差状态卡尔曼滤波,以激光里程计作为观测值,IMU预积分结果作为预测值,通过构建联合函数,滤波融合得到较为精准的激光惯导里程计。最后,后端结合图优化理论引入闭环因子、地面约束因子以及帧与图匹配的里程计因子作为约束条件,构建因子图并优化地图位姿。其中闭环因子采用改进的扫描文本的闭环检测算法进行位置识别,可以降低环境误识别率。所提出的算法在室外厂区楼栋,停车场以及室内车间等多个场景完成场景建图,在距离、水平和高程3个方向的累积偏差均控制10 cm左右,能够有效解决地图的重影和漂移问题,具有高鲁棒性和高精度。

**关键词:** SLAM; 紧耦合; ESKF; 图优化; 闭环检测; 鲁棒性

中图分类号: TP242.3 文献标识码: A 国家标准学科分类代码: 460

## Based on filtering and graph optimization positioning and mapping system

Hua Zhi<sup>1,2,3</sup> Song Jilai<sup>1,2,4</sup> Du Zhenjun<sup>4</sup> Xu Fang<sup>1,2,4</sup> Liu Mingmin<sup>4</sup>

(1. State Key Laboratory of Robotics, Shenyang Institute of Automation, Chinese Academy of Sciences, Shenyang 110016, China;  
2. Institutes for Robotics and Intelligent Manufacturing, Chinese Academy of Sciences, Shenyang 110169, China;  
3. University of Chinese Academy of Sciences, Beijing 100049, China;  
4. Shenyang SIASUN Robot & Automation Co., Ltd., Shenyang 110168, China)

**Abstract:** Aiming at the problems of low mapping accuracy and map ghosting and drift in outdoor large scene environment, a simultaneous localization and mapping system integrating filtering and graph optimization theory is proposed. The system consists of three parts: point cloud data preprocessing, filtering based tight coupling inertial odometer and back-end pose map optimization. Firstly, the point cloud data preprocessing uses the random sampling consistency algorithm to segment the ground, extracts the ground model parameters, and constructs the ground constraint factors in the back-end optimization. Then, the front-end tightly coupled inertial odometer adopts iterative error state Kalman filter, takes the laser odometer as the observed value and the result of IMU pre-integration as the predicted value, and constructs a joint function to filter and fuse to obtain a more accurate laser inertial odometer. Finally, combined with the graph optimization theory, the closed-loop factor, ground constraint factor and odometer factor matched between frame and graph are introduced as constraints to construct the factor graph and optimize the map pose. The closed-loop factor adopts the improved closed-loop detection algorithm of scanned text for position recognition, which can reduce the environmental false recognition rate. The algorithm proposed completes scene mapping in multiple scenes such as outdoor plant buildings, parking lots and indoor workshops. The cumulative deviation in the three directions of distance, level and elevation is controlled by about 10 cm, which can effectively solve the problem of map ghosting and drift, and has high robustness and high precision.

**Keywords:** SLAM; tight coupling; ESKF; graph optimization; closed-loop detection; robustness

## 0 引言

随着无人驾驶和自主移动机器人产业的蓬勃发展,相

关的应用技术研究也成为热点。文献[1]提出实时定位与建图(simultaneous localization and mapping, SLAM)技术

对于自动驾驶和移动机器人行业发展至关重要。在复杂大

收稿日期:2021-11-10

\*基金项目:辽宁省科学技术计划-工业重大专项(2019JH1/10100005)、辽宁省“兴辽英才计划”项目(XLYC1907110)、辽宁省“百千万人才工程”项目(2020921001)资助

场景环境中,纯激光 SLAM 往往难以弥补传感器自身缺陷,文献[2]提出基于多传感器融合技术的 SLAM 方案逐渐成为研究热点。

激光 SLAM 最流行方案是 2014 年 Zhang 等<sup>[3]</sup>提出的 LOAM 框架,它基于角点和平面特征的匹配方法,相比于文献[4-5]提出迭代最近点(iterative closest point, ICP)和正态分布变换(normal distributions transform, NDT)等传统点云配准算法在建图精度和匹配效率上有了很大地提升,其中 ICP 算法精度对建图的初始值依赖很强,点对点配准效率不高。NDT 算法对初始值依赖不高,但是配准精度较低。其中 LOAM 算法框架中,前端缺少点云预处理,后端缺少回环检测,在大场景环境建图过程中,地图容易出现飘移和重影问题。对此,Shan 等<sup>[6]</sup>在 LOAM 的基础上提出了轻量级的 LEGO\_LOAM,它对前端点云做了预处理,通过地面分割算法分离出地面点云和非地面点云,通过聚类剔除算法对非地面点云进行降噪,可以提高前端点云配准的效率。同时 LEGO\_LOAM 中后端添加了基于半径搜索的闭环检测算法,可以一定程度上纠正位姿的误差,提高建图精度。但是它的基于激光俯仰角的地面分割算法存在误分割以及后端优化中回环检测算法回环检测效率不是很高,没有构建环境描述子,仅仅通过不断地检索过去帧。多传感器融合的 SLAM 框架通过多源传感器采集的数据可以消除部分单源里程计累计误差,提高定位与建图的精度。文献[7]提出的雷达/GNSS/IMU 组合导航系统融合 GNSS-RTK 位置、IMU 惯性里程计和激光里程计等信息实现了 5~10 cm 连续稳定车道级定位,但是精度很大程度上依赖于 GPS,而 GPS 往往对于高楼、大树等遮挡环境抗干扰很弱。针对这种问题,Qin 等<sup>[8]</sup>提出了一种视觉传感器与 IMU 的紧耦合方案,前端对帧间 IMU 数据预积分,通过联合优化所有的视觉、惯性信息来求解滑动窗口的状态估计值,可以得到相对精准的融合里程计,但是在室外大场景环境建图中,视觉传感器会遇到光照变化以及测量精度不高等问题。Ye 等<sup>[9]</sup>提出一种基于滑动窗口的雷达与 IMU 紧耦合方案 LIO-Mapping,采用局部滑动窗口对 IMU 预积分结果与雷达里程计结果进行融合误差补偿,最终得到前端里程计估计,可以提高前端里程计的估计值,有效地提高后端地图拼接的精度。但是整体上属于纯图优化方案,随着窗口不断移动,优化参数巨大,所以建图对处理器性能要求高。Shan 等<sup>[10]</sup>在 LEGO\_LOAM 的基础上,提出了一种基于因子图的优化方案 LIO-SAM,该种方案去除了前后帧的点云配准过程,比其他紧耦合建图方案精度更优,但是该种方案执行运算量大,实时性不高,难以适应一些需要实时建图定位的场景。闭环检测作为后端位姿优化重要的一环,它能够很好地调整前端的累计误差,Shan 等提出基于关键帧地图半径搜索算法,可以实现闭环,对于复杂的大场景环境闭环检测效率不高。文献[11]提出由于激光雷达获取的点云

数据是稀疏的,不能像视觉相机采集稠密的点云信息,所以难以通过构建环境语义信息进行环境识别实现回环检测,一般采用的是基于环境特征描述子的匹配识别。文献[12]提出的环境直方图方法,结果不确定大,容易出现误识别。文献[13]提出的扫描文本的方法,将三维点云划分为一个二维矩阵,构建二维图描述子,可以很好地解决旋转不变性问题。但是匹配信息仅仅填充点云最大高度容易导致场景信息丢失,误匹配率高。

本文在前人研究的基础上,提出了一种结合滤波和图优化方法的 SLAM 系统。它包括前端数据预处理、紧耦合激光惯性里程计、后端位姿优化等模块。首先前端预处理采用了随机采样一致性(random sampling consistency, RANSAC)算法分割地面,并将地平面模型参数提取出来构建地面约束因子。算法地面点云分割的精度高,同时引入地面约束因子,可以很好地解决大场景环境地图出现弯曲等问题。其次紧耦合激光惯性里程计模块引入了文献[14]提出的基于误差状态的迭代卡尔曼滤波(error state Kalman filter, ESKF),对 IMU 惯导的预测信息与激光点云配准的观测信息进行融合,通过多次迭代得到较为准确前端里程计估计值。滤波算法效率高,同时可以提高前端里程计精度。最后在后端位姿优化模块引入文献[15]提出的图优化理论,以地面约束因子,闭环因子,里程计因子作为图优化的约束条件,对后端地图位姿进行优化,可以提高地图的精度以及提高系统的鲁棒性。本框架后端优化中的闭环因子,采用降维的思路构建地图描述子,通过环境描述子之间的匹配相识度得分构建闭环。地面约束因子通过假设全局一致性地面存在,通过当前地面点与全局一致地面的距离构建地约束因子。将后端位姿优化问题转为最小二乘问题,通过 GTSAM 优化库求解位姿。

本文的贡献主要有如下 3 点:1)点云数据预处理中采用 RANSAC 算法实现地面分割,并通过地面模型参数构建闭环因子;2)前端通过迭代 ESKF 算法对 IMU 和激光里程计数据进行融合,后端通过图优化理论优化地图位姿;3)提出一种改进的扫描文本闭环检测算法构建闭环因子,有效提高闭环精度。

## 1 前端数据预处理

### 1.1 RANSAC 算法地面分割

地面优化主要是对地面点云进行分割提取,激光建图点云中地面点云占据了 1/3,通过地面分割可以降低面特征提取的数量,提高配准的效率。通过地面分割,可以从地面点集提取地面模型参数构建约束项,防止大场景建图中地图弯曲。同时地面点云的分离,可以减少面特征数量,提高配准的效率。本文采用基于平面模型的随机采样一致性(RANSAC)算法提取平面模型,可以有效提高分割精度和提取地面模型参数。

1)原始点云 $P_{raw}$ 进行直通滤波和法向量滤波,根据机器人激光雷达坐标系 $L_{lidar}$ 与地平面的距离 $H$ 设定一个阈值 $\Delta h$ ,统计中点云 $P_{raw}$ 的Z值在阈值以内的点云集 $P_z$ ,如式(1)所示。

$$H - \Delta h \leq z_i \leq H + \Delta h \quad (1)$$

其中, $p_{z_i} \in P_z$ 。

2)根据激光雷达的安装坐标系,可以确定地平面的法向量是 $n_g = (0, 0, 1)$ ,计算 $P_z$ 中点云的法向量 $n_i = (x_i, y_i, z_i)$ ,通过余弦公式计算向量夹角 $\theta_i$ ,考虑到计算误差,统计 $\theta_i$ 在 $15^\circ$ 以内的点云集 $P_n$ ,如式(2)所示。

$$\theta_i = \arccos \frac{\mathbf{n}_g \cdot \mathbf{n}_i}{|\mathbf{n}_g| * |\mathbf{n}_i|} \quad (2)$$

其中, $p_{\theta_i} \in P_n$ 。

3)从 $P_n$ 点云集中随机选取3个点,确定一个平面。平面方程的一般形式: $ax + by + cz = d$ ,其中系数满足 $a^2 + b^2 + c^2 = 1, d > 0$ ,平面的法向量为 $(a, b, c), d$ 为原点到平面的距离。在原始点云 $P_{raw}$ 中随机选取3个点 $\{P_1(x_1, y_1, z_1), P_2(x_2, y_2, z_2), P_3(x_3, y_3, z_3)\}$ 。根据 $P_1, P_2, P_3$ 求解平面S的方程,如式(3)所示。

$$\begin{aligned} ax_1 + by_1 + cz_1 &= d \\ ax_2 + by_2 + cz_2 &= d \\ ax_3 + by_3 + cz_3 &= d \end{aligned} \quad (3)$$

4)统计点云集 $P_n$ 中在平面S中的点云个数,设定一个平面厚度阈值 $\epsilon$ (点面距离),计算 $P_n$ 中任意点 $P_i(x_i, y_i, z_i)$ 到S的距离 $d_i$ ,如式(4)所示。

$$d_i = |ax_i + by_i + cz_i - d| \quad (4)$$

统计 $d_i < \epsilon$ 的所有点云个数,记作得分 $f(d_i)$ 。

5)循环重复上述步骤1)、2) $K$ 次,选择 $f_{max}$ 的平面 $S_x$ ,计算 $K$ 值,如式(5)所示。

$$1 - (1 - C_m^n C_{m-1}^{n-1} C_{m-2}^{n-2})^K = \phi \quad (5)$$

其中, $m$ 为 $P_n$ 中点云个数, $n$ 为平面S上点的个数, $\phi$ 代表采样 $K$ 次地平面选中的概率,由于 $m$ 和 $n$ 都很大,采用近似替代,如式(6)所示。

$$1 - (1 - (1 - \lambda)^3)^K = \phi \quad (6)$$

式中: $\lambda$ 代表位于 $S_x$ 之外的概率,两边取对数,如式(7)所示。

$$K = \frac{\log(1 - \lambda)}{\log(1 - (1 - \lambda)^3)} \quad (7)$$

重新拟合修正选取的地平面数据,得到误差最小的地平面参数 $(a, b, c, d)$ 。

通过步骤1)~5)可以提取出地平面点云数据,并在室内、外场景分别验证地面分割算法的有效性,通过实验论证,本文地面分割算法可以适应室内室外等复杂场景,对于墙面和道路边界等噪点有很好的过滤作用,如图1(a)所示室外场景地面分割,如图1(b)所示是室内场景分割,其中圆弧状点云为分割的地平面点云,其他为环境点云。

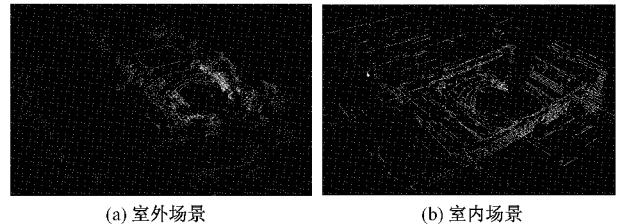


图1 地面分割实验结果

## 1.2 地面约束

室外大场景环境建图往往随着里程计的累计误差,在没有GPS信息约束情况下,往往由于累计误差影响,地图在高度方向误差比较大。针对一些高程差比较小的地区,本方法通过在当前地平面与全局一致性地面之间构建残差项,形成地面约束,可以在很大程度上修正 $[t_z, \theta_{roll}, \theta_{pitch}]^T$ 三自由度,具体实施如下。

1)首先通过RANSAC算法计算第1帧点云的地平面模型,并将平面的参数和法向量保存, $ax + by + cz = d$ ,其中 $a^2 + b^2 + c^2 = 1, d > 0, [a, b, c]^T$ 是平面的法向量。

2)提取当前帧的平面点云,并进行降采样,得到降采样后的 $P_{groundDS}$ 地平面点云,其中 $p_{gi}(x_{gi}, y_{gi}, z_{gi})$ 属于 $P_{groundDS}$ 。

3)计算 $P_{groundDS}$ 中点 $p_{gi}$ 与全局一致性地面的距离,并构建最小二乘问题,如式(8)所示。

$$\min \left\{ \sum_{p_{gi} \in P_{groundDS}} (ax_{gi} + by_{gi} + cz_{gi} - d)^2 \right\} \quad (8)$$

4)通过LM优化求解最小二乘问题,最终得到优化后的 $[t_z, \theta_{roll}, \theta_{pitch}]^T$ ,本约束可以在无斜坡场景中有效提高建图精度。

## 2 紧耦合激光惯性里程计

激光雷达可以通过前后帧点云粗匹配得到6-DOF位姿信息,而IMU可以通过预积分得到6-DOF位姿信息,两者的里程计输出都存在一定的累计误差,尤其是对于大场景SLAM系统中,常常会导致地图丢失位置信息。松耦合方案直接采用两种传感器的位姿信息进行补偿,虽有一定的修正,但是误差依然很大。为了减小误差,本文采用的是基于误差状态的IEKF紧耦合方案,通过构建融合损失函数,对误差进行迭代弥补最终获得较为精准的里程计估计值。雷达融合里程计(LIO)具体方案如下。

1)首先,定义3个坐标系,包括世界系 $F_w$ 、雷达系 $F_{l_k}$ 、IMU系 $F_{b_k}$ ,其中 $F_{l_k}$ 和 $F_{b_k}$ 代表第 $K$ 帧的雷达和IMU的坐标系。其中 $F_{b_k}$ 与机器人坐标系固联。接着,定义滤波器的状态,让 $x_w^{b_k}$ 代表机器人在世界坐标系 $F_w$ 的位姿, $x_{b_{k+1}}^{b_k}$ 表示机器人从 $F_{b_{k+1}}$ 到 $F_{b_k}$ 的状态变换,如式(9)和(10)所示。

$$x_w^{b_k} = [p_w^{b_k}, q_w^{b_k}] \quad (9)$$

$$x_{b_{k-1}}^{b_k} = [p_{b_{k+1}}^{b_k}, v_{b_{k-1}}^{b_k}, q_{b_{k+1}}^{b_k}, \varepsilon_a, \varepsilon_g, g^{b_k}] \quad (10)$$

其中,  $p_w^{b_k}$  和  $q_w^{b_k}$  分别代表机器人  $F_{b_k}$  系相对于  $F_w$  的位置和姿态;  $p_{b_{k-1}}^{b_k}$  和  $q_{b_{k+1}}^{b_k}$  分别代表  $F_{b_{k-1}}$  到  $F_{b_k}$  位置和姿态变换;  $v_{b_{k+1}}^{b_k}$  代表的机器人  $F_{b_k}$  系下的速度;  $\varepsilon_a$  和  $\varepsilon_g$  代表的是加速度和角速度零偏;  $g^{b_k}$  代表的是  $F_{b_k}$  系下的重力加速度。

2)根据状态量确定误差量,  $\delta x$  代表状态  $x_{b_{k+1}}^{b_k}$  的误差量, 如式(11)所示。

$$\delta x = [\delta p, \delta v, \delta \theta, \delta \varepsilon_a, \delta \varepsilon_g, \delta g] \quad (11)$$

其中,  $\delta \theta$  代表 3-DOF 角度误差。

3)根据 ESKF 中误差状态定义, 误差量可以直接累加到状态的先验值, 如式(12)所示。

$$x_{b_{k-1}}^{b_k} = {}'x_{b_{k-1}}^{b_k} \oplus \delta x = \begin{bmatrix} {}'p_{b_{k-1}}^{b_k} + \delta p \\ {}'v_{b_{k+1}}^{b_k} + \sigma v \\ {}'q_{b_{k-1}}^{b_k} \otimes \exp(\delta \theta) \\ {}'\varepsilon_a + \delta \varepsilon_a \\ {}'\varepsilon_g + \delta \varepsilon_g \\ {}'g^{b_k} + \delta g \end{bmatrix} \quad (12)$$

其中, 运算符  $\otimes$  代表四元素积, 运用于角度向量转为四元素旋转量,  $'x_{b_{k+1}}^{b_k}$  代表状态的先验值。

4)误差状态方程, 其中  $\delta x$  的协方差矩阵为  $P_k$ , IMU 的线性连续时间误差状态方程, 如式(13)所示。

$$\delta x = F_t \delta x + G_t W \quad (13)$$

其中,  $F_t$  代表误差状态变换矩阵,  $G_t$  代表噪声对时间  $t$  求导的雅可比矩阵,  $W$  代表高斯噪声向量,  $W = [n_a^T, n_g^T]^T$ ,  $n_a$  和  $n_g$  分别代表角速度噪声和角速度噪声。其中  $F_t$  和  $G_t$  如式(14)和(15)所示。

$$F_t = \begin{bmatrix} 0 & 0 & I & 0 & 0 & 0 \\ 0 & 0 & -R_t^{b_k} [\hat{a}_t]_\times & -R_t^{b_k} & 0 & 0 \\ 0 & 0 & -[\hat{\omega}_t]_\times & 0 & -I_3 & -I_3 \\ 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 \end{bmatrix} \quad (14)$$

$$G_t = \begin{bmatrix} 0 & 0 & 0 & 0 \\ -R_t^{b_k} & 0 & 0 & 0 \\ 0 & -I_3 & 0 & 0 \\ 0 & 0 & I_3 & 0 \\ 0 & 0 & 0 & -I_3 \\ 0 & 0 & 0 & 0 \end{bmatrix} \quad (15)$$

其中,  $[\hat{a}_t]_\times$  代表  $t$  时刻加速度  $\hat{a}_t$  的斜对称矩阵;  $[\hat{\omega}_t]_\times$  代表角速度  $\hat{\omega}_t$  的斜对称矩阵;  $R_t^{b_k}$  代表  $t$  时刻 IMU

坐标系相对于的  $F_{b_k}$  旋转矩阵;  $\hat{a}_t$  和  $\hat{\omega}_t$  分别是加速度测量值  $a_{m_t}$  和角速度测量值  $\omega_{m_t}$  消去零偏和重力影响的结果, 如式(16)和(17)所示。

$$\hat{a}_t = a_{m_t} - \varepsilon_a - g^{b_k} \quad (16)$$

$$\hat{\omega}_t = \omega_{m_t} - \varepsilon_g - g^{b_k} \quad (17)$$

5)根据式(13)求解状态预测方程和状态预测协方差方程, 如式(18)和(19)所示。

$$\delta x_{t_\tau} = (I + F_{t_\tau} \Delta t) \delta x_{t_{\tau-1}} \quad (18)$$

$$P_{t_\tau} = (I + F_{t_\tau} \Delta t) P_{t_{\tau-1}} (I + F_{t_\tau} \Delta t)^T + (G_{t_\tau} \Delta t) Q (G_{t_\tau} \Delta t)^T \quad (19)$$

其中,  $\Delta t = t_\tau - t_{\tau-1}$ ,  $t_\tau$  和  $t_{\tau-1}$  是 IMU 数据的时间,  $Q$  是  $\omega$  的协方差矩阵, 通过 IMU 离线标定获得。

6)预测先验状态  $'x_{b_{k-1}}^{b_k}$ , 需要使用离散事件递推模型。

7)求解状态更新方程, 协方差更新方程和卡尔曼增益方程, 这里引用 LINS 中的思路, 将状态更新问题转为优化问题, 构建了一个损失函数, 如式(20)所示。

$$Loss(x) = \min_{\delta x} \| \delta x \|_{P(x)} + \| f('x_{b_{k+1}}^{b_k} \oplus \delta x) \|_{(J_k M_k J_k^T)} \quad (20)$$

其中,  $\| \cdot \|$  代表矩阵的范数,  $J_k$  代表  $f(\cdot)$  的测量噪声,  $M_k$  代表  $J_k$  的协方差矩阵,  $f(\cdot)$  代表前后帧粗配准结果的残差方程。为了让  $Loss(x)$  最小, 需要保证损失函数中的两项均最小。第 1 项为  $\min_{\delta x} \| \delta x \|_{P(x)}$ , 求解误差状态最小; 第 2 项  $\| f('x_{b_{k+1}}^{b_k} \oplus \delta x) \|_{(J_k M_k J_k^T)}$ , 表示  $F_{b_{k-1}}$  到  $F_{b_k}$  机器人位姿解算结果。对  $\| f('x_{b_{k+1}}^{b_k} \oplus \delta x) \|_{(J_k M_k J_k^T)}$  化简得  $\| f(x_{b_{k+1}}^{b_k}) \|_{(J_k M_k J_k^T)}$ , 此为基于前后帧点云配准的结果。

8)计算点线距离和点面距离, 如式(21)所示。

$$f_i(x_{b_{k+1}}^{b_k}) = \begin{cases} \frac{|(\hat{p}_i^{l_k} - p_m^{l_k}) \times (\hat{p}_i^{l_k} - p_n^{l_k})|}{|\hat{p}_m^{l_k} - p_n^{l_k}|}, & p_i^{l_{k+1}} \in F_e \\ \frac{|(\hat{p}_i^{l_k} - p_m^{l_k})^\top ((\hat{p}_m^{l_k} - p_n^{l_k}) \times (\hat{p}_n^{l_k} - p_l^{l_k}))|}{|(\hat{p}_m^{l_k} - p_n^{l_k}) \times (\hat{p}_n^{l_k} - p_l^{l_k})|}, & p_i^{l_{k+1}} \in F_p \end{cases} \quad (21)$$

其中, 式(21)中第 1 个子式表示的直线特征点云集  $F_e$  中的点  $\hat{p}_i^{l_k}$  到  $p_m^{l_k}$  和  $p_n^{l_k}$  两点连成直线的距离; 第 2 个子式表示平面特征点云集  $F_p$  中的点  $\hat{p}_i^{l_k}$  到  $p_m^{l_k}$ ,  $p_n^{l_k}$  和  $p_l^{l_k}$  三点组成的平面的距离。式(22)中  $\hat{p}_i^{l_k}$  表示的是  $p_i^{l_{k+1}}$  从  $F_{b_{k-1}}$  到  $F_{b_k}$  的变换点云, 这里需要保证点线面计算的时统一所有点云的坐标系。 $R_t^{b_k}$ ,  $p_t^{b_k}$  分别代表雷达到 IMU 的姿态和位置变换, 可以通过外参标定的方法获得。 $R_{b_{k+1}}^{b_k}$ ,  $p_{b_{k-1}}^{b_k}$  分别是  $F_{b_{k+1}}$  和  $F_{b_k}$  之间的姿态和位置变换。

$$\hat{p}_i^{l_k} = R_t^{b_k T} (R_{b_{k+1}}^{b_k} (R_t^{b_k} p_i^{l_{k+1}} + p_t^{b_k}) + p_{b_{k+1}}^{b_k} - p_t^{b_k}) \quad (22)$$

9)式(22)中,两边同乘 $R_i^b$ 移项化简,可以直观地反映出状态变化,如式(23)所示。

$$R_i^b \hat{p}_i^{l_k} + p_i^b = R_{b_{k+1}}^{b_k} (R_i^b \hat{p}_i^{l_{k+1}} + p_i^b) + p_{b_{k+1}}^{b_k} \quad (23)$$

10)根据ESKF基本公式写出卡尔曼增益方程和状态更新方程,如式(24)和(25)所示。

$$K_{k,j} = P_{k,j} H_{k,j}^\top (H_{k,j} P_{k,j} H_{k,j}^\top + J_{k,j} M_{k,j})^{-1} \quad (24)$$

$$\delta x_{j+1} = \delta x_j + K_{k,j} (H_{k,j} \delta x_j - f(x_{b_{k+1}}^{b_k})) \quad (25)$$

其中, $H_{k,j}$ 是 $f(x_{b_{k+1}}^{b_k})$ 关于 $\delta x$ 的雅可比矩阵。

11)将式(24)和(25)代入式(20)进行优化求解。通过不断的迭代过程,每次特征计算都会采用新的线特征和面特征,进一步缩小误差,计算新的 $H_{k,j}$ 、 $J_{k,j}$ ,得到新的卡尔曼增益 $K_{k,j}$ 。在迭代n次后,可以得到协方差更新方程,如式(26)所示。

$$P_{k-1} = (I - K_{k,n} H_{k,n}) P_k (I - K_{k,n} H_{k,n})^\top + K_{k,n} M_k K_{k,n}^\top \quad (26)$$

12)到此ESKF的5个方程组全部求解出来,求出 $\delta x_{j+1}$ ,通过式(12)求解出状态 $x_{b_{k+1}}^{b_k}$ ,并将它作为下一时刻的先验,对下一状态 $x_{b_{k+2}}^{b_{k+1}}$ 进行初始化,如式(27)所示。

$$x_{b_{k+2}}^{b_{k+1}} = [0_3, v_{b_{k+1}}^{b_{k+1}}, q_0, \epsilon_a, \epsilon_g, g^{b_{k+1}}] \quad (27)$$

其中, $q_0$ 代表单位四元数, $v_{b_{k+1}}^{b_{k+1}} = R_{b_k}^{b_{k+1}} v_{b_k}^{b_{k+1}}, g^{b_{k+1}} = R_{b_k}^{b_{k+1}} g^{b_k}$ ,在状态矩阵中,位置和旋转四元素都初始化为0,代表机器人为中心的参考系的不确定性不考虑,其他速度和偏差保持不变。

13)通过在 $F_{b_k}$ 局部系下的位姿信息计算机器人在 $F_w$ 下的全局位姿信息,进行状态合成,如式(28)所示。

$$x_w^{b_{k+1}} = \begin{bmatrix} p_w^{b_{k+1}} \\ q_w^{b_{k+1}} \end{bmatrix} = \begin{bmatrix} R_{b_k}^{b_{k+1}} (p_w^{b_k} - p_{b_{k+1}}^{b_k}) \\ q_{b_k}^{b_{k+1}} \otimes q_w^{b_k} \end{bmatrix} \quad (28)$$

14)通过离线六面法标定方法获取IMU的内参加速度零偏 $\epsilon_a$ 与角速度零偏 $\epsilon_g$ 。离线外参标定的方法获取激光雷达与IMU外参矩阵 $R_i^b$ 、 $p_i^b$ 。基于迭代卡尔曼滤波紧耦合方案可以提高前端里程计的精度,如图2(a)~(c)所示的分别是纯激光LOAM,IMU和Lidar松耦合LEGO\_LOAM,以及OUR紧耦合方案,在一个室内环形车间的里程计实验。其中矩形方框线代表建图位姿轨迹,其他表示前端里程计轨迹。本文方案可以提供更加精确的初始先验位姿。

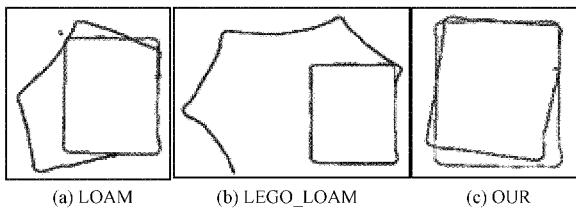


图2 里程计的轨迹误差对比

### 3 后端回环检测

本文提出一种改进的扫描文本方案,首先将扫描的点云数据转换为二维扫描文本的格式,构建描述子。通过近邻搜索在历史关键帧点云中找寻与当前帧相似度高的历史帧作为候选匹配计算的对象,然后计算二者的相似度得分,得分在某一个阈值之内,则认为回到了之前的地方,对地图进行闭环优化。具体闭环的框架如图3所示。本文将扫描文本构建二维矩阵中的值由最大高度改成了最大高度的方差,因为体素内的最大高度会丢失场景的大部分信息,在一些室内场景或者周围物体高度差异性不大的地方容易出现较大的误匹配,导致闭环出错。而采用高度的方差的话,可以充分利用场景的信息,提高闭环的鲁棒性,提高建图的精度。具体实施步骤如下。

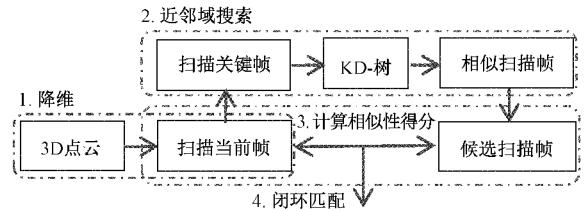


图3 基于文本扫描算法闭环检测的方案框架

1)首先以激光为中心点,然后将三维激光以方位角为横轴和探测距离为纵轴划分为一个二维的栅格,其中方位角的划分数量为 $N_c$ ,方位角均分为 $N_c$ 个扇区,每个扇区的角度为 $2\pi/N_c$ 。其中激光雷达的最大探测距离为 $L_{max}$ ,探测距离划分为 $N_r$ 个圆环,这样每个圆环的宽度为 $L_{max}/N_r$ ,这里取 $N_c=60$ , $N_r=20$ 。这样将三维激光点集划分为 $N_r \times N_c$ 栅格直方图进行存储,保证每个栅格之间没有重叠,如式(29)所示。

$$P = \bigcup_{i \in [N_c], j \in [N_r]} P_{i,j} \quad (29)$$

其中, $P$ 代表所有点云集, $P_{i,j}$ 代表第*i*个扇区,第*j*个圆环的空间点集。

每获得一帧点云数据都会被如此划分,由于激光雷达的光束类似于中心光源,随着扫描半径的增大,距离越远的物体扫描的点云越稀疏,反之近的物体点云越密。点集划分中越靠近激光的点集扇形栅格体积越小,很好地弥补了由远点的稀疏性而引起的信息量不足。

2)点云划分之后,需要对二维扇形栅格 $P_{i,j}$ 进行赋值,这里也是本方法与文献[13]提出方法中不一样的地方,文献[13]直接采用的是该体素内点云的最大高度作为填充,这样容易丢失信息,本文采用的方法是,对体素内所有点云的高度求方差,用方差来作为体素的值,如式(30)和(31)所示。

$$M(z) = \frac{\sum_{p \in P_{i,j}} z(p)}{N} \quad (30)$$

$$\phi(P_{i,j}) = \frac{\sum_{p \in P_{i,j}} (z(p) - M(z))^2}{N} \quad (31)$$

其中,  $M(z)$  代表所有点云的高度均值,  $\phi(P_{i,j})$  代表体素内高度的方差,  $z(p)$  代表获取每个点云的高度信息,  $N$  代表体素内点云的个数。一些划分体素内没有点云的采用 0 填充, 对于一些遮挡区域采用大数  $M$  填充。

3) 三维点云场景映射为二维栅格, 可以有效地进行相似场景的识别, 一帧点云被划分为  $N_c \times N_r$  的二维有序矩阵, 如式(32)所示。

$$I = (a_{ij}) \in R^{N_c \times N_r}, a_{ij} = \phi(P_{ij}) \quad (32)$$

4) 构建当前帧点云  $I^q$  与历史候选帧点云  $I^c$  之间的距离, 通过计算两帧点云的距离来决定是否为同一位置, 该距离是相同索引处的各列之间的距离之和。 $c_j^q$  和  $c_j^c$  分别代表体素中相同索引的两个列向量, 并采用余弦值作为计算距离, 并对计算结果做归一化, 如式(33)所示。

$$d(I^q, I^c) = \frac{1}{N_c} \sum_{j=1}^{N_c} \left( 1 - \frac{\mathbf{c}_j^q \cdot \mathbf{c}_j^c}{\|\mathbf{c}_j^q\| \|\mathbf{c}_j^c\|} \right) \quad (33)$$

5) 由于不同帧点云映射到二维矩阵时, 由于不同时刻的激光雷达的视角是不一样的, 这样会导致当前帧与历史帧点云映射的二维矩阵在列方向是不对应的, 所以这里面需要对当前帧的列顺序进行检查, 并保证和历史帧的二维矩阵列顺序相同。采用取  $I^q$  上面的某一列, 然后与  $I^c$  中的每一列进行距离计算, 其中距离最小的, 则匹配最佳, 记下偏差的列数, 如式(34)和(35)所示。

$$D(I_j^q, I^c) = \min_{n \in [N_c]} d(I_j^q, I_n^c) \quad (34)$$

$$\Delta n = n - j \quad (35)$$

其中,  $D(\cdot)$  代表最小距离,  $\Delta n$  为列移动量。

6) 上下文搜索采用双层搜索算法, 将成对相似性匹配得分与最近邻搜索进行融合, 提高搜索的效率。具体引入关键环来实现双层融合算法, 关键环作为旋转不变描述符, 刚好为每一帧点云映射二维矩阵的一行。矩阵的每一行  $r$  通过一个环形编码函数  $\psi$  进行编码, 然后整体构成一个向量  $\mathbf{K}$ , 如式(36)所示。

$$\mathbf{K} = (\psi(r_1), \dots, \psi(r_{N_r})), \psi: r_i \rightarrow R \quad (36)$$

其中, 环编码函数  $\psi$  使用的是 L0 范数环的占用率, 占用率与激光的视角无关, 很好地解决了旋转不变性问题, 如式(37)所示。

$$\psi(r_i) = \frac{\|r_i\|_0}{N_r} \quad (37)$$

7) 使用关键环可以快速寻找到可能的循环候选对象, 减少搜索的范围。环向量  $\mathbf{K}$  可以构建 KD-Tree, 方便进行数据搜索。式(38)中, 计算距离, 将当前需要查询的扫描关键帧与恒定数量的候选帧进行比较。选择候选中最接近阈值的候选者作为闭环的位置。

$$c^* = \operatorname{argmin}_{c_k \in C} D(I^q, I^{c_k}), \text{s.t. } D < \tau \quad (38)$$

其中,  $c^*$  代表闭环结果的索引值, 其中  $\tau$  是距离阈值, 其中  $C$  代表 KD-Tree 中候选帧的索引集合。

## 4 位姿图优化

### 4.1 构建位姿因子图

位姿图优化是将图理论和非线性优化相结合的优化方法, 通过图的形式对位姿变量和约束条件进行直观描述, 便于拓扑操作和构造目标函数。其中图结构为  $G = \{N, E\}$ , 其中  $N$  表示的图的结点, 包含待优化的位姿参数,  $E$  表示图的边, 包含参数之间的约束函数。图优化的目的是最小化所有的约束函数, 通过优化算法求解最优的位姿参数, 如图 4 所示。

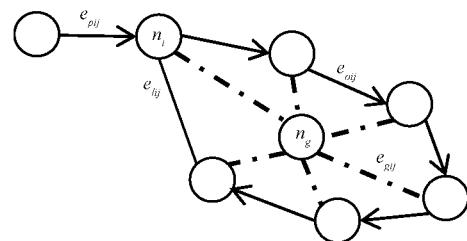


图 4 位姿因子图

其中, 圆圈  $n_i$  表示当前观测位姿结点;  $n_g$  表示地面约束目标结点;  $e_{p_{ij}}$  表示位姿先验因子, 一般是前端里程计的输入作为初始化先验值; 带箭头的线  $e_{rij}$  表示里程计因子, 通过当前帧点云与局部点云地图匹配获得激光里程计约束; 虚线  $e_{gij}$  表示地面约束因子, 通过求解当前帧地面点云与全局一致性地面的距离构成约束; 直线  $e_{ij}$  表示闭环因子, 通过降维匹配的位置识别闭环算法在两个匹配得分高的位姿结点之间构建闭环约束。

其中每一个位姿结点  $n_i$  都表示机器人采集到的每一帧地图的轨迹点, 每个轨迹点包含位置和姿态信息, 位姿使用三维向量  $t_i = [x_i, y_i, z_i]^T$  表示, 姿态用欧拉角  $q_i = [\theta_{ri}, \theta_{pi}, \theta_{zi}]^T$  表示, 每一个结点为  $n_i = [t_i^T, q_i^T]^T$ , 其中每一个结点有 6 个未知参数。每一条边  $e_{ij}$  表示  $n_i$  与  $n_j$  两个结点间的位姿约束, 由于观测值与实际值存在误差, 所以对 2 个结点和 1 个边可以构建一个残差函数  $r(n_i, n_j, e_{ij})$ 。

### 4.2 位姿求解

位姿图优化求解就是最小化所有的残差和, 得到最优的位姿参数  $N = \{n_1, n_2, n_3, \dots, n_m\}$ , 其中优化目标函数如式(39)所示。

$$F = \operatorname{argmin}_N \sum_i^m \sum_j^m r(n_i, n_j, e_{ij}) \quad (39)$$

其中,  $i \neq j$ , 目标函数中  $m$  表示的是位姿图中的结点总数, 对于没有约束关系的结点之间, 残差项  $r = 0$ , 通过融合各个约束条件, 保证目标函数  $F$  最小。其中目标函数是一个非线性函数, 本文采用 LM(levenberg-marquardt) 优化方法求解最小二乘问题, 最终得到最优的位姿参数, 对地图点云位姿进行修正, 得到精度较高的全局一致性地图。

## 5 实验评价

本文实验平台是1台室外巡检机器人,机器人的传感器由1台Velodyne-16线激光雷达和1个型号为Xsense-200的IMU组成,如图5所示。其中IMU固联在车载激光顶部,通过强力胶带固联,组合如下所示。其中激光雷达安装在机器人顶部,保证采集到周围360°场景的完整点云信息。通过遥控室外移动机器人行走,采集激光雷达探测的真实物理场景点云数据和IMU里程计信息,通过一台处理器型号是Intel-i7-10TH,内存16G的笔记本,创建真实物理环境的三维点云地图。本框架的编程语言完全基于C++,操作系统是Ubuntu18.04,以及机器人操作系统(ROS)。代码将会开源到GitHub上以供检验。

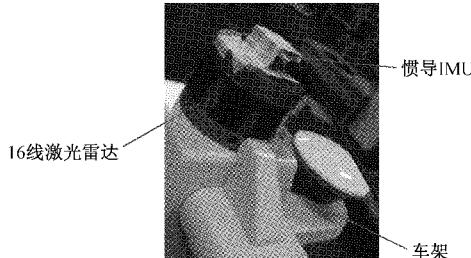


图5 硬件平台框架

为了能够测试SLAM框架的建图精度和有效性,选择了室外厂房建筑物道路环境,停车场复杂环境,以及室内车间环境等多个场景进行建图测试。通过与现有的纯激光框架A-LOAM和融合IMU和Lidar松耦合框架LEGO\_LOAM等流行框架进行了建图完整性和精度对比,来验证算法建图的有效性和鲁棒性。

### 5.1 室外室内建图实验结果对比

第1个场景室外厂房建筑物道路环境,如图6(a)所示我们采集了两栋厂房构成的双环建筑物道路场景,其中一栋建筑物是长方形,另一个建筑物带一个大圆弧的,中间有一个十字路口。整个场景的距离在600m左右,尤其是在弧形区域和十字路口区域容易发生地图的飘移和位姿误差过大难以优化校正,该场景可以很好地检验本文算法的地面向约束以及闭环检测的有效性。第2个场景停车场复杂场景,如图6(b)所示,采集了“匚”字格型的停车场,由于特征变化比较大,没有长墙面等强特征区作为约束,所以建图的难度比较大,地图很容易发生失真和重影,所以可以很好地检验闭环算法的场景识别能力。第3个场景室内车间场景,如图6(c)所示,测试了SLAM算法在室内建图的有效性,选择了一层室内的车间,车间内主体是房梁,同时还有其他物品,室内场景物品摆放紧密,特征匹配丰富。通过室内室外3个不同的场景来验证本文基于滤波和图优化约束融合的SLAM算法建图的有效性和鲁棒性。3个场景建图的结果的俯视图对比如图6所示,建图的主视图对比如图7所示。

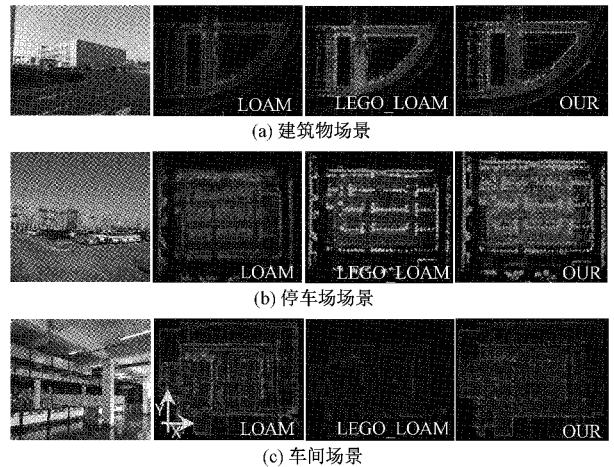


图6 多场景建图俯视图对比

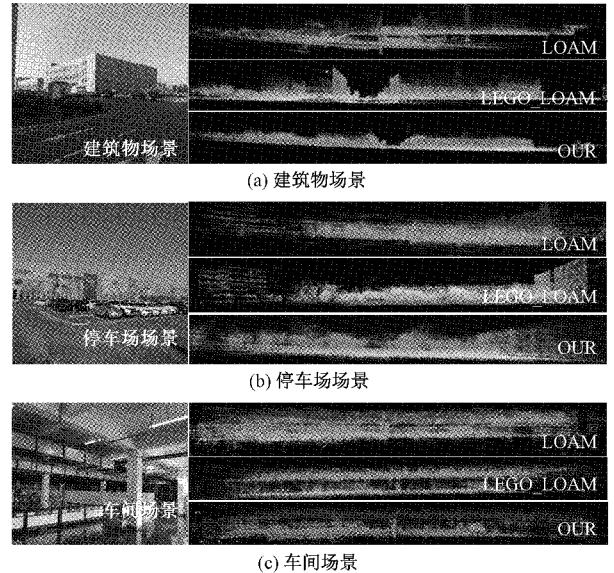


图7 多场景建图主视图对比

通过建图实验对比,由于LOAM没有后端闭环检测算法,以及前端没有地面分割约束,以及IMU数据辅助,所以在3个场景中都发生了重影和漂移,其中室外厂房建筑物场景的Z轴方向发生了较大的漂移,以及建筑物出现局部的重影。在停车场场景中,地图重影严重,室内场景中地图也有Z方向漂移和重影。LEGO\_LOAM和OUR两种算法可以完成3个场景的建图,但是在室外厂房建筑物场景和停车场场景中,由于LEGO\_LOAM没有地面约束以及回环算法识别率低,导致地图在Z方向发生了小范围的漂移,以及停车场场景和室内场景,本文算法构建的全局地图在俯视图和主视图都相对更优一些,同时可以使用室内室外等多场景,可以构建更高精度的全局一致性地图。

### 5.2 场景建图轨迹偏差

为了能够测量地图位姿的累计误差,通过画线标记机器人初始位置,机器人走一个回环然后回到初始的标记位置,

保证机器人真实行走轨迹的初始位置与结束位置基本重合，分别统计机器人位置的距离、水平和高程偏差。其中机器人前进的方向与激光建图 X 轴重合，水平为 Y 轴方向，垂直为

Z 轴方向。其中机器人初始的位置坐标为  $[0, 0, 0]^T$ ，然后以 2 Hz 的频率将建图的实时位姿保存下来，机器人终点的位置则为误差的累加和，具体结果如表 1 所示。

表 1 轨迹偏差对比

多种场景	LOAM			LEGO_LOAM			OUR		
	$\delta x$	$\delta y$	$\delta z$	$\delta x$	$\delta y$	$\delta z$	$\delta x$	$\delta y$	$\delta z$
建图轨迹偏差									
建筑物场景	3.518	0.609	9.477	0.044	2.083	1.220	0.048	0.131	0.020
停车场场景	3.155	3.666	2.608	0.093	0.032	0.048	0.087	0.029	0.037
室内车间场景	0.085	0.175	0.060	0.058	0.012	0.044	0.043	0.050	0.041

其中  $\delta x$  表示的是距离的偏差， $\delta y$  表示水平的偏差， $\delta z$  表示高程偏差。根据表 1 中的数据，本文算法在室外建筑物场景和室外停车场场景误差都是最优的，本文误差可以达到厘米级，而 LOAM 的误差则在米级，其中室外建筑物场景 LEGO\_LOAM 的水平误差和高程误差也在米级。停车场场景中，本文误差和 LEGO\_LOAM 的误差均在厘米级，但是本文建图精度更优。在室内场景，三者算法的误差均在厘米级，其中 LOAM 误差最大，LEGO\_LOAM 的距离误差比本文算法低，但水平误差比本文更优，高程误差基本相同。综上本文算法在室外表现最优，室内表现和 LEGO\_LOAM 近似，也可以满足建图的精度要求。

## 6 结 论

本文提出的同时融合滤波和图优化理论的 SLAM 系统可以实现室外大场景环境建图，精度比 LOAM 和 LEGO\_LOAM 等框架更优。本文主体分两步提高 SLAM 系统的精度：1) 引入迭代误差状态卡尔曼滤波融合 IMU 和激光里程计的数据作为前端粗配准结果，可以一定程度上减少前端里程计累计误差；2) 引入图优化理论，结合地面约束因子，闭环因子以及里程计因子，对建图位姿进行最终优化，建图精度有很大地提升。

本文提出的地面约束因子通过 RANSAC 算法提取平面模型，通过构建全局一致性地面误差模型来构建约束项。闭环因子采用一种新的扫描文本闭环算法，闭环效率相比其他的激光闭环算法更优，通过本算法构建的环境描述子环境误识别率低，闭环效果好。

本文提出的算法主要针对环境重建问题，对于室外大场景，计算资源消耗比较大。后期将引入多线程技术提高资源利用率，提高系统的性能和效率。同时将后端和前端进行整合，采用一步优化的思路，以提高系统的实时性，可以应用于一些需要实时建图和实时位姿输出的场景。

## 参考文献

- [1] 王璐, 蔡自兴. 未知环境中移动机器人并发建图与定位(CML)的研究进展[J]. 机器人, 2004, 26(4):380-384.
- [2] 晁彦举. 基于多传感器的移动机器人自主定位与地图构建技术研究[D]. 济南: 山东大学, 2014.
- [3] ZHANG J, SINGH S. LOAM: Lidar odometry and mapping in real-time [C]. Robotics: Science and

Systems Conference, 2014.

- [4] 阿谷 郁子, RUSINKIEWICZ S, LEVOY M. Efficient variants of the ICP algorithm[J]. 人工知能学会誌, 2005, 20(4):503.
- [5] 张晓, 张爱武, 王致华. 基于改进正态分布变换算法的点云配准[J]. 激光与光电子学进展, 2014, 51(4):100-109.
- [6] SHAN T, 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(IROS), IEEE, 2018:4758-4765.
- [7] 毛建宏. 基于多传感器 Kalman 滤波器的 GPS/IMU 数据融合算法设计[J]. 微电子学与计算机, 2005, 22(6):77-79,83.
- [8] QIN T, LI P, SHEN S. VINS-Mono: A robust and versatile monocular visual-inertial state estimator [J]. IEEE Transactions on Robotics, 2018, 34(4):1004-1020.
- [9] YE H, CHEN Y, LIU M. Tightly coupled 3D lidar inertial odometry and mapping [J]. IEEE, 2019: 3144-3150.
- [10] SHAN T, ENGLOT B, MEYERS D, et al. LIO-SAM: Tightly-coupled lidar inertial odometry via smoothing and mapping [J]. 2020 IEEE IRST International Conference on Intelligent Robots and Systems (IROS), 2020:5135-5142.
- [11] HAN F, YANG X, DENG Y, et al. SRAL: Shared representative appearance learning for long-term visual place recognition [J]. IEEE Robotics & Automation Letters, 2017, 2(2):1172-1179.
- [12] BELONGIE S, MALIK J, PUZICHA J. Shape matching and object recognition using shape contexts [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2002, 24(4):509-522.
- [13] 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(IROS), IEEE, 2018: 4802-4809.
- [14] QIN C, YE H, PRANATA C E, et al. LINS: A lidar-inertial state estimator for robust and efficient navigation[C]. 2020 IEEE International Conference on Robotics and Automation (ICRA), IEEE, 2020: 8899-8906.
- [15] 梁明杰, 闵华清, 罗荣华. 基于图优化的同时定位与地图创建综述[J]. 机器人, 2013, 35(4):500-512.

## 作者简介

- 华智,硕士研究生,主要研究方向为移动机器人自主导航与动态避障。  
E-mail:huazhi@sia.cn
- 宋吉来(通信作者),博士,硕导,主要研究方向为机器人运动控制与智能感知。  
E-mail:songjilai@sia.cn