

DOI: 10.19650/j.cnki.cjsi.J2108761

一种基于动态剔除和场景匹配的 Robust SLAM 方法*

邱佳月¹, 赖际舟², 方 玮², 吕 品², 李志敏²

(1. 航空工业苏州长风航空电子有限公司 苏州 215000; 2. 南京航空航天大学自动化学院 南京 211106)

摘要:针对动态环境中移动物体和结构变形引起激光雷达自主定位精度下降的问题,本文提出了一种 Dynamic Lego-loam 方法。为减小动态点误匹配给激光雷达里程计带来的误差,该方法首先在里程计精解算之前,提出了一种基于先验信息的点云粗配准算法用以剔除动态点,提高了激光雷达里程计的匹配精度。然后,针对环境中的动态变化带来的误差累积和建图重影问题,利用场景匹配的方法优化了传统基于半径的闭环检测方法。大范围采用基于半径的粗搜索快速定位至局部场景,小范围构建区域高度差描述符精确匹配至最相似历史帧,最终实现了精准的闭环检测并提高了动态环境中的建图精度。实验结果表明,在动态环境下,Dynamic Lego-loam 算法相较于 Lego-loam 算法自主定位精度提高了 63%。

关键词: SLAM; 动态环境; RANSAC; 闭环检测

中图分类号: TH86 **文献标识码:** A **国家标准学科分类代码:** 510. 80

A Robust SLAM method based on eliminating dynamic points and matching scenes

Qiu Jiayue¹, Lai Jizhou², Fang Wei², Lyu Pin², Li Zhimin²

(1. Avic Suzhou Changfeng Avionics Co., Ltd., Suzhou 215000, China; 2. School of Automation, Nanjing University of Aeronautics and Astronautics, Nanjing 211106, China)

Abstract: The moving objects and structural deformation in dynamic environments bring the degradation of autonomous positioning accuracy of lidar. To address this issue, a Dynamic Lego-loam method is proposed in this article. To reduce the error caused by the mismatch of dynamic points to the lidar odometry, a point cloud coarse registration method is firstly proposed, which is based on dynamic point culling before the odometer's precise calculation. The accuracy of laser odometry is improved. Then, to reduce the error accumulation and mapping ghosting caused by the dynamic environment, the traditional radius-based closed-loop detection method is optimized by the scene matching method. The radius-based rough search is used to quickly locate the local scene in a large range. The regional height difference descriptor is established in a small range to accurately match the most similar historical frames, which realizes an accurate closed-loop detection and improves the mapping accuracy in the dynamic environment. Compared with the Lego-loam algorithm, experimental results show that the Dynamic Lego-loam algorithm improves the autonomous positioning accuracy by 63% in a dynamic environment.

Keywords: SLAM; dynamic environment; RANSAC; loop detection

0 引 言

移动机器人被广泛应用于大型仓储、灾区救援等复杂、动态且卫星信号弱的工作环境中。其需要通过视觉或激光雷达等传感器感知自身状态,才能实现在有障碍物的环境中面向目标的自主运动,从而完成愈加复杂的作业^[1-2]。

三维激光雷达因其具有三维测距信息准、抗干扰能力强、探测范围广、近全天候工作等优点,逐渐成为同步定位与构图(simultaneous localization and mapping, SLAM)感知手段的主力军^[3-4]。

基于三维激光雷达的 SLAM 算法按照点云匹配方法可分为基于最近点迭代匹配方法^[5]、基于概率模型匹配^[6]以及基于特征匹配方法^[7]。

收稿日期:2021-10-25 Received Date: 2021-10-25

* 基金项目:国家自然科学基金(61973160)项目资助

基于特征匹配的 SLAM 算法以 Loam 算法^[8]、Lego-loam 算法^[9]为代表。从激光雷达点云数据中,通过数学规律提取几何特征,然后利用帧间特征对应关系进行移动机器人的状态估计和构图。与其它两类主流方法相比,一方面,该方法避免将全部点用于迭代计算,提高计算效率;另一方面,提取最具代表的几何特征,也避免了栅格化造成的特征丢失。因此,基于特征匹配的 SLAM 算法更适用于动态场景的自主定位。

大多数 SLAM 系统只能在固定不变的环境中运行。然而在实际应用中,自然因素和人类活动都可能导致不可预知的场景变化,此类场景称为动态环境^[10]。这种不可预知的动态改变对姿态估计的鲁棒性造成了很大的困扰,从而影响移动机器人的长期运行,为此学者展开了一系列的探索。

为实现动态环境下的精确定位,RP-VIO 算法^[11]采用视觉惯性紧耦合方法,引入平面单源性约束进行里程计算解算,有效提高算法在动态环境中的鲁棒性。以 SuMa++^[12]、VDO-SLAM^[13]为代表,采用语义分割与 SLAM 系统结合的方式,感知并剔除潜在动态物体。此类方法用于三维激光雷达,一方面其感知功能受到点云稀疏性的限制;另一方面潜在动态物体处于静止状态时,仍会被移除。为解决该问题,DymSLAM^[14]、AirDOS^[15]等算法,构建动态立体视觉 SLAM 系统,根据帧间运动相似性,采用运动分割的方法得到准确的刚性对象模板,有效剔除动态物体。

1 Dynamic Lego-loam 算法原理架构

根据帧间相似性原理,本文提出一种激光雷达的 Dynamic Lego-loam 算法,其算法方案如图 1 所示。首先利用基于曲率的方法提取特征点,为减小动态点误匹配给激光雷达里程计带来的误差,设计基于先验信息的点云粗配准算法用以剔除动态点^[16],并提供相对精确的转移矩阵初值用于莱温伯格马夸特(Levenberg-Marquardt, LM)精配准,同步进行地图构建。针对 Lego-loam 算法采用的基于半径搜索的回环优化方法,在大范围定位与建图中,无法完全消除环境中的动态变化带来的累积误差和建图重影问题。后端利用 Scan Context 环境描述符^[17](SC)优化基于半径的粗搜索(RS)方法,实现精准的回环检测,用以消除全局累积误差。最终实现在动态环境中,输出可靠精确的位姿估计与三维建图。

2 基于先验信息的 RANSAC 粗配准方法

在激光雷达点云配准中,场景中的静态点解算得到的转移矩阵往往是一致的,而动态点解算得到的转移矩

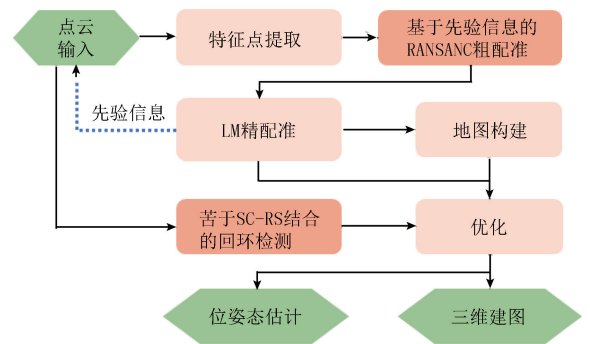


图 1 Dynamic-Lego-loam 算法框架

Fig. 1 The framework of the Dynamic-Lego-loam algorithm

阵则差别较大^[18-19]。因此,本文提出基于 RANSAC 的动态场景中点云匹配方法,可以通过一致性约束将动态点作为外点剔除,将静态点作为最优内点集用于后续的精配准。

然而,激光点云数量达到数万个,RANSAC 从中任选三组数据点解算转移矩阵的组合很多。传统 RANSAC 会对以上所有组合都进行上述的操作,运算量很大,因此对于采样点的选择就至关重要。如图 2 所示,本文采取基于先验信息的采样方法,以减少随机采样造成的时间浪费。而且,传统 RANSAC 仅采用内点占比评估模型,在噪声占比更大的环境中,可能会产生反而移除静态点的错误。针对于此,本文设计了内点分布因子评估模型,可以降低误移除的风险。另外通常情况下,只需要保证模型估计所采用的激光雷达点都是内点的概率足够高即可,因此本文通过设置合理的终止条件,避免无限采样迭代产生的不必要计算。

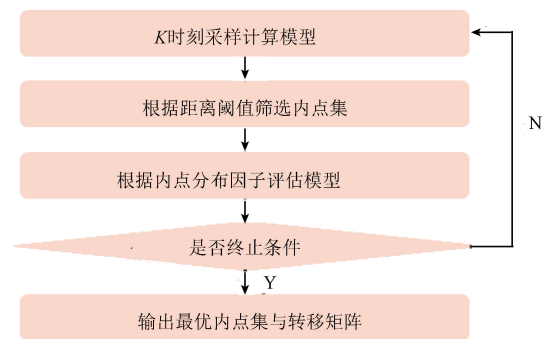


图 2 基于先验信息的 RANSAC 粗配准方法

Fig. 2 Rough registration of RANSAC based on prior information

2.1 基于先验分布信息的采样计算方法

在粗配准之前,根据 Lego-loam 算法的特征点提取方法,首先将激光雷达点云划分 $N_a \times N_b$ 段,其中 N_a 为激光雷达线数,记 $B_{k,l}$ 为第 k 帧点云的第 l 段。然后根据曲率式(1)筛选 $B_{k,l}$ 曲率 c 最大的 2 个点为角特征点和曲率 c

最小的4个点为平面特征点。

$$c = \frac{1}{|S| \cdot \|\mathbf{x}_i\|} \left\| \sum_{i \neq j} (\mathbf{x}_i - \mathbf{x}_j) \right\| \quad (1)$$

其中, $\mathbf{x}_i, \mathbf{x}_j$ 分别表示不同两激光点的坐标, S 选取10, 表示该激光点位于同一激光线根据时间戳顺序前后各5个点。

由于例如行人、车辆等动态点往往集中在小范围内, 而地面、墙面等静态点往往均匀分布在大范围内。因此本文在初始帧采样时, 在点云段中随机、离散地采样特征点, 以此避免采样点集中在动态小范围内, 降低无效采样的概率。另外, 由于激光雷达扫描频率较快, 相邻帧间点云相似率极高, 因此可以利用前一帧的最优内点集分布情况指导当前帧的采样。

记录前一帧 $B_{k,l}$ 中最优内点集的比重, 并将其映射到 $[0.1, 1]$, 以保证所有 $B_{k,l}$ 都存在被采样的机会, 从而避免 $B_{k,l}$ 因当前帧最优内点集比重为0而在接下来的每一帧均不会被采样的情况。映射后得到前一帧的地面点比率 $\varepsilon_{k-1,l}^*$ 为:

$$\varepsilon_{k-1,l}^* = \frac{n_{k-1,l}^{best}/n_{k-1,l}}{[0, 1]} [0.1, 1] \quad (2)$$

其中, $n_{k-1,l}^{best}$ 为 $B_{k,l}$ 在 $k-1$ 时刻的最优内点数量, $n_{k-1,l}$ 为 $B_{k,l}$ 在 $k-1$ 时刻的激光点数量。

对于当前帧的采样, 定义在 $B_{k,l}$ 中采样的概率分布 $p_{k,l}$ 如下:

$$p_{k,l} = \frac{\varepsilon_{k-1,l}^*}{\sum_l \varepsilon_{k-1,l}^*} \quad (3)$$

根据该概率分布得到第 k 帧抽取得到的全部采样数据集 D_k 为:

$$D_k = \bigcup_l (N_a \times N_b \times p_{k,l}) \quad (4)$$

在采样数据集 D_k 中抽样解算得到转换矩阵, 记为 $\mathbf{T}_{k+1,k} = [t_x, t_y, t_z, \theta_x, \theta_y, \theta_z]^T$ 。其中, t_x, t_y, t_z 分别是沿着雷达系的 x, y, z 轴的平移, $\theta_x, \theta_y, \theta_z$ 是旋转角度。

2.2 基于自适应距离阈值的内点集筛选方法

由于移动机器人所处环境错综复杂, 传统 RANSAC 通过设置固定距离阈值筛选内点集的方法, 在不断变化的环境中, 无法准确剔除动态点。因此, 本文引入特征点到模型的距离标准差, 自适应选取距离阈值, 提高其在动态环境中的鲁棒适应性。

预测 k 时刻特征点 $\mathbf{x}_{k,r}$ 的坐标 $\tilde{\mathbf{x}}_{k+1,r}$:

$$\tilde{\mathbf{x}}_{k+1,r} = \mathbf{T}_{k+1,k}(1:3) + \mathbf{R}_{k+1,k} \mathbf{x}_{k,r} \quad (5)$$

其中, $\mathbf{T}_{k+1,k}(1:3)$ 是 $\mathbf{T}_{k+1,k}$ 前三列向量, $\mathbf{R}_{k+1,k}$ 是由罗德里格斯公式定义的一个旋转矩阵:

$$\mathbf{R}_{k+1,k} = e^{\hat{\omega}\theta} = \mathbf{I} + \hat{\omega}\sin\theta + \hat{\omega}^2(1 - \cos\theta) \quad (6)$$

式中, \mathbf{I} 为单位矩阵, $\theta = \|\mathbf{T}_{k+1,k}(4:6)\|$, $\omega =$

$\frac{\mathbf{T}_{k+1,k}(4:6)}{\|\mathbf{T}_{k+1,k}(4:6)\|}$, $\hat{\omega}$ 是 ω 的反对称矩阵, $\mathbf{T}_{k+1,k}(4:6)$ 是 $\mathbf{T}_{k+1,k}$ 后3列向量。

采用 k 最近邻算法 (k-nearest neighbor, kNN), 在预测坐标集中搜索 $\mathbf{x}_{k,r}$ 的最邻近激光点坐标 $\mathbf{x}_{k+1,r}$, 将 $\mathbf{x}_{k+1,r}$ 作为激光点到该模型的距离。

通过式(7)计算自适应距离阈值 d_l , 若激光点到该模型的距离在阈值范围内, 则认为该激光点为内点。

$$d_l = 2\sqrt{\frac{1}{N} \sum (d_{k,r} - \bar{d})^2} \quad (7)$$

其中, $d_{k,r}$ 为 $\mathbf{x}_{k+1,r}$ 到 $\tilde{\mathbf{x}}_{k+1,r}$ 的欧式距离, 作为该激光点到模型的距离, \bar{d} 为所有激光点到模型的平均距离。

2.3 基于内点分布因子的模型评估方法

传统 RANSAC 仅通过内点数量评估模型的优劣。然而, 静态点往往不仅是占比最大的, 而且应该是分布最均匀、最离散的。基于此, 本文最优内点集的选择不再仅仅考虑内点占比, 还应考虑到内点分布。

首先, 计算 k 时刻内点所占比重为 T_{count} , 若该模型解算得到的 T_{count} 比原模型增大, 则更新内点集与模型, 否则保持原模型不变。

$$T_{count} = \frac{N_k^{in}}{N_k} \quad (8)$$

其中, N_k 表示第 k 帧激光点总数量, N_k^{in} 表示第 k 帧内点数量。

利用 $B_{k,l}$ 中内点的重心表示其中所有内点, 并且根据内点比率赋予 $B_{k,l}$ 相应的权重, 得到以下加权协方差矩阵 C :

$$C = \frac{\sum_l \varepsilon_{k,l}}{(\sum_l \varepsilon_{k,l})^2 - \sum_l \varepsilon_{k,l}^2} \sum_l \varepsilon_{k,l} (\mathbf{x}_{k,l} - \bar{\mathbf{x}}_k)(\mathbf{x}_{k,l} - \bar{\mathbf{x}}_k)^T \quad (9)$$

其中, $\mathbf{x}_{k,l}$ 为 $B_{k,l}$ 中内点的中心, $\bar{\mathbf{x}}_k = \frac{1}{\sum_l \varepsilon_{k,l}} \sum_l \varepsilon_{k,l} \mathbf{x}_{k,l}$ 为激光雷达特征点的权重中心, $\varepsilon_{k,l} = \frac{n_{k,l}^{in}}{n_{k,l}}$ 为 $B_{k,l}$ 中内点比重。

该加权协方差矩阵, 一方面可以减轻恰好符合模型的动态点带来的影响, 同时可以减小包含少量静态点的点云段给模型计算带来的影响。由此, 将二维内点分布评分因子 s 运用到三维点云中:

$$s = \left(\sum_l \varepsilon_l \right) \pi \sqrt{\det(C)} \quad (10)$$

该评估因子 s 反映内点分布, 因子越大则计算得到的模型质量越好。据此, 可以得到最优内点集并更新最优模型。

2.4 基于合理阈值的终止条件设置

如果采样概率分布准确,本文所提的算法可以经过少量迭代就可以获得符合终止条件的最优转移矩阵模型。本文通过设置合理的终止条件,避免无限采样,从而减少不必要的时间开销,为移动机器人的实时高精度定位提供保障。

终止条件 K_s 的计算如式(11)所示。当迭代次数大于终止条件时停止迭代,获得最优内点集及对应的转移矩阵 $T_{k+1,k}$ 作为精配准的初值。

$$K_s = \frac{\log \mu}{\log \left(1 - \left(\sum_l p_{k,l} \varepsilon_{k,l} \right)^3 \right)} \quad (11)$$

其中, μ 反映迭代过程中内点的概率分布要求,一般根据经验值设置。

激光雷达里程计精配准方法,采用 Lego-loam 中基于特征点的 LM 迭代计算。但参与解算的特征点集已经不再是全部的特征点集,而是筛除动态点的最优内点集,可以避免由于动态点的集中使迭代计算陷入局部最优解的风险。另外,采用粗配准解算得到的转移矩阵作为 LM 迭代初值,可以使迭代起点更加逼近于全局最优解,增大迭代解算得到全局最优解的概率。

3 基于 SC 优化 RS 的回环检测

Lego-loam 算法采用基于半径的回环检测方法,仅能大范围内粗略定位至距离最近场景。然而在面向动态场景时,一方面,动态障碍物带来的里程计偏差,引起最近距离的解算失误,因此仅采用距离约束可靠性较低;另一方面,该算法未在局部场景中修剪动态障碍物,动态障碍物会错误地投影在静态地图中,降低了地图构建的精确度和清晰度。

本文提出基于 SC 优化 RS 的回环检测方法,如图3所示。首先在大范围采用基于半径的粗搜索,快速定位至局部场景;利用区域高度差作为 Scan Context 描述符,同步当前帧的 Scan Context 描述符与局部场景的 Scan Context 描述矩阵实现相似性匹配,精确定位至最相似历史帧。最终实现快速精确的闭环检测,消除动态场景变化带来的全局累积误差,进一步优化位姿输出,提高构图精度。

3.1 基于局部静态地图的 RS 回环检测方法

在地图构建中,仅用之前所有帧的最优内点集用以构建点云地图,降低运算成本的同时移除局部静态地图中的动态障碍物。

同时,以较低频率选择关键帧构建位姿图,采用基于 RS 粗搜索方法保存与当前帧距离最近的关键帧。储存当前帧点云作为目标点云用以构建 Scan Context 描述符,储存搜索得到的历史帧及附近帧的 Scan Context 描述符,

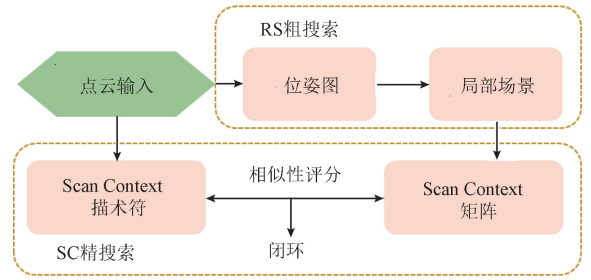


图3 基于 RS-SC 结合的回环检测方法

Fig. 3 The loop detection method based on RS-SC combination

形成待匹配局部场景的描述矩阵。


3.2 基于 SC 的闭环精搜索方法

1) Scan Context 描述符构建

如图4所示,本文采用极坐标系替代笛卡尔坐标系。首先以传感器的位置为原点,计算 XY 平面上每个点的方位角和半径。然后使用基于环和扇形的方法重新组织点云,在将点云沿径向使用环分割的同时,沿方位角采用扇形分区,那么环和扇形就能唯一索引到点云的任意区域。

这种做法能够进一步使得旋转式激光雷达点云在网格间均匀分布,而且远距离的网格也能保留更多的特征。相比于笛卡尔坐标系划分方法,能够提高同一网格在不同帧中的相似度。

传统方法中选取每一个区域中的高度最大值作为矩阵的数值。但一般情况下,即使激光雷达重复扫描同一位置,由于其扫描不重复性或安装的倾斜性,单单仅靠高度最大值无法进行场景相似性判断。因此,为了提高场景识别的鲁棒性,本文中选取每一区域中的高度最大值与高度最小值之差作为该特征矩阵的数值。至此,目



(a) 笛卡尔坐标网格划分

(a) Cartesian coordinate meshing

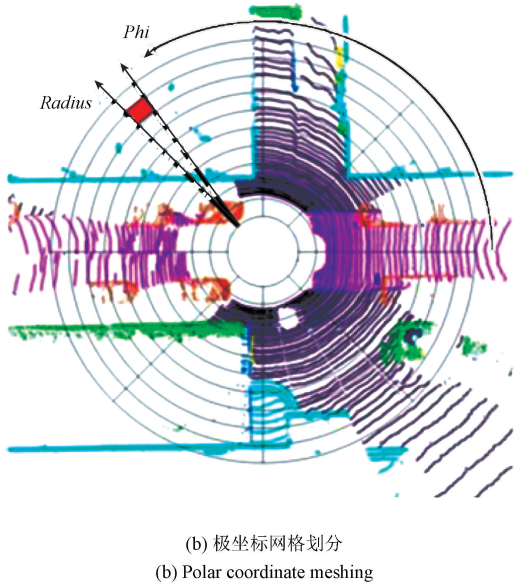


图4 两种 BEV 投影方法图

Fig. 4 Two methods of BEV projection



图5 SLAM 实验验证平台

Fig. 5 SLAM experiment evaluation platform

标点云的 Scan Context 描述符可以用一个 $N_s \times N_r$ 的矩阵描述。

2) Scan Context 相似性判断

为实现目标点云与局部场景的匹配,采用余弦距离表示点云 Scan Context 描述符的相似性。定义两帧点云的 Scan Context 描述符为 I^q 和 I^c , 余弦相似性公式 $d(I^q, I^c)$ 如下:

$$d(I^q, I^c) = \frac{1}{N_s} \sum_{j=1}^{N_s} \left(1 - \frac{c_j^q \cdot c_j^c}{\|c_j^q\| \|c_j^c\|} \right) \quad (12)$$

其中, c_j^q 和 c_j^c 分别是目标点云与待匹配点云的 Scan Context 的第 j 列的列向量。

为解决帧间列向量的平移问题,计算两个 Scan Context 描述符的所有列向量之间的距离,并取最小值作为最终的距离,那么列平移的最佳匹配关系就可以定义为:

$$c^* = \underset{c_k}{\operatorname{argmin}} D(I^q, I^c), \quad D < \tau \quad (13)$$

其中, τ 是设定的判断两个场景是否相似的距离阈值, c^* 是最终检测出来最佳匹配场景。至此实现了精准的闭环检测,消除了环境的动态变化带来的误差累积。

4 实验验证

为了能够验证本文 Dynamic Lego-loam 在动态环境中的自主定位性能,采用本文算法、Loam 算法与 Lego-loam 算法,在室内地下车库环境中实现自主定位并比较其定位与建图效果。

如图5所示,实验验证基于无人车平台系统。采用 Intel CORE i7-6700HQ 处理器,安装 Linux 操作系统,内存为 8 GB,显卡为 NVIDIA GTX960。激光雷达传感器为 16 线三维激光雷达 Velodyne VLP-16,最大探测距离为 100 m,垂直角度范围为 30° ,水平角度范围为 360° ,扫描频率设置为 10 Hz。采用徕卡 M60 全站仪作为参考真值,测距范围 1 500 m,测距精度 1 mm,测角范围 360° ,扫描频率 10 Hz。

为了更好地验证算法的定位精度与回环检测效果,在车库中进行两组实验:

实验一:移动机器人静止,0~23.6 s 处于静态环境,在 23.6 s 加入行人围绕移动机器人不断走跑运动干扰,比较静态环境下的定位结果与动态环境下的定位结果。

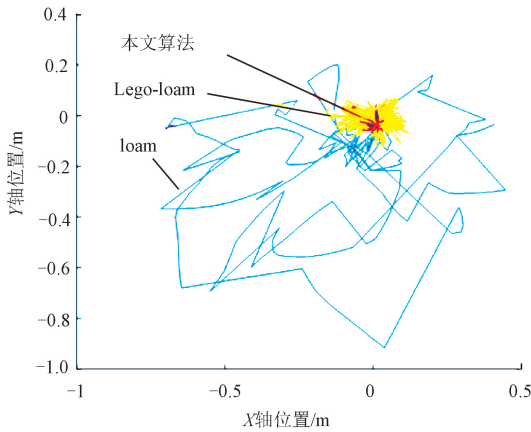
实验二:移动机器人真实行驶轨迹为图 10 全站仪所测,不断存在行人、车辆干扰,采用全站仪作为参考结果,比较 SLAM 算法定位和构图的效果。

4.1 自主定位结果分析

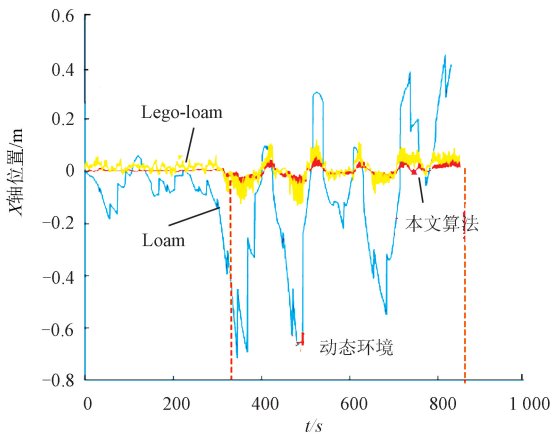
图6为实验一(移动机器人静止实验)结果。图6(a)为静止实验的二维轨迹,图6(b)~(d)为传统方法与本文提出方法的定位结果图,橘色虚线区间为加入动态物体影响的时间段。因传感器静止,定位结果即反映定位误差。

由定位结果图可以看出,移动机器人在完全静止的环境下,3种 SLAM 算法定位性能较好。当进入动态环境中,此时 Loam 算法定位误差急剧增大,Lego-loam 算法也进入较大的波动。与此同时,由于 Loam 算法未对全局地图进行修正,其定位误差逐渐累积。Lego-loam 采用 GTSAM 库进行回环矫正,使其能不断修正偏移误差,但其高度方向的误差较大并无法修正。本文算法在传统算法的基础上,由于加入剔除动态点的粗配准,能够极大程度减少动态障碍物带来的影响,在高度方向也表现良好。同时,本文采用更加精准的闭环检测方法,最终实现累积误差的消除,回归至原点。

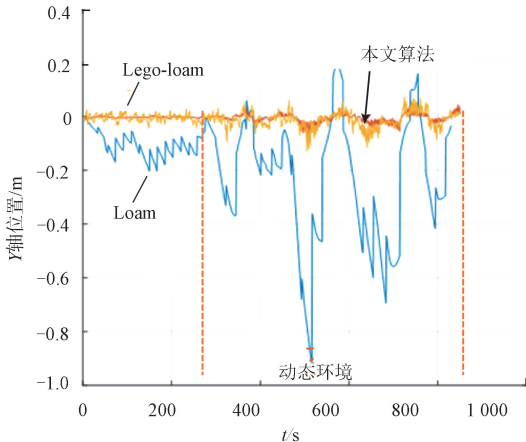
图7为实验二(移动机器人机动实验)结果,图7(a)中的黑色轨迹为全站仪测量得到的参考真值。可以看出,由于机动实验中存在较多的转弯、颠簸和动态障碍物的影响,相比于其他两种算法,本文算法综合表现最好。




(a) 实验一二维轨迹
(a) Two-dimensional trajectory



(b) 实验一X轴位置误差
(b) X-axis position errors



(c) 实验一Y轴位置误差
(c) Y-axis position errors



(d) 实验一Z轴位置误差
(d) Z-axis position errors

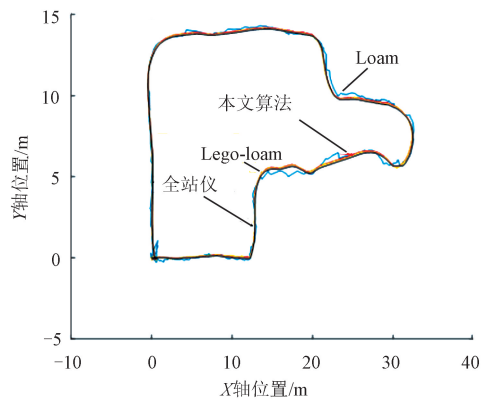
图6 移动机器人静止实验结果

Fig. 6 Experiment results of the stationary mobile robot

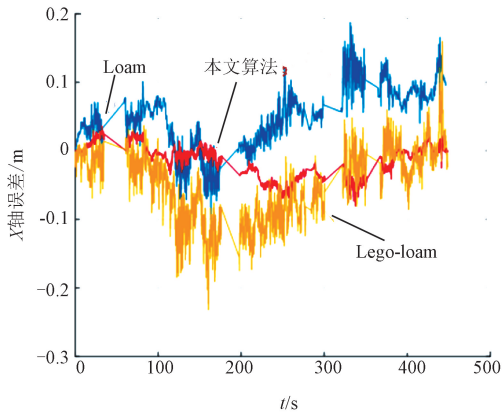
表1 实验二定位误差分析

Table 1 Experiment 2 positioning error analysis m


坐标轴	参数	Loam	Lego-loam	本文
X 轴	最大误差	0.188	0.232	0.080
	平均误差	0.048	0.056	0.021
	误差均方根	0.067	0.072	0.028
Y 轴	最大误差	0.141	0.181	0.077
	平均误差	0.027	0.060	0.032
	误差均方根	0.035	0.070	0.032
Z 轴	最大误差	0.093	0.252	0.084
	平均误差	0.049	0.116	0.036
	误差均方根	0.042	0.129	0.054



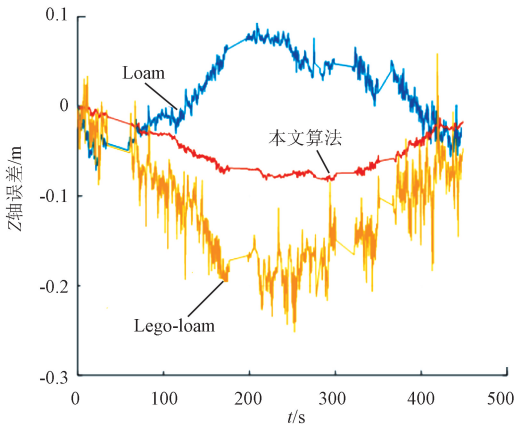
(a) 实验二二维轨迹
(a) Two-dimensional trajectory



(b) 实验二X轴位置误差
(b) X-axis position errors



(c) 实验二Y轴位置误差
(c) Y-axis position errors



(d) 实验二Z轴位置误差
(d) Z-axis position errors

图 7 移动机器人机动实验结果

Fig. 7 Experiment results of the maneuverable mobile robot

4.2 三维建图结果分析

如图 8~10 所示为三维地图重建结果,其中图 8 为 Loam 算法得到的建图结果,图 9 为 Lego-loam 算法得到的建图结果,图 10 为本文提出的 SLAM 算法建图结果。




图 8 Loam 三维建图效果

Fig. 8 The 3D map built by Loam




图 9 Lego-loam 三维建图效果

Fig. 9 The 3D map built by Lego-loam




图 10 本文算法三维建图效果

Fig. 10 The 3D map built by Dynamic-Lego-loam

由通过 3 种 SLAM 算法得到的三维地图与地下车库实际场景对比,由于 Loam 算法不包含闭环检测,回到起点时无法实现累积误差的消除,因此利用 Loam 得到的三维地图偏移较大。Lego-loam 算法采用 GTSAM 库能够实现简单的基于半径的回环检测,但由图 10 可以看出移动

机器人的重复路径无法实现严格的闭环,在高度方向上仍然存在一定的漂移,反映在地图中即出现构图的偏移。本文算法在构图中,一方面去除动态点云的影响,另一方面执行严格的闭环检测,因此构建的三维地图与实际场景相符合。

综上所述,本文所提的 SLAM 算法能够解决动态障碍物对导航结果带来的影响,实现移动机器人在动态环境中的精准可靠自主定位。

5 结 论

本文针对三维激光雷达 SLAM 面向动态环境时精度受损问题,提出了一种 Dynamic Lego-loam 方法。算法分析与实验结果表明:

1) 环境中的动态点影响激光雷达自主定位精度。本文提出的基于先验信息的 RANSAC 粗配准方法,能够去除动态点在精配准中带来的误匹配,并提供较为精确的迭代初值。

2) 针对动态环境中误差累积问题,本文将基于半径的粗搜索与基于场景匹配的精搜索相结合,用于闭环检测。该方法能够在较大范围内快速定位至局部场景,小范围精确匹配到最邻近场景,实现误差的精准矫正。

3) 本文所提出的动态点剔除方法,基于 RANSAC 拟合得到的模型为最佳模型的假设,在环境中动态点占据大多数,且维持同一运动状态的情况下效果较差。在该情况下,可考虑采用其他传感器辅助实现激光雷达自身定位。

参考文献

- [1] WEI B, REN M, ZENG W, et al. Perceive, attend, and drive: Learning spatial attention for safe self-driving[C]. 2021 IEEE International Conference on Robotics and Automation (ICRA), IEEE, 2021: 4875-4881.
- [2] 袁洪,张扬,来奇峰,等. 低轨星座/惯导紧组合导航技术研究[J]. 导航定位与授时,2022,9(1):41-49.
YUAN H, ZHANG Y, LAI Q F, et al. Research on LEO constellation/inertial navigation compact navigation technology[J]. Navigation Positioning and Timing, 2022, 9(1):41-49.
- [3] WANG Z, DING S, LI Y, et al. Range adaptation for 3d object detection in lidar[C]. Proceedings of the IEEE/CVF International Conference on Computer Vision Workshops, 2019, DOI. 10.1109/ICCVW.2019.00285.
- [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. A review of SLAM algorithms for 3D lidar [J]. Chinese Journal of Scientific Instrument, 2021, 42(9): 13-27.
- [5] KONECNY J, PRAUZEK M, KROMER P, et al. Novel point-to-point scan matching algorithm based on cross-correlation[J]. Mobile Information Systems, 2016(15): 1-11.
- [6] CABALLERO F, MERINO L. DLL: Direct LIDAR localization: A map-based localization approach for aerial robots[C]. 2021 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS), IEEE, 2021: 5491-5498.
- [7] ZHAO L, MAO Z, HUANG S. Feature-based SLAM: Why simultaneous localisation and mapping? [J]. Robotics: Science and Systems 2021, 2021.
- [8] ZHANG J, SINGH S. Low-drift and real-time lidar odometry and mapping[J]. Autonomous Robots, 2017, 41(2): 401-416.
- [9] SHAN T, ENGLLOT 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.
- [10] 冯明驰,刘景林,李成南,等. 一种多焦距动态立体视觉 SLAM[J]. 仪器仪表学报,2021,42(11):200-209.
FENG M CH, LIU J L, LI CH N, et al. A multi-focal length dynamic stereo vision SLAM [J]. Chinese Journal of Scientific Instrument, 2021, 42(11): 200-209.
- [11] RAM K, KHARYAL C, HARITHAS S S, et al. RP-VIO: Robust plane-based visual-inertial odometry for dynamic environments[C]. 2021 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS), IEEE, 2021: 9198-9205.
- [12] CHEN X, MILIOTO A, PALAZZOLO E, et al. Suma++: Efficient lidar-based semantic slam[C]. 2019 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS), IEEE, 2019: 4530-4537.
- [13] ZHANG J, HENEIN M, MAHONY R, et al. VDO-SLAM: A visual dynamic object-aware SLAM system[J]. ArXiv Preprint, 2020, ArXiv:2005.11052.
- [14] WANG C, LUO B, ZHANG Y, et al. DymSLAM: 4D dynamic scene reconstruction based on geometrical motion segmentation [J]. IEEE Robotics and Automation Letters, 2020, 6(2): 550-557.

- [15] QIU Y, WANG C, WANG W, et al. AirDOS: Dynamic SLAM benefits from articulated objects [J]. ArXiv Preprint, 2021, ArXiv:2109.09903.
- [16] TAN W, LIU H, DONG Z, et al. Robust monocular SLAM in dynamic environments [C]. 2013 IEEE International Symposium on Mixed and Augmented Reality (ISMAR), IEEE, 2013: 209-218.
- [17] 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.
- [18] 孙龙龙, 江明, 焦传佳. 基于运动矢量的改进视觉 SLAM 算法[J]. 电子测量与仪器学报, 2020, 34(9): 23-31.
SUN L L, JIANG M, JIAO CH J. Improved visual SLAM algorithm based on motion vector [J]. Journal of Electronic Measurement and Instrumentation, 2020, 34(9): 23-31.
- [19] 贾松敏, 郑泽玲, 张国梁, 等. 基于混合特征的机器人定位与地图创建[J]. 仪器仪表学报, 2018, 39(12): 198-206.
JIA S M, ZHENG Z L, ZHANG G L, et al. Robot localization and map creation based on mixed features[J]. Chinese Journal of Scientific Instrument, 2018, 39(12): 198-206.

作者简介



邱佳月(通信作者), 分别于 2017 年和 2021 年于南京航空航天大学获得学士和硕士学位。现为航空工业苏州长风航空电子有限公司助理工程师, 主要研究方向为机器视觉与人工智能。

E-mail: 867638510@qq.com

Qiu Jiayue (Corresponding author) received her B.Sc. degree and M.Sc. degree both from Nanjing University of Aeronautics and Astronautics in 2017 and 2021, respectively. She is currently an assistant engineer of at Avic Suzhou Changfeng Avionics Co., Ltd., Her main research interests include machine vision and artificial intelligence.



赖际舟, 分别于 2000 年和 2005 年于南京航空航天大学获得学士和博士学位, 现为南京航空航天大学教授、博士生导师, 主要研究方向为惯性导航及多信息可靠融合导航技术。

E-mail: laijz@nuaa.edu.cn

Lai Jizhou received his B.Sc. degree and Ph.D. degree both from Nanjing University of Aeronautics and Astronautics (NUAA) in 2000 and 2005, respectively. He is currently a professor and a Ph.D. advisor at NUAA. His main research interests include inertial navigation and integrated navigation system.