

柯福阳^{1,2} 陆佳嘉³ 杭琦琳^{1,4} 宋宝^{1,5} 陈伟超¹

面向实际场景 SLAM 应用的光照适应性研究

摘要

为探究环境感知设备在 SLAM 算法应用过程中的光照适应性问题,在不同光照强度下分别进行激光雷达和深度相机 SLAM 算法的验证性评估实验.基于四轮差速机器人,搭载 16 线激光雷达和深度相机,结合 LOAM(Lidar Odometry And Mapping)和 RTAB-MAP(Real-Time Appearance-Based Mapping)算法,分别在明暗环境中分析验证设备光照适应性.实验结果表明:在明亮环境下,基于视觉 SLAM 和激光 SLAM 系统偏差的中误差分别为 0.203 和 0.644 m;在黑暗环境中两者偏差的中误差分别为 0.282 和 0.683 m;深度相机在明、暗环境中的定位建图效果均优于激光雷达,深度相机的光照适应性更强.

关键词

激光 SLAM;视觉 SLAM;RTAB-MAP 算法;LOAM 算法

中图分类号 TP391.4

文献标志码 A

收稿日期 2022-05-06

资助项目 2020 年无锡市科技发展资金(N20201011);第十六批江苏省“六大人才高峰”高层次人才项目(XYDXX-045);江苏省自然科学基金(BK20211037)

作者简介

柯福阳,男,博士,教授,研究方向为 SLAM 无人驾驶特定场景应用、三维激光工业测量与控制.ke.fuyang@qq.com

- 1 南京信息工程大学 无锡研究院,无锡,214000
- 2 南京信息工程大学 遥感与测绘学院,南京,210044
- 3 无锡学院 物联网工程学院,无锡,214105
- 4 南京信息工程大学 自动化学院,南京,210044
- 5 安徽理工大学 空间信息与测绘工程学院,淮南,232001

0 引言

作为自动驾驶中最为常见的技术——SLAM(Simultaneous Localization And Mapping,同时定位与建图)技术具有广泛的应用,它可以为单车智能自动驾驶完成例如导航、路径规划等多项复杂任务提供基础数据.SLAM 技术可以在未知环境下实现机器人位置信息提取的同时完成对周围环境的构建^[1-2],根据建立的运动载体的运动方程和观测方程,利用贝叶斯方法估计载体的状态信息.在实际场景的测试实验中,Leonard 等^[3]将 SLAM 问题归纳为 3 个方面:载体自定位、目标定位和建图.

根据传感器类别,SLAM 主要分以下 3 类:1) 基于相机的视觉 SLAM,例如基于单目、双目和深度相机的视觉 SLAM.视觉 SLAM 常用算法有 Mono-SLAM^[4]、PTAM^[5]、LSD-SLAM^[6]、RTAB-MAP^[7]、ORB-SLAM^[8-10]、SVO^[11]等.其中:PTAM 把整个 SLAM 工程分为处理前端的特征跟踪和后端的建图线程,在保持鲁棒的同时可以提高系统的实时性;ORB-SLAM 采用 PTAM 的思想,将系统分为多个工作线程,该算法在系统稳定性方面相较于 PTAM 有较大的提高,并且在公开数据集下有优良的评价;SVO 是基于半直接法的视觉 SLAM 算法,可以有效提高系统的运行速度;LSD-SLAM 算法是在 2014 年提出的基于直接法半稠密的单目 SLAM 算法,其建图效果优于其他单目 SLAM 算法.2) 基于激光雷达的 SLAM,按照设备不同可以分为基于 2D、3D 和固态激光雷达的激光 SLAM^[12].激光 SLAM 常用算法有 EKF-SLAM^[13]、Gmapping^[14]、Hector SLAM^[15]、LOAM^[16]、Cartographer SLAM^[17]、LEGO-LOAM^[18]等.其中:Gmapping 和 Hector SLAM 算法可用于 2D 激光雷达 SLAM 系统,LOAM 和 LEGO-LOAM 算法可用于 3D 激光雷达 SLAM 系统,Cartographer SLAM 算法可用于 2D 或者 3D 激光雷达 SLAM 系统.3) 基于多种传感器融合的 SLAM.常用的融合 SLAM 算法有视觉惯导组合 SLAM、视觉激光组合 SLAM 和激光雷达惯导组合 SLAM 等.虽然有众多的 SLAM 技术开源算法和开源数据库,且众多学者一直致力于拓展 SLAM 算法,但是专注于 SLAM 算法的实际应用场景中的鲁棒性和光照适应性的开源评价较少.

对于 SLAM 算法在未知环境中进行实际应用的鲁棒性、光照适应性的研究亦显得十分重要.LOAM(Lidar Odometry and Mapping)算法和 RTAB-MAP(Real-Time Appearance-Based Mapping)分别适用于激

光雷达和深度相机 SLAM, 算法运行效率高且稳定性强, 被广泛应用于实际场景. 本文分别在明亮的高辨识环境和黑暗的低辨识环境下进行激光 SLAM 和视觉 SLAM 实验, 通过提取特征量的方式对 LOAM 算法和 RTAB-MAP 算法的效率进行对比分析, 进一步探究 SLAM 算法在实际应用环境中的鲁棒性和光照适应性, 为提高 SLAM 算法的落地质量和效率提供数据参考. 本文采用的无人驾驶小车实验测试平台同时搭建了激光雷达和深度相机传感器, 底盘为四驱控制, 处理器为 Jetson-nano.

1 激光 SLAM 算法原理

本文采用常用的 LOAM 算法进行激光 SLAM 实验. 如图 1 所示, LOAM 算法从采集到的点云数据中提取锐利的特征边和平整外表特征, 通过采集点或线的特征匹配来估计激光雷达的运动. LOAM 算法的核心步骤包括特征提取和位姿估计^[19].

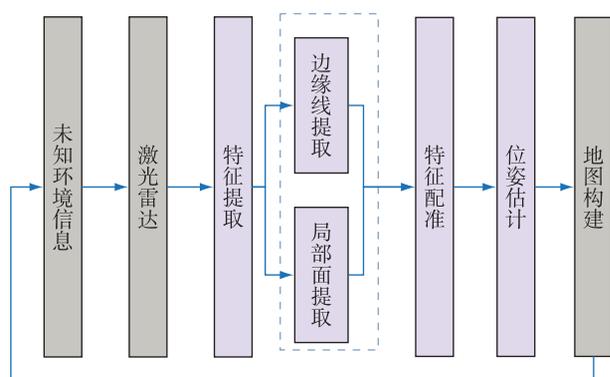


图 1 激光 SLAM 系统框架

Fig. 1 Lidar SLAM system framework

1.1 特征提取

在确定和提取特征点时, LOAM 算法提取点云集中的边缘点和平面片点的具体操作为: 假设第 k 次扫描获得点云 P_k , 采集 P_k 中一特征点 i , 坐标记为 $X_{(k,i)}$, 在 i 的邻域内取点 j , 坐标记为 $X_{(k,j)}$, 记点 j 的集合为 S , 则点 i 处局部曲面的曲率 c 定义为

$$c = \frac{1}{|S| \|X_{(k,i)}\|} \sum_{j \in S, j \neq i} \|X_{(k,i)} - X_{(k,j)}\|, \quad (1)$$

其中, $|S|$ 表示集合 S 内所含点的个数, 实验取值为 5. 在本文实验中提取特征遵循边缘点为曲率 c 最大的点, 平面片点为曲率 c 最小的点的原则, 将曲率 c 大于 0.005 的点作为边缘点, 曲率 c 小于 0.005 的点作为平面片点.

为了使提取的特征点明显且分布均匀, 将整个

区域划分成无数个子区域, 每个子区域内最多含有 2 个边界点和 4 个平面片点, 这就保证了特征点数量不超过子区域数量^[20]. 在提取特征点时需避免几种情况: 1) 为了不影响整体点集, 要避免提取局部平面与激光束大致平行的点, 如图 2 上图中的 B 点; 2) 为了提高检测效率, 避免重复检测减少冗余点, 要避免提取周围已有特征点的点, 如图 2 下图中的 C 和 F 点; 3) 为了提高检测有效性, 利于特征匹配要避免提取在某帧点云中遮挡而在另一帧点云中未被遮挡的边界区域的点, 如图 2 下图中的 D 点.

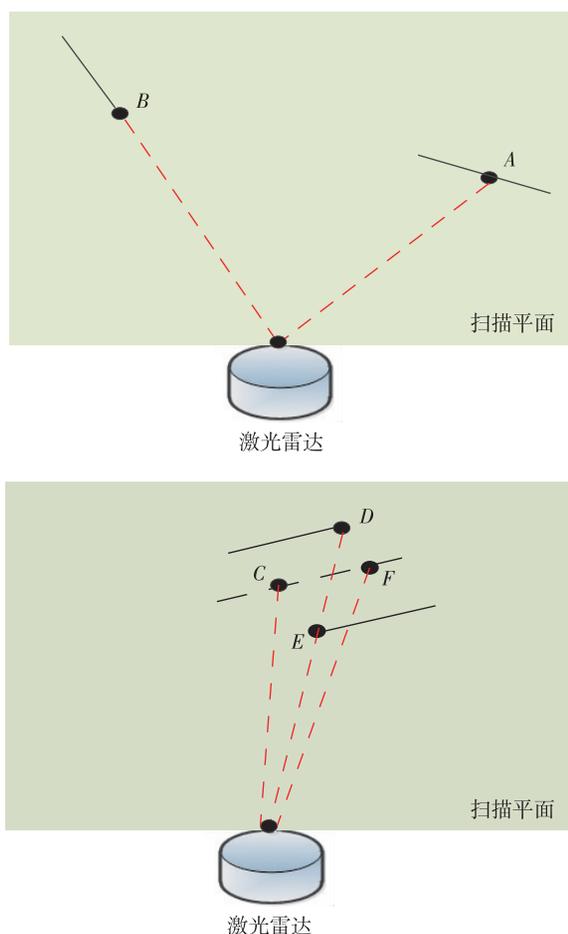


图 2 特征提取的误区示意

Fig. 2 Schematic diagram of the points that will not be selected as feature points

1.2 位姿估计

LOAM 算法在实时估计载体运动状态时采用线性运动模型. 如图 3 所示, 将第 $k-1$ 次扫描时的起止时间分别记为 t_{k-1} 与 t_k , 第 k 次扫描时的起止时间分别记为 t_k 与 t_{k+1} , 在 t_{k-1} 至 t_k 期间得到的点云记为 p_{k-1} , 在 t_k 至 t_{k+1} 期间得到的点云记为 p_k , 将 p_{k-1} 点云集转换到 t_k 时刻的坐标系上后得到的点云集记为

\bar{P}_{k-1} .由此,通过 \bar{P}_{k-1} 与 P_k 进行点云匹配即可完成激光雷达的运动估计.

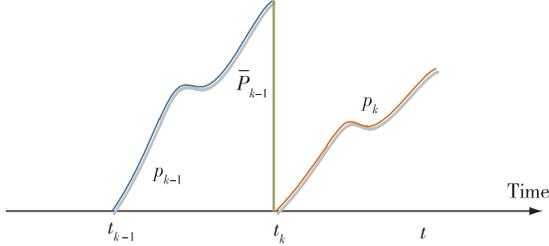


图 3 点云匹配示意

Fig. 3 Schematic diagram of point cloud matching

假设无人驾驶设备匀速运动,第 k 次扫描开始时刻为 t_k ,当前时刻为 t , $\mathbf{T}_k(t)$ 是时间段 $[t_k, t]$ 的姿态, $\mathbf{T}_k(t)$ 包含平移向量 $\boldsymbol{\tau}_k(t) = [t_x, t_y, t_z]$ 和旋转角度向量 $\boldsymbol{\theta}_k(t) = [\theta_x, \theta_y, \theta_z]^T$,旋转矩阵 $\mathbf{R}_k(t)$ 展开如下:

$$\mathbf{R}_k(t) = e^{\hat{\boldsymbol{\theta}}_k(t)} = \mathbf{I} + \frac{\hat{\boldsymbol{\theta}}_k(t)}{\|\boldsymbol{\theta}_k(t)\|} \sin \|\boldsymbol{\theta}_k(t)\| + \left(\frac{\hat{\boldsymbol{\theta}}_k(t)}{\|\boldsymbol{\theta}_k(t)\|} \right)^2 (1 - \cos \|\boldsymbol{\theta}_k(t)\|), \quad (2)$$

其中, e 表示自然对数, $\hat{\boldsymbol{\theta}}_k(t)$ 是 $\boldsymbol{\theta}_k(t)$ 的对称矩阵.将第 k 次扫描的点云 P_k 中任意一点 $i, j \in P_k$ 的获取时间记为 $t_{(k,i)}$,那么, $[t_k, t_{(k,i)}]$ 时间的位姿 $\mathbf{T}_{(k,i)}$ 可以通过线性插值计算:

$$\mathbf{T}_{(k,i)} = \frac{t_{(k,i)} - t_k}{t - t_k} \mathbf{T}_k(t). \quad (3)$$

需要注意的是,考虑 $\mathbf{T}_k(t)$ 是一个变量,点云 P_k 中提取的边缘点 e_k 和平面片点 h_k 可通过下式进行坐标系转换:

$$\bar{X}_{(k,i)} = \mathbf{R}_{(k,i)} X_{(k,i)} + \boldsymbol{\tau}_{(k,i)}, \quad (4)$$

其中, $X_{(k,i)}$ 表示点云 P_k 中的边缘点 e_k 或平面片点 h_k , $\bar{X}_{(k,i)}$ 表示坐标转换后对应的 \bar{e}_k 或 \bar{h}_k , $\mathbf{R}_{(k,i)}$ 和 $\boldsymbol{\tau}_{(k,i)}$ 是 $\mathbf{T}_{(k,i)}$ 对应的旋转矩阵和平移向量.

2 视觉 SLAM 算法原理

本文采用常用的 RTAB_MAP 算法进行视觉 SLAM 实验.如图 4 所示,RTAB-MAP 算法本质上是一种与时间和尺度无关的基于图优化的算法.其核心思想是当地图中定位点的数目使得找到定位匹配的时间超过某个设定阈值时,RTAB-MAP 算法将 WM (Working Memory) 中形成闭环可能性小的定位点转移到 LTM (Long-Term Memory) 中,被转移的定位点不再参与下次闭环检测运算.当检测到一个闭

环时,从 LTM 中重新取回其直接定位点放入 WM 中用于将来的闭环检测.RTAB-MAP 算法的关键包特征签名、权值优化、贝叶斯估计和词袋库更新优化.

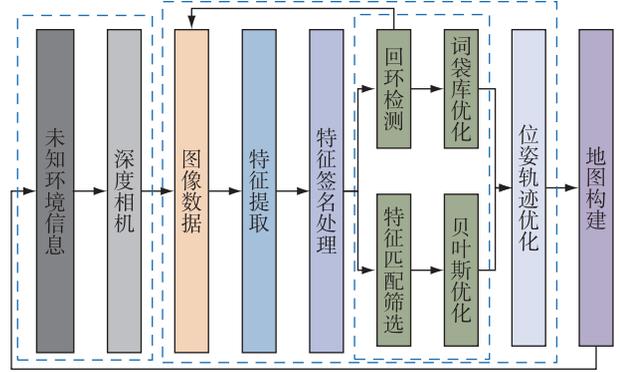


图 4 视觉 SLAM 系统框架

Fig. 4 Visual SLAM system framework

2.1 特征签名

RTAB-MAP 算法使用词袋方法创建图像签名,将 t 时刻的图像签名记为 z_t .完整的图像签名可通过视觉词典中的单词来描述,通过提取图像中 SURF 特征点构建视觉词汇向量,结合 K-Means 算法构造单词表.RTAB-MAP 选用在线增量方法创建词典,该方法优于传统的预先训练词典法,具有广泛的应用空间.

2.2 权值优化

为了更新获取到的定位点的权重,将当前时刻的定位点 L_t 的签名 z_t 与 STM (Short Time Memory) 中的最后一个定位点的签名 z_c 进行比较,两者的相似度 s 衡量方式为

$$s(z_t, z_c) = \begin{cases} \frac{N_{\text{pair}}}{N_{z_t}}, & N_{z_t} \geq N_{z_c}, \\ \frac{N_{\text{pair}}}{N_{z_c}}, & N_{z_t} < N_{z_c}, \end{cases} \quad (5)$$

其中, N_{pair} 表示定位点签名能匹配到单词对的数量, N_{z_t} 与 N_{z_c} 分别对应签名 z_t 与 z_c 的总单词数目.如果相似度 $s(z_t, z_c)$ 超过设定的相似度阈值,则被选择比较的定位点将被转入到 L_t 中.RTAB-MAP 算法在融合后的签名中保留了在签名 z_c 和 z_t 中都存在的单词,因此对这两个签名的识别能力较强,而对其他签名的判别能力则较弱.

2.3 贝叶斯估计

RTAB-MAP 算法采用贝叶斯估计进行后期的闭环检测,通过估计当前时刻定位点 L_t 与存储在 WM

中的定位点之间能够形成一个闭环的概率来检测闭环。

通常,为便于实现闭环检测,将 t 时刻所有闭环假设的随机变量记为 s_t ,以 $s_t = i$ 表示 L_t 位闭环结点,即在结点处 L_t 与一个已经被检测的定位点 L_i 形成闭环。以 $s_t = -1$ 表示 L_t 是一个新的定位点,因此,在 WM 中所有最新定位点在时间索引 i 的后验概率分布 $p(S_t | L_t)$ 为

$$p(S_t | L') = \rho p(L_t | S_t) \sum_{i=-1}^{t_n} (s_t | s_{t-1} = i) \cdot p(S_{t-1} = i | L_{t-1}), \quad (6)$$

其中, σ 是归一化项, $L' = L_{-1}, \dots, L_t$ 是定位点序列,序列 L' 仅包含来自 WM 和 STM 中的定位点。不同于经典贝叶斯估计中的定长序列 L' ,由于新的定位点被不断创建,且 WM 中的定位点会被转移到 LTM 中或重新从 LTM 中取回,因此,式(6)中的 L' 长度不断变化。

概率 $p(L_t | S_t)$ 本质是衡量定位点 L_t 与定位点 s_t 的相似度。RTAB-MAP 算法采用似然函数 $\gamma(S_t | L_t)$ 来区分定位点 L_t 与不同定位点对应相似值之间差异。根据式(5),将当前定位点 L_t 与点集中有可能与其形成闭环得定位点 s_t 进行比较,则得到系列的相似度 $s_j = s(z_t, z_j)$,然后,将每个相似度与它们标准差 σ 之间的差异利用所有不为零的 s_i 的均值标准化,标准化方式如下:

$$P(L_t | S_t = j) = \gamma(S_t | L_t) = \begin{cases} \frac{s_j - \sigma}{u}, & S_j \geq \mu + \sigma, \\ 1, & \text{其他.} \end{cases} \quad (7)$$

而对于 $s_t = -1$ 的新的定位点,标准化方式如下:

$$P(L_t | S_t = -1) = \gamma(S_t = -1 | L_t) = \frac{\mu}{\sigma} + 1. \quad (8)$$

上述计算结果与相似度的均值以及标准差之间的比率有关。如果 $\gamma(S_t = -1 | L_t)$ 比较大,即 L_t 并不与 WM 中某个特定的定位点相似,则 $\sigma < \mu$,那么 L_t 是新定位点的可能性较大。

$p(S_t | S_{t-1}) = i$ 叫做转移模型,是在已知一个 s_{t-1} 的分布条件下用来预测 s_t 的分布的,这与机器人在时刻 $t-1$ 到时刻 t 间的移动是类似的。与 $p(S_{t-1} = -1 | L^{t-1})$ (也就是过滤器中递推的一部分)一起,构成了下一轮闭环检测的置信值(这个置信值本质上计算的是一个全概率,也就是在给定条件下产生某个结果的概率)。转移模型的计算方式如下:

在 $t-1$ 处闭环形成的前提条件下, t 处出现一个新定位点的概率为

$$P(S_t = -1 | S_{t-1} = -1) = 0.9. \quad (9)$$

在 $t-1$ 处没有闭环形成的前提条件下, t 与 i 形成闭环的概率为

$$P(S_t = i | S_{t-1} = -1) = 0.1/N_{\text{WM}}, \quad i \in [0, t_n]. \quad (10)$$

在 $t-1$ 与 j 发生闭环的条件下, t 处出现一个新定位点的概率为

$$P(S_t = i | S_{t-1} = j) = 0.1, \quad i, j \in [0, t_n]. \quad (11)$$

在 $t-1$ 与 j 形成闭环的前提下, t 与 i 形成闭环的概率为

$$P(S_t = i | S_{t-1} = j), \quad i, j \in [0, t_n]. \quad (12)$$

上述概率由以 j 为中心的离散高斯曲线定义,即 $j-16$ 至 $j+16$ 范围内 i 不为空时的值。如果之前形成了闭环,那么在拓扑图中有些定位点可能会有超过两个的邻接定位点,则这些邻接定位点可能并不完全都在 WM 中而是被转移到了 LTM 中,此时概率会被归一化到 0.9。

2.4 词袋库更新优化

完成闭环检测后还需要进一步完善检测词袋库。为了使 WM 更全面,将 LTM 中仍然存在的一些闭环概率最高且表现出与 WM 中的邻近定位点同样特征的定位点直接转移,即取回到 WM 中。完成取回过程后,则直接用更新后的定位点去更新词袋中的单词。

3 实验与分析

本实验使用微型工业级别的实验小车,如图 5 所示,该实验小车选择四驱差速转向的控制底盘,车身长 30 cm、宽 26 cm、高 7 cm,自重(质量)约 20 kg,在保证安全的前提下其最大负载可至 15 kg。将多线激光雷达和深度相机安置在实验平台的顶端,其中相机位于车顶前部,不仅可以扫描拍摄到周围环境,还可以实现载体自定位以及周围环境的建图。在实验小车的中心位置装有 IMU 姿态传感器,可以融合激光雷达和相机信息优化最终的定位结果和地图。

3.1 实验环境

本实验选择某研究院一楼展览大厅作为实验场地,实验实景如图 6 所示,大厅平面如图 7 所示。在实验场地中,有展览桌、展览柜、试验舱、电柜等硬件设备。为了验证 SLAM 算法的适用性和鲁棒性,通过改变展厅灯、窗帘的开关分别进行明亮与黑暗场景的实验。

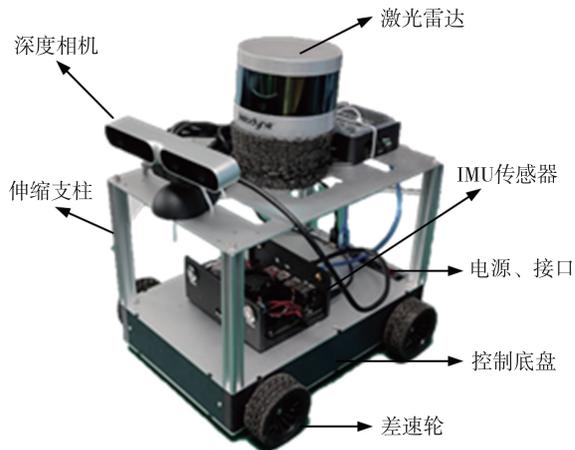


图 5 小车结构和实物外观

Fig. 5 Structure schematic and physical appearance of the experiment cart



a. 左向实景



b. 右向实景

图 6 大厅实景

Fig. 6 Left view (top) and right view (bottom) of the hall to carry out experiment

3.2 评价指标

为了对室内制图结果进行定量评价,本实验首先利用 ROS 可视化工具展出构建的点云地图,然后采用 RVIZ 中的量取功能量取特征物或者点的直径、胸径、长度等信息.将连续量测 5 次的平均值作为测量值 d ,采用常规的距离测量方式连续量测 5 次的平均值作为真实值 d_0 .通过计算测量值与真实值之间的距离偏差及其统计值作为评价标准来衡量实验结果的优劣. n 个特征物或者点的量测距离的偏差 ε 、平均偏差 $\bar{\varepsilon}$ 和偏差的中误差 m 的计算方法如下:

$$\varepsilon = d - d_0, \quad (13)$$

$$\bar{\varepsilon} = \frac{1}{n} \sum_{i=1}^n \|\varepsilon_i\|, \quad (14)$$

$$m = \sqrt{\frac{\varepsilon\varepsilon}{n}}. \quad (15)$$

如图 8 所示,本实验场景选取的特征物为展览桌、展览柜、试验舱、电柜等硬件设备,选取的特征点为桌拐点、实验设备角点和脚点.

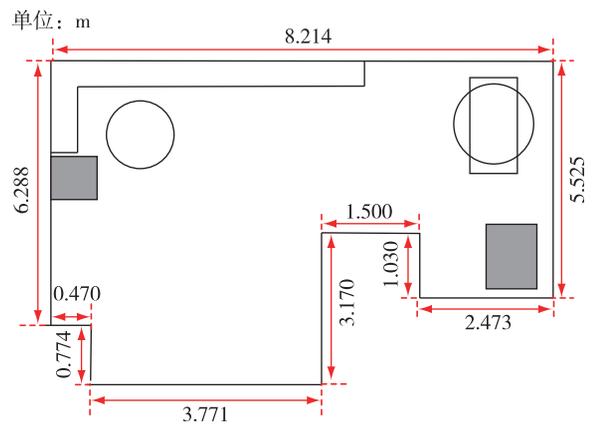


图 7 大厅平面

Fig. 7 Floor plan of the hall



图 8 特征物与特征点

Fig. 8 Feature objects and feature points

3.3 激光 SLAM 实验与分析

3.3.1 明亮场景下激光 SLAM 实验

在明亮场景中 LOAM 算法计算获得的完整点云地图如图 9 所示,点云地图中部分区域成图效果一般,点云表面较粗糙.整体上点云分布离散不均匀,左边效果较好,右边较差.分析其原因主要是实验采用的 16 线激光雷达布线少,不能很好地表征视野范围内的物体和区域.

实验中分别量测特征物点云的长宽,量测特征点之间的距离,获得的量测值以及相应的偏差如表 1 所示.实验测量值与真实值之间存在差异,最大偏差为 1.961 m,最小偏差为 0.016 m,平均偏差为 0.398

m, 偏差中误差为 0.644 m. 此外, 由于使用的激光雷达每次只能扫描 16 个点, 加之小车运动过程激光束受到遮挡, 实验中出现多处未被测量特征点.

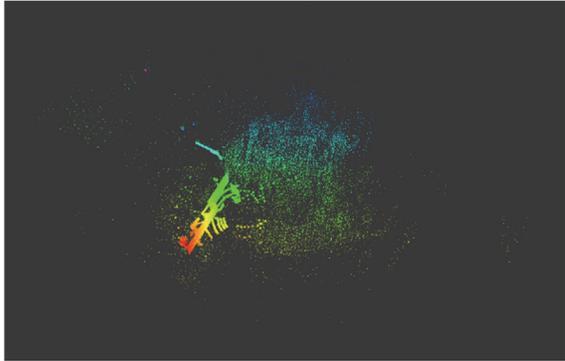


图 9 明亮环境下 SLAM 点云

Fig. 9 SLAM point cloud in bright environment

表 1 激光雷达在明亮场景下表征物、表征点定量分析

Table 1 Quantitative analysis of objects and points acquired by lidar in bright environment m

表征 编号	长度		偏差	表征 编号	长度		偏差
	测量值	真实值			测量值	真实值	
1	1.323	1.071	0.252	24		6.920	
2	1.287	1.342	-0.055	25	0.578	1.049	-0.471
3		2.525		26		0.936	
4		7.261		27	5.381	6.387	-1.006
5	2.890	2.732	0.158	28		8.227	
6		1.417		29	0.558	0.584	-0.026
7	2.611	2.653	-0.042	30	4.516	4.432	0.084
8	1.325	1.562	-0.237	31		8.399	
9	2.486	2.926	-0.440	32		6.942	
10		5.245		33		7.340	
11	1.395	1.411	-0.016	34	3.874	2.936	0.938
12	2.249	2.204	0.045	35		6.172	
13		5.539		36		6.040	
14		2.615		37	5.671	4.819	0.852
15	1.925	1.688	0.237	38	2.268	2.339	-0.071
16		1.870		39	2.137	1.741	0.396
17	1.557	2.405	-0.848	40	2.787	2.597	0.190
18	2.824	2.675	0.149	41		0.921	
19		7.772		42	2.882	3.885	-1.003
20	2.228	2.992	-0.764	43	4.181	6.142	-1.961
21		6.689		44		4.251	
22	6.531	5.678	0.853	45		2.836	
23		2.773		46	2.843	2.896	-0.053

3.3.2 黑暗场景下激光 SLAM 实验

在黑暗场景中对室内环境进行三维地图构建, LOAM 算法计算获得的点云地图如图 10 所示. 黑暗环境下构建的点云地图中粗糙点云数量较多, 复杂

区域或者遮蔽区域处建立的点云地图效果不明显, 点云散射、表面粗糙. 其原因除了实验采用的激光雷达布线较低之外, 黑暗的环境一定程度上限制了实验小车的行驶, 其轨迹无法遍及整个室内区域, 进而无法获取完整的室内环境点云信息.

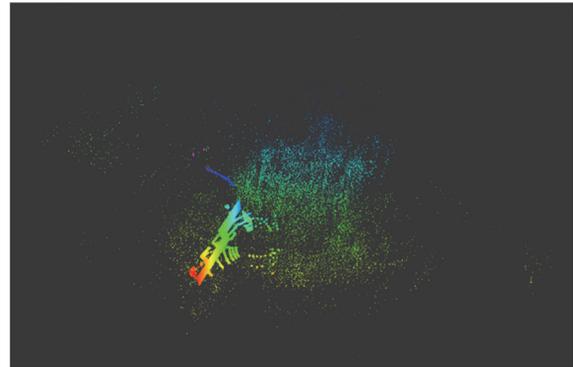


图 10 黑暗环境下 SLAM 点云

Fig. 10 SLAM point cloud in dark environment

实验中特征物和特征点的量测值以及相应的偏差如表 2 所示. 实验测量值与真实值之间存在差异,

表 2 激光雷达在黑暗场景下表征物、表征点定量分析

Table 2 Quantitative analysis of objects and points acquired by lidar in dark environment m

表征 编号	长度		偏差	表征 编号	长度		偏差
	测量值	真实值			测量值	真实值	
1	1.369	1.071	0.298	24		6.920	
2	1.274	1.342	-0.068	25	0.468	1.049	-0.581
3		2.525		26		0.936	
4		7.261		27	5.277	6.387	-1.110
5	2.882	2.732	0.150	28		8.227	
6		1.417		29	0.529	0.584	-0.055
7	2.616	2.653	-0.037	30	4.538	4.432	0.106
8	1.389	1.562	-0.173	31		8.399	
9	2.482	2.926	-0.444	32		6.942	
10		5.245		33		7.340	
11	1.390	1.411	-0.021	34	4.173	2.936	1.237
12	2.138	2.204	-0.066	35		6.172	
13		5.539		36		6.040	
14		2.615		37	5.845	4.819	1.026
15	2.012	1.688	0.324	38	2.232	2.339	-0.107
16		1.870		39	2.283	1.741	0.542
17	1.672	2.405	-0.733	40	2.740	2.597	0.143
18	2.868	2.675	0.193	41		0.921	
19		7.772		42	2.938	3.885	-0.947
20	2.474	2.992	-0.518	43	4.138	6.142	-2.004
21		6.689		44		4.251	
22	6.659	5.678	0.981	45		2.836	
23		2.773		46	2.835	2.896	-0.061

最大偏差为 2.004 m,最小偏差为 0.021 m,平均偏差为 0.477 m,偏差中误差为 0.683 m,均大于明亮环境下的偏差统计结果,黑暗环境下实验结果偏差明显增大.

3.4 深度相机视觉 SLAM 实验与分析

3.4.1 明亮场景下深度相机视觉 SLAM 实验

在明亮场景中采用 RTAB-MAP 算法构建室内环境的三维点云地图,结果如图 11 所示.虽然大部分区域的点云表面平滑,但部分区域的点云较为粗糙.对于规则物体,其点云表面较为平滑,但对于复杂环境和不规则物体,其点云表面则较为粗糙,点云信息不完整,成图效果较差.

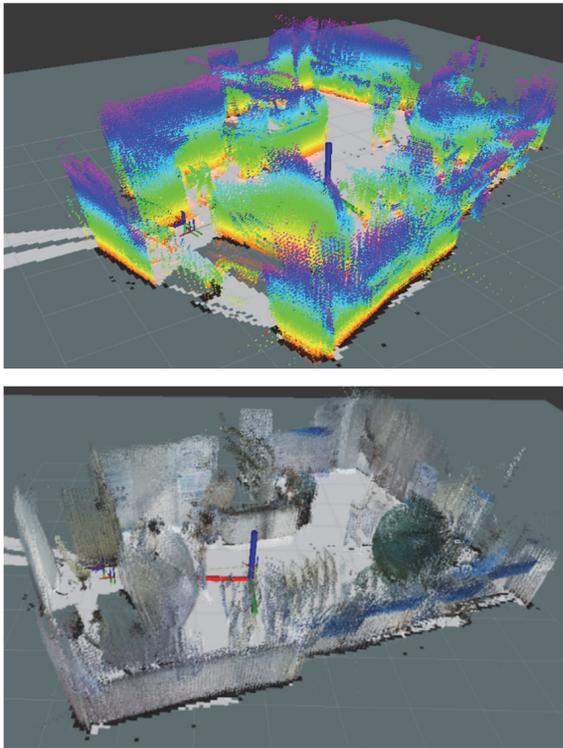


图 11 明亮环境下 V-SLAM 点云

Fig. 11 V-SLAM point cloud in bright environment

实验中分别量测特征物点云的长宽,量测特征点之间的距离,获得的量测值以及相应的偏差如表 3 所示.实验值与真实值之间存在不同程度的差异,最大偏差为 1.519 m,最小偏差为 0.005 m,平均偏差为 0.112 m,偏差中误差为 0.203 m.值得注意的是,由于深度相机可快速成像,避免了激光雷达逐点扫描的弊端,实验中相关预选特征点都被测量到.

在采集数据的过程当中,由于选取的特征点或特征物时采用的是人工选取的方式,也就造成了实验对比时选取结果的偏差,进而影响实验偏差;在进

表 3 深度相机在明亮场景下表征物、表征点定量分析

Table 3 Quantitative analysis of objects and points acquired by depth camera in bright environment m

表征 编号	长度		偏差	表征 编号	长度		偏差
	测量值	真实值			测量值	真实值	
1	1.087	1.071	0.016	24	6.967	6.920	0.047
2	1.286	1.342	-0.056	25	1.298	1.049	0.249
3	2.681	2.525	0.156	26	0.941	0.936	0.005
4	7.443	7.261	0.182	27	6.549	6.387	0.162
5	2.791	2.732	0.059	28	8.322	8.227	0.095
6	1.458	1.417	0.041	29	0.629	0.584	0.045
7	2.714	2.653	0.061	30	4.385	4.432	-0.047
8	1.755	1.562	0.193	31	8.346	8.399	-0.053
9	3.085	2.926	0.159	32	6.894	6.942	-0.048
10	5.342	5.245	0.097	33	7.495	7.340	0.155
11	1.416	1.411	0.005	34	2.985	2.936	0.049
12	2.097	2.244	-0.147	35	6.018	6.172	-0.154
13	5.434	5.539	-0.105	36	5.893	6.040	-0.147
14	2.544	2.615	-0.071	37	4.869	4.819	0.050
15	0.823	1.688	-0.865	38	2.098	2.339	-0.241
16	2.057	1.870	0.187	39	1.796	1.741	0.055
17	0.886	2.405	-1.519	40	2.682	2.597	0.085
18	2.665	2.675	-0.010	41	0.93	0.921	0.009
19	7.611	7.772	-0.161	42	3.739	3.885	-0.146
20	3.038	2.992	0.046	43	6.137	6.142	-0.005
21	6.511	6.689	-0.178	44	4.302	4.251	0.051
22	5.744	5.678	0.066	45	2.704	2.836	-0.132
23	2.689	2.773	-0.084	46	2.845	2.896	-0.051

行实测时,采用的是人工距离测量方法,也造成了测量值的人工误差.在明亮的实验环境下,基于深度相机的 SLAM 点云匹配结果和建图效果明显优于基于 16 线激光雷达的结果.

3.4.2 黑暗场景下深度相机视觉 SLAM 实验

在黑暗环境中采用 RTAB-Map 算法构建的点云地图如图 12 所示,点云表面粗糙区域较明亮情况下粗糙区域有所增加,主要集中在复杂区域和遮蔽区域.主要原因是由于上述区域内,周围环境信息较为复杂,而黑暗环境又增加了实验车的行驶难度,进而影响相机的摄取效果,由此则影响了区域的最终点云地图,致使该区域下的点云表面变得更为粗糙.

实验中特征物和特征点的量测值以及相应的偏差如表 4 所示.实验测量值与真实值之间存在差异,最大偏差为 1.154 m,最小偏差为 0.005 m,平均偏差为 0.143 m,偏差中误差为 0.282 m.黑暗环境下实验平台行驶迟缓,导致建图信息不完整而影响建图

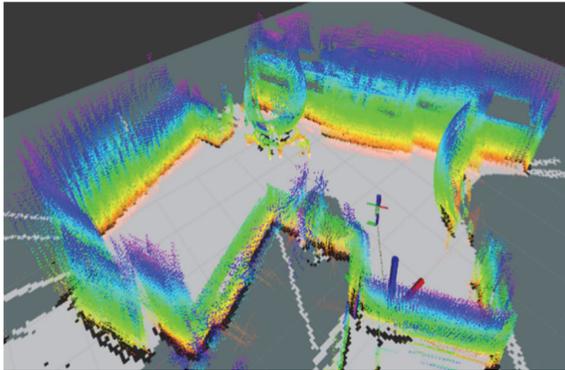


图 12 黑暗环境下 V-SLAM 点云

Fig. 12 V-SLAM point cloud in dark environment

表 4 深度相机在黑暗环境下表征物、表征点定量分析

Table 4 Quantitative analysis of objects and points acquired by depth camera in dark environment m

表征编号	长度			表征编号	长度		
	测量值	真实值	偏差		测量值	真实值	偏差
1	1.087	1.071	0.016	24	6.966	6.920	0.046
2	1.285	1.342	-0.057	25	1.306	1.049	0.257
3	2.650	2.525	0.125	26	0.941	0.936	0.005
4	7.454	7.261	0.193	27	6.563	6.387	0.176
5	2.793	2.732	0.061	28	8.323	8.227	0.096
6	1.465	1.417	0.048	29	0.635	0.584	0.051
7	2.713	2.653	0.060	30	4.382	4.432	-0.050
8	1.747	1.562	0.185	31	8.347	8.399	-0.052
9	3.096	2.926	0.170	32	6.883	6.942	-0.059
10	5.331	5.245	0.086	33	7.447	7.34	0.107
11	1.418	1.411	0.007	34	2.976	2.936	0.040
12	2.105	2.244	-0.139	35	6.091	6.172	-0.081
13	5.414	5.539	-0.125	36	5.882	6.04	-0.158
14	2.535	2.615	-0.080	37	4.895	4.819	0.076
15	1.603	1.688	-0.085	38	2.109	2.339	-0.230
16	2.063	1.87	0.193	39	1.794	1.741	0.053
17	1.251	2.405	-1.154	40	2.608	2.597	0.011
18	2.664	2.675	-0.011	41	0.928	0.921	0.007
19	7.585	7.772	-0.187	42	3.870	3.885	-0.015
20	3.042	2.992	0.050	43	6.136	6.142	-0.006
21	6.505	6.689	-0.184	44	4.309	4.251	0.058
22	5.747	5.678	0.069	45	2.653	2.836	-0.183
23	2.698	2.773	-0.075	46	2.946	2.896	0.050

效果,增加了寻找特征信息的难度,相较于表 3 中明亮环境下的偏差结果,黑暗环境下获得的实验结果偏差多数明显增大.另外,相对激光雷达测试实验的最终结果,评价指标较低,说明成图精度优于激光雷达后的图精度.

4 结论

针对 SLAM 算法落地时缺乏先验数据支撑以及算法实际应用的鲁棒性和光照适应性研究较少等问题,本文分别在明亮和黑暗两种环境下采用 LOAM 算法进行了激光 SLAM 实验,并采用 RTAB-MAP 算法进行了深度相机视觉 SLAM 实验.通过对比分析实验,得出在空间较小的室内环境中,基于 RTAB-MAP 算法的深度相机 SLAM 建图效果优于基于 LOAM 算法的 16 线激光雷达 SLAM 建图效果,前者具有更好的鲁棒性,光照适应性更强.

本文的 SLAM 实验扩充了 SLAM 实际运行数据库,为 SLAM 算法的实际落地效果提供了结果参考,有利于室内自动驾驶场景的未来研究.

参考文献

References

- [1] Guo Z Y, Huang Y P, Hu X, et al. A survey on deep learning based approaches for scene understanding in autonomous driving[J]. Electronics, 2021, 10(4) : 471
- [2] Grigorescu S, Trasnea B, Cocias T, et al. A survey of deep learning techniques for autonomous driving[J]. Journal of Field Robotics, 2020, 37(3) : 362-386
- [3] Leonard J J, Durrant-Whyte H F. Simultaneous map building and localization for an autonomous mobile robot [C] // IEEE/RSJ International Workshop on Intelligent Robotics and Systems. November 3 - 5, 1991, Osaka, Japan. IEEE, 1991 : 1442-1447
- [4] Davison A J, Reid I D, Molton N D, et al. MonoSLAM: real-time single camera SLAM[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2007, 29(6) : 1052-1067
- [5] Klein G, Murray D. Parallel tracking and mapping for small AR workspaces[C] // 2007 6th IEEE and ACM International Symposium on Mixed and Augmented Reality. November 13 - 16, 2007, Nara, Japan. IEEE, 2007 : 225-234
- [6] Engel J, Schöps T, Cremers D. LSD-SLAM: large-scale direct monocular SLAM [M] // European Conference on Computer Vision 2014, Part II, LNCS 8690. Springer, Cham, 2014 : 834-849
- [7] Labbé M, Michaud F. RTAB-Map as an open-source lidar and visual simultaneous localization and mapping library for large-scale and long-term online operation[J]. Journal of Field Robotics, 2019, 36(2) : 416-446
- [8] Mur-Artal R, Montiel J M M, Tardós J D. ORB-SLAM: a versatile and accurate monocular SLAM system[J]. IEEE Transactions on Robotics, 2015, 31(5) : 1147-1163
- [9] Mur-Artal R, Tardós J D. ORB-SLAM2: an open-source SLAM system for monocular, stereo, and RGB-D cameras [J]. IEEE Transactions on Robotics, 2017, 33(5) : 1255-1262
- [10] Campos C, Elvira R, Rodríguez J J G, et al. ORB-SLAM3:

- an accurate open-source library for visual, visual-inertial, and multimap SLAM [J]. IEEE Transactions on Robotics, 2021, 37(6): 1874-1890
- [11] Forster C, Pizzoli M, Scaramuzza D. SVO: fast semi-direct monocular visual odometry [C] // 2014 IEEE International Conference on Robotics and Automation (ICRA). May 31 - June 7, 2014, Hong Kong, China. IEEE, 2014: 15-22
- [12] 马争光, 赵永国, 刘成业, 等. 激光和视觉融合 SLAM 方法研究综述 [J]. 计算机测量与控制, 2019, 27(3): 1-6
MA Zhengguang, ZHAO Yongguo, LIU Chengye, et al. Survey of SLAM with laser-camera fusion sensor [J]. Computer Measurement & Control, 2019, 27(3): 1-6
- [13] Smith R C, Cheeseman P. On the representation and estimation of spatial uncertainty [J]. The international Journal of Robotics Research, 1986, 5(4): 56-68
- [14] Grisetti G, Stachniss C, Burgard W. Improved techniques for grid mapping with Rao-Blackwellized particle filters [J]. IEEE Transactions on Robotics, 2007, 23(1): 34-46
- [15] Kohlbrecher S, Stryk O V, Meyer J, et al. A flexible and scalable SLAM system with full 3D motion estimation [C] // 2011 IEEE International Symposium on Safety, Security, and Rescue Robotics. November 1 - 5, 2011, Kyoto, Japan. IEEE, 2011: 155-160
- [16] Zhang J, Singh S. Low-drift and real-time lidar odometry and mapping [J]. Autonomous Robots, 2017, 41(2): 401-416
- [17] Hess W, Kohler D, Rapp H, et al. Real-time loop closure in 2D LIDAR SLAM [C] // 2016 IEEE International Conference on Robotics and Automation. May 16 - 21, 2016, Stockholm, Sweden. IEEE, 2016: 1271-1278
- [18] 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
- [19] Lepetit V, Moreno-Noguer F, Fua P. EPnP: an accurate $O(n)$ solution to the PnP problem [J]. International Journal of Computer Vision, 2009, 81(2): 155
- [20] 陈贵宾. 基于三维激光雷达的自动驾驶车辆高精度地图构建 [D]. 长春: 吉林大学, 2019
CHEN Guibin. High definition MAP construction for autonomous vehicle based on 3D lidar [D]. Changchun: Jilin University, 2019

Illumination adaptability of SLAM applications in real scenes

KE Fuyang^{1,2} LU Jiajia³ HANG Qilin^{1,4} SONG Bao^{1,5} CHEN Weichao¹

¹ Wuxi Research Institute, Nanjing University of Information Science & Technology, Wuxi 214000, China

² School of Remote Sensing & Geomatics Engineering, Nanjing University of Information Science & Technology, Nanjing 210044, China

³ School of Internet of Things Engineering, Wuxi University, Wuxi 214105, China

⁴ School of Automation, Nanjing University of Information Science & Technology, Nanjing 210044, China

⁵ School of Spatial Information and Surveying and Mapping Engineering, Anhui University of Science & Technology, Huainan 232001, China

Abstract To explore the illumination adaptability of environmental perception equipment in application of SLAM (Simultaneous Localization And Mapping), comparative experiments of lidar and depth camera for SLAM were carried out under different illumination intensities. Combined with the LOAM (Lidar Odometry And Mapping) and RTAB-MAP (Real-Time Appearance-Based Mapping) algorithms, a 16-line lidar and a depth camera were placed on a four-wheel differential robot to carry out SLAM application in bright and dark environments. The experimental results show that in bright environment, the median errors of system deviations are 0.203 m and 0.644 m for the visual SLAM and lidar SLAM, respectively, which are 0.282 m and 0.683 m respectively in dark environment. The depth camera outperforms the lidar in positioning and mapping performance in both bright and dark environment, and it can be concluded that the depth camera is more illumination adaptable.

Key words lidar SLAM; visual SLAM (VSLAM); real-time appearance-based mapping (RTAB-MAP); lidar odometry and mapping (LOAM)