

DOI: 10.19650/j.cnki.cjsi.J2513798

基于闭环检测和地面优化的激光雷达惯性 里程计建图与定位^{*}

王 禹, 王彬彬, 王 斐, 邹 强
(东北大学机器人科学与工程学院 沈阳 110000)

摘 要:在机器人建图的过程中,通常需要准确的估计机器人的姿态,从而为后期导航和路径规划提供一个基础。然而在常见的室外工作环境中,由于机器人偏航角、滚转角和俯仰角这 3 个状态量在一定程度上不可观测且难以评价和消除误差,所以经常会导致在户外场景下地图 Z 轴严重漂移,无法获取一个准确的全局一致地图。为了降低 Z 轴漂移误差,提出了一种完整的机器人建图系统架构,其通过地面优化和闭环检测两部分相结合的方法降低特征匹配所需点云数量的同时,提高机器人建图的准确性。为了高效融合多源传感器数据,并实时估计惯性测量单元的动态零偏,该系统基于激光惯导同步定位与建图方法,通过构建因子图框架,将激光里程计因子、惯性里程计预积分因子以及回环检测因子纳入其中,通过因子图优化对机器人全局位姿进行估计,从而降低累积误差,最终构建出整体一致的全局地图。该算法部署到了更易产生上下振动的四足机器人平台上进行了实机实验,并使用公开数据集进行广泛评估,与基线方法相比,实验结果表明该系统在保证建图效果的同时,提高了建图精度,降低了绝对轨迹误差平均值。

关键词:地面优化;闭环检测;室外环境;Z 轴漂移;同时定位与建图

中图分类号: TP242 TH39 **文献标识码:** A **国家标准学科分类代码:** 510.80

Research on the localization and mapping based on closed-loop detection and ground optimization

Wang Yu, Wang Binbin, Wang Fei, Zou Qiang

(Faculty of Robot Science and Engineering, Northeastern University, Shenyang 110000, China)

Abstract: Accurate estimation of a robot's posture is fundamental for navigation and path planning during the mapping process. However, the states of yaw, roll and pitch of robots are unobservable and difficult to evaluate and eliminate errors in the outdoor environments. This often leads to serious drift of the Z-axis in the generated map, thereby preventing the construction of a globally consistent and accurate map. To address this issue, we propose a complete robot mapping system architecture, which improves the performance of robot mapping combined with two methods: ground segmentation and closed-loop detection. To efficiently integrate data from multiple sensors and estimate the dynamic biases of the Inertial Measurement Unit in real time, the system employs a LiDAR-inertial odometry simultaneous localization and mapping method. By constructing a factor graph framework, the system incorporates Lidar odometry factors, IMU pre-integration factors, and loop closure detection factors. Through factor graph optimization, the robot's global pose is estimated to reduce accumulated errors and ultimately generate a globally consistent map. In addition, the algorithm has been deployed on the quadruped robot dog platform, conducting outdoor experiments and using public datasets for extensive evaluation. The experimental results showed that our system has better mapping effects and accuracy, significantly reducing the average positional error compared to baseline methods.

Keywords: ground optimization; loop detection; outdoor environment; Z-axis shift; simultaneous localization and mapping

0 引 言

近年来,机器人同时定位与建图(simultaneous localization and mapping, SLAM)技术的不断发展,被广泛应用于各种场景之下,如自动驾驶、灾后搜索、隧道建图等。如今 SLAM 主要可以分为两大类:视觉 SLAM 和激光 SLAM。视觉 SLAM 通常使用相机作为传感器,由于价格便宜,且可以获取丰富的环境信息,深受广大研究者的喜爱。然而,相机只能在慢速运动状态下才能准确的估计机器人的自身运动,测量距离有限以及容易受到环境光照的影响,因此往往使用平台和场景有限,对于激光 SLAM 而言,其使用激光雷达作为传感器,构建未知环境的 3D 点云地图。相比于其他传感器而言,激光雷达价格较为昂贵,但由于可以进行长距离的测量,能够实现厘米级别的精度,被广泛应用于各种任务,如建图、定位、目标检测、点云配准等。对于激光 SLAM 而言,大部分情况下都是将激光雷达传感器搭载在地面移动平台上,常见如轮式机器人,或者四足机器人等。由于轮式机器人和四足机器人具有良好的越障能力,其广范应用于室内外复杂场景下的同步定位和建图。近年来,激光 SLAM 发展迅速,短短几年期间就已经取得了巨大的进步,其中不乏有一些较为优秀的 SLAM 算法系统框架^[1-4],它们出色的姿态精度和扩展性,获得了众多业界人士的认可。

然而,上述研究内容大多关注室内外一般场景下的 SLAM 问题,而不是复杂地形下的 SLAM 问题,例如非结构化地面、草地、陡坡等。这些地形会影响地面移动机器人的运动稳定性和传感器数据准确性,从而使问题更加复杂也更具有挑战性。对于地面移动平台而言,由于其行驶在地面之上,因此也有一些学者利用地面作为约束条件,提出地面辅助的激光 SLAM 方法,以此提高性能。在 SLAM 中,地面优化是指将传感器数据中的地面部分与非地面部分(如障碍物、建筑物等)进行分离的过程。地面优化的主要作用包括以下几个方面:减少计算复杂度、提高环境建模的准确性、改善运动估计和定位精度和增强障碍物检测与避障。对于地面优化而言,众多学者进行了广泛的研究,基于激光 SLAM 的地面优化大致可分为 4 类:地面估计方法^[5-7]、基于高程图的方法^[8]、基于模型的方法^[9]、基于深度学习的方法^[10]。总体说来,这些方法,要么就是精度高花费时间长、通用性差;要么就是速度快、成本低但适应性差,严重依赖于数据集。

目前,一些令人较为印象深刻的算法如 LeGO-LOAM (lightweight and ground-optimized LiDAR odometry and map on variable terrain)^[11],其在分割和优化两个过程中引入地面约束,在分割阶段利用地面剔除一些不可靠的激光点数据,在优化过程采用两步优化的方式求解六自由度

位姿,在一定程度上解决了 3 个自由度不可观测的问题,进一步提高 SLAM 性能。然而其地面提取方式较为简单,仅仅通过判断相邻激光束之间的夹角是否小于一定角度阈值来提取地面点云,容易导致在复杂颠簸陡峭、灌木丛较多的情况下容易出现分割不准确的问题。

也有学者在 SLAM 框架中使用地面优化方法。例如 PaGO-LOAM (robust ground optimized LiDAR odometry)^[12]使用 Patchwork^[13]更为精细的地面优化算法,代替原有 LeGO-LOAM 算法中的地面优化模块,使其性能得到了进一步提升。Wei 等^[14]提出了一种用于室内无 GPS 环境下地面约束激光里程计方法,该方法从局部地图中提取地面,并使用加权最小二乘方法估计地面参数,然后在位姿图中对每个关键帧构建地面约束进行优化,有效的减少了 Z 轴漂移问题。Pan 等^[15]利用双阈值地面滤波和主成分分析从每帧中提取地面、立面、立柱等特征点,然后使用多尺度线性最小二乘迭代最近点算法进行当前帧与局部子图的配准,最后对每一类中的特征点进行联合优化,以估计自身运动。为了可靠的生成大型室内环境地图,Koide 等^[16]假设存在一个全局地面,并在位姿图中引入地面约束来优化机器人的位姿,然而该方法并不能使用于室内多层结构化和室外复杂崎岖的环境。

针对上述激光雷达自身垂直分辨率低或机器人本体运动过程中上下振动导致点云数据 Z 轴估计不准的问题,提出了一种新的带有闭环检测和地面优化的快速激光雷达惯性里程计和建图方法,该方法主要包括 3 部分:激光雷达惯性里程计、闭环检测和地面优化;它可用于实时建图和有效抑制 Z 轴漂移的问题。主要贡献为:

- 1) 一种 3D 激光 SLAM 算法,其利用地面优化,闭环检测的方法来解决颠簸复杂陡峭地形下和激光雷达测量偏差导致的 Z 轴漂移问题。

- 2) 将该算法部署到了实体四足机器人上面,使其在算力有限的情况下依然可以有效运行。

- 3) 与一些现有方法相比,该方法在公开数据集上降低了数据处理量的同时,在复杂环境中仍可以实现准确的自身位姿估计。

1 系统框架

提出的系统架构如图 1 所示,首先,3D 激光点云通过地面优化模块^[17]分类为地面点和非地面点,随后结合惯性测量传感器(inertial measurement unit, IMU)数据完成畸变矫正与特征提取。然后在图像投影中基于曲率进行角点和面点的提取,系统利用优化的闭环检测算法实现历史帧匹配,并通过因子图优化修正机器人全局轨迹,最终生成高精度的全局地图。




图1 系统框架

Fig. 1 System framework

1.1 地面优化

地面优化模块作为本 SLAM 系统框架中的预处理优化模块,主要用于从 3D 激光点云中分割出地面,更关注于地面优化模块在整个 SLAM 系统框架中的作用,详细的地面优化细节参照文献[17]。

假设一帧激光点云数据为 P ,如图 2 所示,其由 N 个激光点 P_i 构成,其中 $i \in N$ 。将 P 输入地面优化模块可得地面点集合 G 和非地面点 $\bar{G}$,其中 $P = G \cup \bar{G}$ 。接着对 P 和 G 进行图像投影,为后续提取特征点奠定基础。其中地面图像投影主要用于提取地面点和剔除不可靠的角点提取,增加角点提取的准确率。




图2 计算曲率的激光点示意图

Fig. 2 Diagram of laser spots calculating curvature

设 S 为激光雷达同一帧上连续点 p_i 左右两侧点的集合,则在 S 中点 p_i 的曲率 c_i 的具体计算方法如式(1)所示。

$$C_i = \frac{1}{|S| \cdot \|r_i\|} \left\| \sum_{\substack{j \in S \\ j \neq i}} (r_j - r_i) \right\| \quad (1)$$

式中: r_i 代表在点 p_i 处距离雷达中心的距离; r_j 表示左右相邻点距离雷达中心的距离。式(1)中分母为一个常数,为了减少计算复杂度,可以对其化简,简化后的表达式如式(2)所示。

$$C_i = \left\| \sum_{\substack{j \in S \\ j \neq i}} (r_j - r_i) \right\|^2 \quad (2)$$

根据曲率 C_i 的数值,可以判断点 i 所在的局部表面的平坦程度。若曲率 C_i 较大,则表明该点处于一个不平

坦的角点;反之,若曲率 C_i 较小,则表明该点处于一个平坦的局部面上。在每帧上的曲率计算完成之后,还需要标记一些存在遮挡和平行的点,最后在进行特征提取。特征提取过程为按顺序遍历每一帧,然后将每一帧的点云数据划分为 6 段,每段分开提取一定数量的特征,保证特征均匀。对于每段区间而言,对曲率进行从小到大排序,然后设定一个曲率阈值 k ,当激光点曲率值大于阈值 k 时,将该点视为角点;而当激光点曲率小于 k 时,将该点视为平面点。鉴于平面点可能较多,影响后续处理流程因此还需要使用体素网格进行处理。基于曲率方法提取的角点和面点如图 3 所示。




图3 提取的角点和面点示意图

Fig. 3 Diagram of extracted corner and plan points

1.2 闭环检测

闭环检测模块在激光 SLAM 模块中常用于判断机器人是否到达曾经访问过的地方,以此减少全局位姿误差。提出的方法主要基于扫描上下文^[18](scan context, SC) 框架,与以往不同是,提出方法利用特征提取模块中提取的角点和面点构建全局描述符。在不减少精度的情况下,大大减少了所需处理点云的数量和异常点的影响,提高了闭环检测的精度,同时也缩短了闭环检测时间。

首先对输入非地面点云中的特征点进行点云划分,点云分割示意图如图 4 中所示。




图4 点云优化示意图

Fig. 4 Point cloud segmentation diagram

对点云沿着径向和角度两个方面进行划分,对沿半径增大方向,把点云空间等分成 N_r 个圆环,每个圆环的宽度为:

$$d_r = \frac{L_{\max}}{N_r} \quad (3)$$

式中: $L_{\max}$ 为激光点的最远距离。对按角度划分而言,把圆环切割成 N_s 等分,每个扇区角度为:

$$\theta_r = \frac{2\pi}{N_s} \quad (4)$$

分割后,激光点集合 P 可表示为:

$$P = \cup_{i \in [N_r], j \in [N_s]} P_{ij} \quad (5)$$

构建特征点描述子向量和向量最近邻查找。首先利用生成的扫描上下文,构建具有旋转不变性的特征点描述子。具体点来说,就是对扫描上下中的每一行 r 使用一个环编码函数 ψ 来分配一个值作为标识,然后每个环的值组合成一个 N_r 维的向量 $\mathbf{k}$, ψ 和 $\mathbf{k}$ 表示为:

$$\psi(r_i) = \frac{\|r_i\|_0}{N_s} \quad (6)$$

$$\mathbf{k} = (\psi(r_1), \dots, \psi(r_{N_r})), \psi: r_i \rightarrow R \quad (7)$$

式中: $\|r_i\|_0$ 表示半径 r_i 对应圆环中空优化单元的个数。接着根据计算的向量,使用 nanoflann 外部库对所有特征点的历史帧向量共同构建 KDTree,然后使用特征点当前帧对应的向量在 KDTree 中查找,找出 n 个可能相似帧。

对于 SC 而言,其首先利用生成的 SC 图像,然后利用距离函数:

$$d(\mathbf{I}^q, \mathbf{I}^c) = \frac{1}{N_s} \sum_{j=1}^{N_s} \left(1 - \frac{c_j^q \times c_j^c}{\|c_j^q\| \|c_j^c\|} \right) \quad (8)$$

粗略的判断闭环候选,当距离函数小于某个阈值时,就认为检测到了闭环候选。对于同一地点的当前帧和历史帧而言,当两帧点云之间有旋转时使用式(8)进行计算可能会导致两帧的距离函数较大,为了解决上述问题,因此将历史帧 $\mathbf{I}^c$ 按列平移,得到 $\|N_s\|$ 个扫描上下文,依次与当前帧的扫描上下文计算距离,从中选择距离最小的那个,计算公式如式(9)所示。

$$D(\mathbf{I}^q, \mathbf{I}^c) = \min_{n \in [N_s]} d(\mathbf{I}^q, \mathbf{I}^c) \quad (9)$$

式中: $\mathbf{I}^q$ 、 $\mathbf{I}^c$ 分别为当前帧和历史帧的 SC,其中 c_j^q 为 $\mathbf{I}^q$ 中的第 j 列, c_j^c 为 $\mathbf{I}^c$ 中的第 j 列。

1.3 因子图优化

提出方法采用 ISAM2 (incremental smoothing and mapping 2)^[19]进行因子图优化,通过在因子图中添加激光里程计因子、IMU 预积分因子、回环检测因子等执行因子图优化,矫正全局位姿轨迹误差,最终实现鲁棒的定位和精确地图构建,因子图结构如图 5 所示,其中间表示为机器人状态节点,两机器人状态节点之间为激光里程计因子,下方为 IMU 预积分因子,上方为回环检测因子。




图 5 因子图架构

Fig. 5 Factor graph framework

SLAM 过程可以看作是一个状态估计问题,其根据机器人预测的先验位姿和传感器观测到的数据对机器人实际位姿进行求解,也可以描述为基于先验的最大后验求解。假设机器人在一段时间内的运动位姿分别为 $x_0, \dots, x_n$,而在每个状态时刻观测到的路标为 $\ell_0, \dots, \ell_m$,则机器人的运动方程和观测方程可以描述为:

$$x_k = f(x_{k-1}, \mu_k) + w_k \quad (10)$$

$$z_{k,j} = h(x_k, \ell_j) + v_{k,j} \quad (11)$$

式中: $k = 1, \dots, n; j = 1, \dots, m; x_k$ 表示 k 时刻的机器人位姿; μ_k 为 k 时刻的外部输入; $w_k, v_{k,j}$ 表示为 k 时刻的高斯噪声,均服从高斯分布模型即 $w_k \sim N(0, R_k)$, $v_{k,j} \sim N(0, Z_{k,j})$; $Z_{k,j}$ 表示 k 时刻机器人的观测值; ℓ_k 表示 k 时刻机器人观测到路标信息。对于运动方程和观测方程,假设其符合一阶马尔可夫假设,即当前时刻只与上一时刻和输入有关,用概率模型对其转化后可得:

$$\begin{cases} p(x_k | x_{k-p}, u_k) = \frac{1}{\sqrt{|2\pi \Sigma|}} e^{-\frac{1}{2} \|f(x_{k-p}, u_k) - x_k\|^2} \\ p(z_{k,j} | x_k, \ell_j) = \frac{1}{\sqrt{|2\pi \Sigma|}} e^{-\frac{1}{2} \|h(x_k, \ell_j) - z_{k,j}\|^2} \end{cases} \quad (12)$$

对于输入量 u 、机器人位姿 x 、路标信息 ℓ 及观测值 z ,假设其联合概率密度函数为 $p(X, u, \ell, z)$ 。由于上述变量之间的相互独立,因此 $p(X, u, \ell, z)$ 可以表示为:

$$p(X, u, \ell, z) = p \begin{pmatrix} X_0, \dots, X_n \\ u_0, \dots, u_n \\ \ell_0, \dots, \ell_m \\ z_0, \dots, z_n \end{pmatrix} =$$

$$p(x_0) \prod_{k=1}^n p(X_k | X_{k-1}, u_k) \prod_{k=1}^n p(u_k) \prod_{j=1}^m \prod_{k,j} p(z_{k,j} | x_k, \ell_j) \quad (13)$$

对于一个 SLAM 过程而言,其可以使用一个贝叶斯网络模型进行表示。如图 6 所示。其中运动方程与实线框中内容对应,观测方程与虚线框中内容对应。

当贝叶斯网络简化为因子图后,式(13)则可以使用因子图的方式进行描述:




图6 SLAM问题对应的动态贝叶斯网络

Fig. 6 The dynamic Bayesian network corresponding to SLAM problem

$$p(\theta) \propto \prod_i \phi_i(\theta_i) \prod_{(i,j) \in E} \psi_{(i,j)}(\theta_i, \theta_j) \quad (14)$$

式中: ϕ_i, θ_i 分别为因子图中第 i 个变量的先验因子与节点; E 为约束条件的集合; $\psi_{(i,j)}$ 为第 i 个与第 j 个节点之间的约束因子。由于最大化因子图的乘积与最大化动态贝叶斯网络的后验概率估计等价, 所以 $\{x, \ell\}^*$ 又可以表示为:

$$\{x, \ell\}^* = \underset{X, \ell}{\operatorname{argmax}} p(\theta) \quad (15)$$

对于式(15)可将其转化为最小二乘问题, 然后利用高斯牛顿或者 L-M 迭代算法进行优化求解。

2 实验验证

采用的实验设备为宇树 GO1 机械狗, 如图 7 所示。其上搭载速腾 RS-LiDAR-16 线扫固态激光雷达, 垂直测角 $-15^\circ \sim 15^\circ$, 水平测角 360° , 惯性测量单元使用机身内置 6 轴 IMU, 动态精度为 1° 。宇树四足机器人的内部架构, 一般都是由一块主控板、一块运动控制主板、一块或多块感知主板组成, 内部一个交换机将各个板卡连起来成为一个局域网, 其中算法主要运行在 Nano 主控 MCU 上, 其内部处理器为 ARMv8、6 核、8 GB 运行内存。此外, 使用一台 i7-13700H 20 核 2.40 GHz 处理器和 16 GB 内存的 ThinkBook 笔记本进行 KITTI 数据集^[20-21]测试, 以



图7 Go1 四足机械狗

Fig. 7 Go1 quadruped robot dog

上算法都是在 Ubuntu18.04 中使用机器人操作系统^[22]执行。

2.1 户外实验

为了验证算法在真实机器人上的有效性和稳定性, 选取校内一段场景进行实机性能测试, 场景如图 8(a) 所示。由于该算法关注于地面优化相关的激光 SLAM 算法, 所以将一些优秀并且能够部署的开源激光 SLAM 算法部署到了四足机器人上, 然后与该算法性能进行对比, 其建图结果分别如图 8(b) ~ (d) 所示。通过对比建图效果可以发现 PaGO-LOAM 算法在建图结果上存在部分重影误差, 而 LeGO-LOAM+SC 算法虽然可以解决重影误差但其点云建图效果相对稀疏, 存在噪点太多问题, 细节处理不是很好, 相比之下, 该算法则能够有效稳定的工作。




图8 实际场景与不同算法的实际建图效果

Fig. 8 Actual environments and mapping results of different algorithms

2.2 数据集评估

为了验证该方法的有效性, 选取 KITTI raw data 中的 02 和 05 序列进行算法和真值的对比, 其中 02 是乡村场景, 05 是城市场景, 但两者地面路段都存在一定程度上的陡峭不平。值得注意的一点是该算法修改了激光雷达的配置参数, 以适应 HDL64E 的 KITTI 数据集。同时, 为了保证数据对比的有效性, 采取和 ALOAM 算法中一致的曲率阈值 k 和距离阈值 d 的设定, 分别是 0.1 和 5。

此外使用 evo 工具包进行轨迹的评估, 不同算法的轨迹评估如图 9 和 10 所示。不同的算法依次为真值、LeGO-LOAM、LeGO-LOAM+SC、PaGO-LOAM 和该系统算法。通过图 9(b) 和 10(b) 的 Z 轴高度变化可以明显看

出,该路段颠簸不平整,再结合图 9(a) 和 10(a) 可以容易得出该算法精度比其他算法精度更高。




图 9 不同算法在 KITTI 02 序列上的评估

Fig. 9 Estimation on KITTI 02 of different algorithms

该系统在 KITTI 02 序列上进行了绝对轨迹误差 (absolute trajectory error, ATE) 的评估,其结果分析如图 11 所示,其中图 11(c) 从上到下依次对应算法 LeGO-LOAM+SC、提出算法、Pago LOAM 和 Lego LOAM。与此同时,将详细数据记入了表格中,如表 1 所示。




图 10 不同算法在 KITTI 05 序列上的评估

Fig. 10 Estimation on KITTI 05 of different algorithms

通过图 11 和表 1 可以看出该算法下运行的绝对轨迹误差平均值分别相比于 Lego-LOAM+SC、Pago LOAM 和 Lego LOAM 分别降低了 26.52%、95.43% 和 96.73 %。

2.3 实验结果分析

在室外实验和数据集实验中可以看出,不同算法的




图 11 提出算法在 KITTI 02 序列上的 ATE 结果
Fig. 11 Our algorithm ATE results of KITTI 02

建图效果对比结果表明,PaGO-LOAM 算法在开启闭环检测参数(设置为 True)后,采用了一种基于关键帧最近邻搜索的简单闭环检测方法。然而,从建图结果可以看出,该算法在复杂场景中依然存在明显的重影现象,无法有效构建精确的全局地图。相比之下,LeGO-LOAM+SC 算法通过对原始 3D 激光点云生成全局描述子,并结合两阶段闭环匹配搜索策略,实现了更精细的闭环检测。其建

表 1 KITTI 02 序列上不同算法的绝对轨迹误差值

Table 1 Absolute trajectory errors on KITTI 02 of different algorithms

算法对比	RMSE	mean	median	std	min	max	SSE
Lego LOAM	16.48	303.78	14.11	5.84	5.07	30.46	1 261 807.22
Pago LOAM	11.37	217.2	10.25	3.32	5.39	26.12	600 727.38
Lego LOAM+SC	14.75	13.50	10.99	5.96	3.55	30.36	1 011 089.03
本文	10.52	9.92	8.75	3.51	3.31	23.43	5 14 461.86

图结果显示,闭环匹配效果较好,未出现重影问题。然而,该算法在处理点云时存在过度稀疏化的问题,导致地图中噪点较多,整体建图质量有所下降。与上述方法相比,提出的闭环检测算法被集成到一个松耦合 SLAM 系统中进行公平测试,结果显示,该算法不仅能够准确识别闭环并有效解决重影问题,还能生成更加细致且高质量的全局地图,在建图质量和细节完整性上表现出显著优势。

3 结 论

这种克服复杂地面的 SLAM 系统架构,通过地面优化和闭环检测提高 SLAM 的准确性,同时将该算法部署到四足机器狗平台上。为了验证所提方法的有效性,使用真实场景数据集和 KITTI 数据集与几种典型的 SLAM 方法进行对比测试。结果表明,提出方法在复杂的地形环境和大规模的环境下,可以提供实时、长期、鲁棒和高

精度的自我运动估计。该系统虽通过地面优化一定程度解决了机器人在户外环境建图过程中的 Z 轴飘移问题,但未针对四足机器人本体结构提出优化方案。未来,将进一步对四足机器人腿部里程计进行机器人建图优化,通过在后端图优化中构建腿部里程计约束因子,进一步提高算法的性能。

参考文献

[1] SHAN T X, ENGLT B, MEYERS D, et al. LIO-SAM: Tightly-coupled lidar inertial odometry via smoothing and map[C]. IEEE/RSJ International Conference on Intelligent Robots and Systems, 2020: 5135-5142.

[2] XU W, CAI Y X, HE D J, et al. FAST-LIO2: Fast direct lidar-inertial odometry[J]. IEEE Transactions on Robotics, 2022, 38(4), 2053-2073.

[3] 诸葛晶昌, 高宏, 罗其俊, 等. 激光雷达 IMU 紧耦合 SLAM 算法研究[J]. 仪器仪表学报, 2024, 45(11):

- 243-251.
- ZHUGE J CH, GAO H, LUO Q J, et al. Research on tightly coupled SLAM algorithm for LiDAR IMU [J]. Chinese Journal of Scientific Instrument, 2024, 45 (11): 243-251.
- [4] 周治国, 曹江微, 邸顺帆. 3D 激光雷达 SLAM 算法综述[J]. 仪器仪表学报, 2021, 42(9): 13-27.
- ZHOU ZH G, CAO J W, DI SH F. Overview of 3D LiDAR SLAM algorithms [J]. Chinese Journal of Scientific Instrument, 2021, 42(9): 13-27.
- [5] RUMMELHARD L, PAIGWAR A, NÈGRE A, et al. Ground estimation and point cloud segmentation using spatiotemporal conditional random field [C]. IEEE Intelligent Vehicles Symposium, 2017: 1105-1110.
- [6] 任家卫, 徐晓苏. 基于平面特征的地面机器人雷达-惯性里程计外参标定方法[J]. 仪器仪表学报, 2025, 46(2): 344-354.
- REN J W, XU X S. Ground robot LiDAR-inertial odometry calibration based on plane constraint [J]. Chinese Journal of Scientific Instrument, 2025, 46(2): 344-354.
- [7] 孙伟, 曾豪霆, 张小瑞, 等. 基于点云强度和地面约束的大范围激光 SLAM [J]. 电子测量与仪器学报, 2024, 38(4): 66-75.
- SUN W, ZENG H T, ZHANG X R, et al. Large scale based on point cloud strength and ground constraints Lidar SLAM[J]. Journal of Electronic Measurement and Instrumentation, 2024, 38(4): 66-75.
- [8] STEINKE N, GOEHRING D, ROJAS R, et al. Groundgrid: LiDAR point cloud ground segmentation and terrain estimation [J]. IEEE Robotics and Automation Letters, 2023, 9(1): 420-426.
- [9] ZERMAS D, IZZAT I, PAPANIKOLOPOULOS N. Fast segmentation of 3D point clouds: A paradigm on LiDAR data for autonomous vehicle applications[C]. 2017 IEEE International Conference on Robotics and Automation, 2017: 5067-5073.
- [10] PAIGWAR A, ERKENT Ö, SIERRA-GONZALEZ D, et al. GndNet: Fast ground plane estimation and point cloud segmentation for autonomous vehicles [C]. 2020 IEEE/RSJ International Conference on Intelligent Robots and Systems, 2020: 2150-2156.
- [11] SHAN T X, ENLOT B. LeGO-LOAM: Lightweight and ground-optimized LiDAR odometry and mapping on variable terrain[C]. IEEE/RSJ International Conference on Intelligent Robots and Systems, 2018: 4758-4765.
- [12] SEO D U, LIM H, LEE S, et al. PaGO-LOAM: Robust ground-optimized LiDAR odometry [C]. 2022 19th International Conference on Ubiquitous Robots, 2022: 1-7.
- [13] LIM H, OH M, MYUNG H. Patchwork: Concentric zone-based region-wise ground segmentation with ground likelihood estimation using a 3D LiDAR sensor [J]. IEEE Robotics and Automation Letters, 2021, 6(4): 6458-6465.
- [14] WEI X, LYU J X, SUN J, et al. GCLO: Ground constrained LiDAR odometry with low-drifts for GPS-denied indoor environments [C]. 2022 International Conference on Robotics and Automation, 2022: 2229-2235.
- [15] PAN Y, XIAO P CH, HE Y J, et al. MULLS: Versatile LiDAR SLAM via multi-metric linear least square [C]. 2021 IEEE International Conference on Robotics and Automation, 2021: 11633-11640.
- [16] KOIDE K, MIURA J, MENEGATTI E. A portable three-dimensional LiDAR-based system for long-term and wide-area people behavior measurement [J]. International Journal of Advanced Robotic Systems, 2019, 16(2): 1729881419841532.
- [17] LEE S, LIM H, MYUNG H. Patchwork ++: Fast and robust ground segmentation solving partial under-segmentation using 3D point cloud [C]. 2022 IEEE/RSJ International Conference on Intelligent Robots and Systems, 2022: 13276-13283.
- [18] 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, 2018: 4802-4809.
- [19] KAESSE M, JOHANSSON 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.
- [20] 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, 2012: 3354-3361.
- [21] GEIGER A, LENZ P, STILLER C, et al. Vision meets

robotics: The kitti dataset[J]. The International Journal of Robotics Research, 2013, 32(11): 1231-1237.

[22] QUIGLEY M, CONLEY K, GERKEY B, et al. ROS: An open-source robot operating system [C]. ICRA Workshop on Open Source Software, 2009, 3(3.2): 5.

作者简介



王禹,2019 年于沈阳工程学院获得学士学位,现为东北大学博士研究生,主要研究方向为多传感器融合。

E-mail:2210747@ stu. neu. edu. cn

Wang Yu received his M.Sc. degree from Shenyang Institute of Engineering in 2019. He is currently a doctoral student at Northeastern University, with a main research focus on multi-sensor fusion.



王斐(通信作者),1997 年,1999 年于哈尔滨工业大学获得学士学位、硕士学位,2004 年于日本德岛大学获得博士学位,现为东北大学教授,主要研究方向为多模态感知与识别,人机交互。

E-mail:wangfei@ mail. neu. edu. cn

Wang Fei (Corresponding author) received his B. Sc. degree and M. Sc degree from the Harbin Institute of Technology in 1997 and 1999, received his Ph. D. degree from the University of Tokushima, Japan, in 2004. He is currently a professor at Northeastern University. His main research interests include multimode sensing and cognition, coordinated control of human-robot system.