

doi:10.19306/j.cnki.2095-8110.2022.06.015

基于点云聚类评估的激光雷达鲁棒定位方法

方 玮, 赖际舟, 吕 品, 郑国庆, 温焯贝

(南京航空航天大学自动化学院, 南京 211106)

摘 要: 基于先验地图的激光雷达定位方法在封闭工业场景下得到了广泛应用, 然而环境变化、行人和车辆等动态物体的干扰会影响激光雷达与先验地图的匹配精度。提出了一种动态环境下基于点云聚类评估的三维激光雷达鲁棒定位方法: 通过设定角度和距离双阈值, 对点云深度图像进行分割聚类, 相较于传统分割方法, 分割结果对点云噪声更为鲁棒; 通过对原始点云进行分割聚类, 在粗匹配结果下评估聚类的匹配度, 剔除误匹配聚类进行二次匹配以提高匹配精度; 通过聚类评估的结果判断匹配成功和失败的点对, 进而对点云整体匹配结果的正确性进行评估, 相较于传统仅基于距离阈值的判断准则, 具有更高的准确性; 最终, 分别通过公开数据集和实际试验验证了该算法的有效性。试验结果表明, 相较于传统匹配方法, 该方法有效提高了动态场景下的定位精度和匹配结果评估的准确度, 定位误差可以维持在 10cm 以内。

关键词: 动态环境; 激光雷达; 先验地图; 鲁棒匹配; 容错定位

中图分类号: TP242 **文献标志码:** A **文章编号:** 2095-8110(2022)06-0122-11

Robust 3D Lidar Localization Based on Point Cloud Clustering Evaluation

FANG Wei, LAI Ji-zhou, LYU Pin, ZHENG Guo-qing, WEN Ye-bei

(College of Automation Engineering, Nanjing University of Aeronautics and Astronautics, Nanjing 211106, China)

Abstract: Lidar localization based on priori map has been widely used in closed industrial scenes. However, environmental changes and interference from dynamic objects such as pedestrians and vehicles can affect the matching accuracy of Lidar and prior maps. A robust 3D lidar localization method based on point cloud clustering evaluation in dynamic environment is proposed. The range image of the point cloud is segmented and clustered by setting the dual thresholds of angle and distance, with the results more robust to noises compared with traditional segmentation method. After segmentation and clustering of the raw point cloud, the matching degree of the clusters is evaluated under the rough matching result. The mismatched clusters are eliminated to achieve a more accurate matching result in the second matching process. The result of clustering evaluation is used to judge whether the corresponding point pairs are correct, and then the correctness of matching result of the whole point cloud is evaluated. Compared with the traditional judgment criterion based only on distance threshold, the method proposed in this paper achieves higher accuracy. Finally, the effectiveness of the algorithm proposed in this paper is verified through the public dataset and practical experiment, respectively. The experiment results show that compared with the

收稿日期: 2022-01-04; **修订日期:** 2022-03-01

基金项目: 国家自然科学基金(61973160); 航空科学基金(2018ZC52037)

作者简介: 方玮(1997-), 男, 硕士研究生, 主要从事激光雷达导航与多源信息融合方面的研究。

通信作者: 赖际舟(1977-), 男, 教授, 主要从事多信息智能决策与导航方面的研究。

traditional method, the method proposed in this paper effectively improves the localization accuracy and the evaluation accuracy of the matching result in dynamic scenes. The localization error can be maintained within 10cm.

Key words: Dynamic environment; Lidar; Priori map; Robust matching; Fault-tolerant localization

0 引言

工业无人车是一种具有自主定位、感知、规划和运行能力的智能机器人。目前,在园区巡检、无人物流等方面有着越来越广泛的应用。导航定位作为无人车自主运行的前提,其精度直接影响了无人车运行的可靠性以及任务完成能力。

目前,无人车大多依赖卫星进行定位,因此只能运行于卫星信号良好的开阔环境。然而,随着需求的多样化,无人车需要在一些复杂环境中(例如工业园区内)进行作业。该环境内由于受到建筑物、树木等的遮挡,卫星信号的质量难以得到保障,从而影响了无人车的定位精度。对此,一般采取的做法是增加其他类型的传感器,例如惯性测量单元(Inertial Measurement Unit, IMU)、轮式编码里程计、激光雷达(Light Detection and Ranging, LiDAR)、视觉传感器等,最终通过融合算法获取最终的载体位置和姿态。

激光雷达由于不依赖环境光照、测距精度高的特点,相较于视觉传感器有着更高的稳定性和精度,因此逐渐成为无人车和无人机导航主要的传感器^[1-2]。通过激光雷达同步定位与构图(Simultaneous Localization and Mapping, SLAM)的方法对无人车进行定位,在未发生回环的情况下定位误差会随行驶里程而发散。近年来,基于先验地图的激光雷达定位方法成为无人车定位的主要方式之一,通过事先构建环境的全局无漂地图,无人车将激光雷达点云实时匹配至先验地图,从而可以消除激光雷达里程计的漂移,定位精度可以达到厘米级。

Zhang J. 等^[3-4]提出了基于激光雷达的 SLAM 框架 LOAM(Lidar Odometry and Mapping),首先基于曲率计算公式提取一帧点云中的角点和平面点,然后针对提取的特征点分别构建了点到直线以及点到平面的距离误差函数,最终采用 Levenberg-Marquardt 法最小化距离误差函数以获取载体的位姿。Shan T. 等^[5]在 LOAM 的基础上,针对地面车辆的应用场景进行了改进,提出了 LeGO-LOAM 框架,首先利用地

面点云估计车辆在横滚、俯仰和高度方向的运动变化,然后在此基础上利用其他非地面点云估计另外三个自由度的变化,最终得到车辆的六自由度运动信息,相较于 LOAM,它的精度相当但实时性更好。

不同于卫星的几何式定位,IMU、里程计、激光雷达或者视觉都是通过累积每两个时刻之间的载体位姿变化进行递推式的定位,因此不可避免地会存在累积误差。消除累积误差的方法是在定位过程中融合全局信息,通常采用位置信息已知的路标或者地图提供全局的位置信息。R. Mur-Artal 等^[6]提出了一种基于 ORB(Oriented FAST and BRIEF)特征^[7]的视觉里程计,但其对环境光照条件较为敏感。为了解决该问题,文献^[8]首先使用激光雷达构建了全局的先验地图,然后基于该地图,提出了一种混合光束平差法获取当前相机的位姿。文献^[9]同样使用激光雷达构建了场景地图作为先验信息,但其使用相机的测量匹配至激光雷达生成的地图以获取载体位姿。Koide 等^[10]使用基于图优化的 SLAM 方法融合激光雷达和全球定位系统(Global Positioning System, GPS)量测,前端使用正态分布变换(Normal Distributions Transform, NDT)^[11]方法进行激光雷达点云的扫描匹配,获取激光雷达里程计信息,在后端采用 GPS 信息作为位姿图的约束,最终通过因子图融合的方式获取载体位姿。Zhu Y. 等^[12]前端采用 LOAM^[3]进行点云匹配,后端基于 g2o 库^[13]融合激光雷达和 GPS 量测,首先构建了场景的点云地图,然后采用迭代最近点(Iterative Closest Point, ICP)^[14]方法将激光雷达点云匹配至该地图对无人车进行定位,定位精度达到 10cm。N. Steinke 等^[15]通过提取激光雷达点云中的线、面特征匹配至地理数据库,实现了厘米级的定位精度,但该方法需要首先获取目标区域内的地理数据库。相较于 LOAM 中简单的点特征,文献^[16]通过提取结构性强、区分度高的线、面、角等特征,在将点云匹配至先验地图时得到了更精确和鲁棒的定位结果。

然而,当前的激光雷达定位方案仅仅通过点层次的几何特征来筛选用于匹配的点云,一方面易受

激光雷达测量噪声的影响;另一方面,在动态物体较多的环境中,也无法区分动态点云和静态点云,从而影响最终的定位精度。本文从聚类的层次考虑,对点云聚类的整体误差进行评估,从而不易受到测量噪声的影响,同时可以将对应于动态物体的点云进行整体性地辨识和移除,从而提高了最终的定位精度。

此外,在车辆实际运行过程中,也会存在很多意外情况导致点云匹配结果出错,例如车辆线/角速度变化过快导致点云匹配初值偏差过大而无法收敛至正确解,传感器视野大面积受遮挡导致用于匹配的有效点过少而无法正确解算位姿变换,传感器数据异常导致的解算异常,环境变化过大导致实时点云和地图点云之间相差过大而无法正确匹配至地图。这些情况下点云匹配常常会收敛至错误解导致无人车的定位结果完全错误,如果无法及时发现并做出应对措施,可能会导致无人车运行至错误路线,甚至导致无人车发生碰撞等较为严重的事故。因此,如何评估点云匹配结果是否正确,对于无人车的稳定运行是必不可少的。

基于以上考虑,本文提出了一种动态环境下基于先验地图的三维激光雷达鲁棒定位方法,主要包含以下工作:

- 1)提出了一种基于角度和距离双阈值的点云深度图像分割方法,相较于传统仅基于角度或者距离阈值的分割方法,分割结果对点云噪声更为鲁棒;
- 2)提出了一种基于点云聚类评估的鲁棒点云匹配方法,首先对原始扫描点云进行聚类分割,然后对点云聚类的匹配度进行评估,通过剔除匹配度较差的聚类,保留匹配度较好的聚类进行匹配定位,提高了在动态场景中点云匹配定位结果的精度;
- 3)提出了一种基于聚类评估的两阶段点云匹配结果评估方法,第一个阶段首先评估每一个聚类

的匹配度,第二个阶段基于所有聚类的匹配度判断匹配结果成功或者失败,相较于传统的评估方法,提高了评估结果的准确度;

4)构建了面向动态场景的基于先验地图的三维激光雷达鲁棒点云匹配与容错定位系统,并在公开数据集和实际试验中验证了本文方法的有效性。

1 动态环境下基于点云聚类评估的三维激光雷达鲁棒定位方法

本文提出的动态环境下基于点云聚类评估的三维激光雷达鲁棒定位方法,相较于传统方法仅仅只是提取特征点并进行点云匹配的简单过程,增加了点云聚类分割以及基于分割后聚类匹配度评估的二次匹配过程,使得匹配结果更为准确。方法主要分为点云分割、点云匹配 I、聚类评估、点云匹配 II、匹配评估、全局位姿初始化六个模块(见图 1)。相较于传统方法(如 LOAM)只是从原始点云提取特征点后直接匹配至地图点云的方式,本文提出的方法首先将原始扫描点云分割为地面点和若干聚类,经降采样后通过点云匹配 I 模块将扫描点云匹配至地图,然后通过聚类评估模块对每个点云聚类的匹配度进行评估,通过点云匹配 II 对地面点和匹配度良好的聚类点云再次进行匹配,得到最终的位姿估计。通过这样的两阶段匹配方法,剔除原始点云中匹配不良的动态点或是噪点,从而可以获得更精确的匹配结果。最后,通过匹配评估模块对点云匹配的结果进行评估,判断匹配结果是否出错,若正确,则继续进行下一帧点云的匹配,若错误,则通过全局位姿初始化模块重新初始化传感器的位姿。相较于传统的激光雷达定位框架无法在定位结果错误后自行修正的现状,本文算法通过计算扫描点云和地图点云之间的匹配度,从而对匹配结果的正确性进行评估,并在匹配错误时通过全局重定位进行修正。




图 1 系统总览

Fig. 1 System overview

1.1 基于角度和距离双阈值的点云深度图像分割

点云分割模块从每一帧点云中提取出地面点云和分别属于每一个物体的点云,并剔除其他无法被聚为一类的单独的点。

定义 F_L 为激光雷达坐标系,其原点 O_L 位于激光雷达中心,其三轴 X_L, Y_L, Z_L 分别指向激光雷达的前、左、上。记 t 时刻获取的一帧原始激光雷达点云为 $P_t = \{p_i\}, i=1, 2, \dots, n$, 其中, n 为一帧点云的总点数, $p_i = (x_i, y_i, z_i)^T$ 为每一个点在 F_L 下的三维坐标。首先,类似于 LeGO-LOAM^[5],将原始的激光雷达点云 P_t 投影至深度图像 I_t 。

对于地面无人车来说,地面是一种稳定的特征,但由于激光雷达扫描点云的稀疏性,深度图像 I_t 同一列内的相邻像素点对应到实际地面上的两点相距很远。因此,直接基于欧式距离准则的方法难以稳定地对地面点进行分割,类似于文献[5]和文献[17],本文基于深度图像 I_t ,采用如下的阈值分割方法提取地面点:

对于 I_t 中的任意一点 $I_t(u_i, v_i)$,其对应的 F_L 系下的三维点坐标 $p_i = (x_i, y_i, z_i)^T$,并且设与其处于 I_t 中同一列的上一个点 $I_t(u_i, v_i - 1)$ 对应的三维点坐标 $p_{up} = (x_{up}, y_{up}, z_{up})^T$,与其处于 I_t 中同一列的下一个点 $I_t(u_i, v_i + 1)$ 对应的三维点坐标 $p_{down} = (x_{down}, y_{down}, z_{down})^T$,如果满足如下的判断条件,则将其标记为地面点

$$|z_i - h_g| < \delta_{gh} \quad (1)$$

$$\arctan\left(\frac{|z_i - z_{up}|}{\sqrt{(x_i - x_{up})^2 + (y_i - y_{up})^2}}\right) < \delta_{ga} \quad (2)$$

$$\arctan\left(\frac{|z_i - z_{down}|}{\sqrt{(x_i - x_{down})^2 + (y_i - y_{down})^2}}\right) < \delta_{ga} \quad (3)$$

其中,式(1)保证了只有在一定高度范围内的点才会被标记为地面点; h_g 代表激光雷达相对于地面的高度; δ_{gh}, δ_{ga} 代表了地面的平坦度;式(2)和式(3)保证了只有高度的梯度变化在一定范围内的点才会被标记为地面点,设提取的地面点集为 G_t 。

图2所示为一室外复杂场景中各方法的地面点提取效果对比,图2(a)为激光雷达原始扫描点云,其中蓝色框内为地面凸起的路旁人行道,黄色框内为较低矮的灌木丛,红色圈内为路上的行人和车辆;图2(b)为本文方法的地面点提取结果;图2(c)、图2(d)分别为文献[5]和基于随机抽样一致(Random Sample Consensus, RANSAC)平面拟合的地面点提取结果。可以看到,图2(c)中文献[5]采用方法提取的地面点

中包含了较多的灌木丛返回的点云,一部分行人、车辆返回的点云也被包含在了地面点中;图2(d)中基于RANSAC平面拟合方法提取的地面点虽然剔除了行人、车辆和灌木丛的点云,但其只提取出了地面较为平坦的部分,未提取到蓝色框内的地面凸起部分;而本文方法通过综合考虑地面的平坦度和激光雷达安装高度,在剔除行人、车辆和灌木丛的点云的同时,成功提取了凸起部分的地面点云,取得了更准确的地面点分割效果。

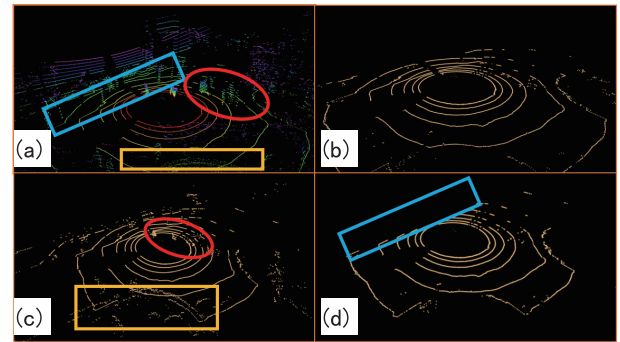


图2 各方法地面点提取效果对比
Fig. 2 Comparison of ground points extraction effects of the methods

地面点分割后,不同于文献[18]中仅基于角度阈值的分割方法,本文对区域增长的判断准则上同时设定了角度和距离阈值,做了如下改进:

设 I_t 中相邻两点 (u_i, v_i, r_i, p_i) 和 (u_j, v_j, r_j, p_j) , 激光雷达扫描中心 O_L , 根据激光雷达的扫描角分辨率,可获得射线 $\overrightarrow{O_L p_i}$ 和 $\overrightarrow{O_L p_j}$ 之间的夹角,设为 α , 设 $d_1 = \min(r_i, r_j), d_2 = \max(r_i, r_j)$, 若至少满足以下两个条件之一,则标记 (u_i, v_i) 和 (u_j, v_j) 属于同一聚类

$$\beta = \arctan\left(\frac{d_1 \sin \alpha}{d_2 - d_1 \cos \alpha}\right) > \delta_\beta \quad (4)$$

$$dis = \|p_i - p_j\| < \delta_d \quad (5)$$

其中,式(4)为文献[18]中的判断准则,该准则考虑了扫描点随距离的增大而变稀疏的非均匀特点,通过相邻扫描点间距和扫描距离的比值作为区域增长的判断条件,有效地缓解了由于点云稀疏性而引起的过分割现象。然而,在扫描距离较短时, β 值的大小会显著受到激光雷达测距误差的影响,常常会由于测距误差而导致过分割,因此本文加入了式(5)作为另一判断准则,如果两点之间的欧氏距离小于一定阈值,同样也被标记为同一聚类,即只需满足式(4)或式(5)之一, (u_i, v_i) 和 (u_j, v_j) 即被

标记为同一聚类。图3展现了改进前后分割结果的对比,其中不同的颜色代表不同的聚类,要注意的是这里展示的分割结果已经经过了上述地面点提取的过程,图3(a)和图3(b)分别为同一场景改进前后的分割结果,可以看到在对具有一定噪声的物体(如植被)进行分割后,图3(b)相对于图3(a)获得了更完整和连续的分割结果(图3(a)、图3(b)中蓝色方框内);图3(c)和图3(d)分别为另一场景改进前后的分割结果,右下角的卡车对应的点云在图3(c)中被分割为了若干个聚类,而在图3(d)中则被分割为了一个整体(图3(c)、图3(d)中蓝色方框内)。




图3 点云分割结果对比

Fig. 3 Comparison of point cloud segmentation results

图3(a)、图3(b)为同一帧原始扫描点云改进前后的分割结果,图3(c)、图3(d)为另一帧原始扫描点云改进前后的分割结果,注意这里展示的分割结果不包含地面点云。图3(a)、图3(b)中的蓝色方框内为一排相连植被返回的点云,尽管相较于墙面等的平坦表面具有更大的起伏,但仍属于一个物体,可以看到图3(a)中改进前算法将该部分点云分割为了许多细小的点云聚类,但图3(b)中改进后算法则成功地将其分割为了一个完整的点云聚类。图3(c)、图3(d)中的蓝色方框内为一辆卡车返回的点云,图3(c)中改进前算法将同属于一辆卡车的点云分割为了若干的点云聚类,而图3(d)中改进后算法则分割为了一个完整的点云聚类。

1.2 基于残差卡方检验的点云聚类匹配度评估方法

由于地图变化或环境中存在动态物体的情况,这些变化或动态的物体所返回的点云会对匹配结果产生不良影响,最终影响位姿估计的精度。因此,本文在初次点云匹配的结果下,对每一聚类的匹配良好度进行评估,剔除匹配不良的聚类,之后在点云匹配II模块中对剩余匹配良好的聚类点云

进行二次匹配,进一步优化位姿估计。

上文提到,原始点云 P_i 经过点云分割模块处理后,被分割为地面点集以及若干个聚类, $P_i = \{G_i, C_{i,t}\}, i = 1, 2, \dots, k$, 对于任一聚类 $C_{i,t}$ (不包含地面点集), 通过如下的卡方检验步骤评估其匹配良好度:

设 $C_{i,t} = \{c_j\}, j = 1, 2, \dots, m$, 其中, c_j 为 $C_{i,t}$ 中包含的点, m 为 $C_{i,t}$ 的总点数。对于 c_j , 寻找其到 M_i 中的最近平面的距离, 设为 d_j , 理想情况下, 若激光雷达不存在测量误差且匹配正确, 则 $d_j = 0$ 。因此, 可以将 d_j 建模为一个零均值的一维正态分布, 即 $d_j \sim N(0, \sigma_d^2)$, 其中, σ_d 代表传感器测量误差, 本文设置为 0.1m。对于 $C_{i,t}$, 构建如下的假设检验量

$$\chi_i^2 = \sum_{j=1}^m \left(\frac{d_j}{\sigma_d} \right)^2 \quad (6)$$

由于 $d_j \sim N(0, \sigma_d^2)$, 因此 $\frac{d_j}{\sigma_d} \sim N(0, 1)$ 为标准正态分布, 从而 $\chi_i^2 \sim \chi^2(m)$ 服从自由度为 m 的卡方分布。然后, 选取显著性水平 $\alpha (0 < \alpha < 1)$ 对 χ_i^2 进行单边检验, 则其拒绝域为

$$P(\chi_i^2 > \chi_\alpha^2(m)) \quad (7)$$

在本文中, 取 $\alpha = 0.05$ 。

对于处于拒绝域内的聚类, 认为其匹配度较差, 在后续的点云匹配II模块中将该聚类包含的点剔除, 排除其对位姿估计的负面影响。设经过上述检验并剔除匹配度较差的聚类后, 所保留的聚类为 $\hat{P}_i = \{\hat{C}_{i,t}\}, i = 1, 2, \dots, \hat{k}, \hat{k}$ 为保留的聚类数。

1.3 基于点云聚类评估的鲁棒点云匹配方法

相较于传统点云匹配方法直接从原始点云 P_i 中提取特征点进行匹配, 本文方法仅使用地面点以及满足聚类评估模块检验的聚类所包含的点, 通过剔除匹配度较差的聚类进行进一步的点云匹配, 以优化位姿估计结果, 具体步骤如下:

设分割后点云 $P_i = \{G_i, \{C_{i,t}\}\}, i = 1, 2, \dots, k$ 是地面点以及所有分割后的聚类所包含的点, G_i 为地面点云, $C_{i,t}$ 表示第 i 个聚类的点云, k 为聚类个数。

首先, 类似于 LOAM, 从 P_i 中提取特征点构建点到面的距离残差, 通过高斯牛顿迭代得到粗匹配位姿 T_{rough} 。将 P_i 通过粗匹配位姿 T_{rough} 进行变换得到 P_{i,T_r} 。

$$P_{i,T_r} = T_{\text{rough}} \cdot P_i \quad (8)$$

设 $P_{i,T_r} = \{G_{i,T_r}, \{C_{i,t,T_r}\}\}, i = 1, 2, \dots, k$, 对 P_{i,T_r} 中的每一聚类 C_{i,t,T_r} , 运用 1.2 节中的聚类评估步骤进行匹配度评估。设经过聚类评估并剔除

匹配度较差的聚类后,所保留的聚类为 $\hat{P}_l = \{G_l, \{\hat{C}_{i,l}\}\}, i = 1, 2, \dots, \hat{k}, \hat{k}$ 为保留的聚类数。

在提取出匹配度较好的聚类点云后,从 \hat{P}_l 中提取特征点构建点到面的距离残差,通过高斯牛顿迭代进行二次匹配,得到最终的匹配位姿 T_{fine} 。

1.4 基于聚类评估的两阶段点云匹配结果评估方法

相较于传统仅基于单个点对的距离设定阈值的匹配评估方法,本文提出了一种基于聚类评估的两阶段点云匹配结果评估方法。第一个阶段首先评估每一个聚类的匹配度,如果一个聚类匹配成功,就认为该聚类内的所有点匹配成功,反之则聚类内的所有点匹配失败;第二个阶段基于所有聚类的匹配度判断匹配结果成功或者失败,计算所有成功匹配的聚类包含的点数与总点数的比值,具体过程如下。

经过点云匹配 II 模块后,通过将满足检验评估的聚类点云匹配至地图得到传感器估计位姿 T_{fine} ,然后按照聚类评估模块的步骤,首先对地面点集进行同样的评估,如果评估失败,即地面点集匹配度较差,则直接判定点云匹配结果错误;如果地面点集匹配度良好,即在地面点集通过检验评估的前提下,再进行如下的评估步骤:

按照聚类评估模块的步骤,再次对所有聚类(不包含地面点集)进行匹配度的评估,设再次评估后,成功匹配的点云和聚类为 $\hat{P}_l = \{\hat{C}_{i,l}\}, i = 1, 2, \dots, \hat{k}, \hat{k}$ 为成功匹配的聚类数。为了消除扫描点随扫描距离分布不均的影响,对所有聚类点进行体素滤波,记 $|\hat{C}_{i,l}|$ 为 $\hat{C}_{i,l}$ 滤波后的点数,同时对原始点云分割所得聚类 $\{C_{i,l}\}, i = 1, 2, \dots, k$ 也进行体素滤波,记 $|C_{i,l}|$ 为 $C_{i,l}$ 滤波后的点数,按照式(9)计算成功匹配的聚类点数占比

$$\delta = \frac{\sum_{i=1}^{\hat{k}} |\hat{C}_{i,l}|}{\sum_{j=1}^k |C_{i,l}|} \quad (9)$$

如果 δ 低于设定阈值 δ_0 ,则判定点云匹配结果错误。本文设置 δ_0 为 0.5。

在判定点云匹配结果错误后,尝试重新初始化传感器的位姿,本文采用一种基于激光扫描描述子的方法^[19]对传感器的位姿进行全局初始化,通过在构建地图时存储下各位置处的扫描描述子构成描

述子库,再在地图的描述子库中搜寻与当前扫描描述子最相似的描述子对应的位置,即为全局初始化的结果,关于描述子的构建方法可以参考文献^[19],在此不做赘述。

2 验证与分析

为验证本文所提定位框架相对于传统匹配方法在定位精度上的提升,以及匹配评估方法相对于传统评估方法的优势,在公开数据集和实际试验中都进行了验证。算法运行的配置如下,选择 Intel CORE i9 8950 处理器和 8GB 的内存,算法基于 C++ 实现,运行环境为 Linux Ubuntu 下的机器人操作系统 ROS。

本文用于对比的方法为 LOAM 和 Lio-sam^[20],不同的是去除了 LOAM 和 Lio-sam 中的地图更新部分,改为和已知先验地图匹配;用于对比的传统点云匹配评估方法为基于点云匹配残差的评估方法,以及另一种基于点云匹配成功率的方法,它们的评估指标分别计算如下:

设 P, Q 为两帧待匹配点云,经点云匹配将 P 匹配至 Q 后,获得了 P 到 Q 的位姿估计 T ,设 P 中总点数为 n ,配对成功的 m 对点对为 $\{p_i, q_i\}, i = 1, 2, \dots, m$ 。其中 p_i 与 q_i 已形成对应关系,满足 $|T * p_i - q_i| < r_{\text{thre}}$,即对应点距离小于设定阈值 r_{thre} (本文中 $r_{\text{thre}} = 0.5\text{m}$)的点对认为是配对成功的点对,基于点云匹配残差的评估方法构建如下的评估指标

$$\epsilon = \frac{1}{m} \sum_{i=1}^m (T * p_i - q_i)^2 \quad (10)$$

若 ϵ 值小于设定的阈值 $\epsilon_{\text{thre}}, \epsilon < \epsilon_{\text{thre}}$,则认为匹配成功,否则匹配失败。基于点云匹配成功率的方法计算 P 中成功匹配的点数占 P 中总点数的比例

$$\eta = \frac{m}{n} \quad (11)$$

若匹配成功的点数的比例 η 大于设定的阈值 $\eta_{\text{thre}}, \eta > \eta_{\text{thre}}$,则认为匹配成功,否则匹配失败。

2.1 数据集验证与分析

本文采用文献^[21]中公开的动态环境数据集,该数据集包含了室内大厅、火车站、步行区等各种存在大量行人的环境,通过手持 Ouster OS1-64 激光雷达以 10Hz 的频率采集点云序列,选取了其中在步行区采集的数据验证本文算法。图 4 中展示了其中的一帧扫描点云的强度图像,用红色标注的点为场景中的行人返回的点云。



图4 数据集 Ouster 激光雷达扫描点云强度图像

Fig. 4 Intensity image by Ouster lidar scan in dataset

首先通过因子图^[20]融合点云数据与参考真值构建场景的先验地图(图5中白色点云),然后将激光雷达实时点云匹配至先验地图获取传感器位姿。图5中蓝色点云为激光雷达原始扫描点云,红色点云为通过本文算法提取的匹配度良好的点云,可以看到,本文算法提取的红色点云中已经不包含行人返回的点云(图5中黄色方框内的蓝色点云),成功剔除了场景中动态行人的点云,因此定位结果相较于 LOAM 和 Lio-sam 更为平稳和准确。


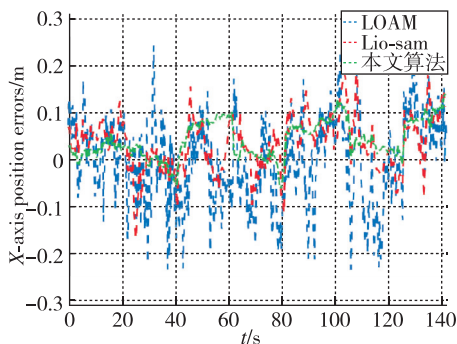



图5 数据集点云地图(白色)和实时点云(红色和蓝色)

Fig. 5 Point cloud map (white) and real-time point cloud (red and blue) in dataset

图6展示了 LOAM、Lio-sam 和本文所提方法的定位结果的误差对比,表1列出了均方根误差(Root Mean Square Error, RMSE)的对比结果,可以看到,相较于 LOAM,本文算法的定位误差减小了近50%,相较于 Lio-sam,本文算法的定位误差减小了27.5%。



(a) X 轴误差



(b) Y 轴误差

图6 定位误差对比

Fig. 6 Positioning error comparison

表1 定位均方根误差(RMSE)对比

Tab. 1 Positioning RMSE comparison

方法	X 轴误差 RMSE/m	Y 轴误差 RMSE/m	总误差 RMSE/m
LOAM	0.091	0.066	0.113
Lio-sam	0.068	0.043	0.080
本文算法	0.058	0.020	0.058

2.2 试验验证与分析

2.2.1 匹配定位试验

本文选择的试验场地为南航校园主干道,无人车搭载有 Velodyne VLP-16 激光雷达传感器和实时差分 GPS(RTK),RTK 用作定位基准,以及辅助构建全局无漂的先验地图(见图7)。通过因子图^[21]融合激光雷达和 RTK 构建先验地图(图8(b))。无人车的行进路线在图8(a)中用蓝线表示。

图9展示了本文算法对点云的筛选作用,图9(a)中的白色点为地图点云,彩色点为聚类后的点云(除地面点),每种颜色代表一个聚类;图9(b)中的蓝色点云为图9(a)中所有聚类构成的点云,红色点云为经



(a) 无人车定位验证平台




(b) 试验验证场景

图 7 试验硬件平台和场景

Fig. 7 Experiment hardware platforms and scenarios




(a) 试验场景鸟瞰图




(b) 试验场景先验地图

图 8 试验场景先验地图构建

Fig. 8 Priori map of experiment scenarios



(a) 点云分割结果




(b) 聚类评估结果

图 9 本文算法点云分割和处理效果

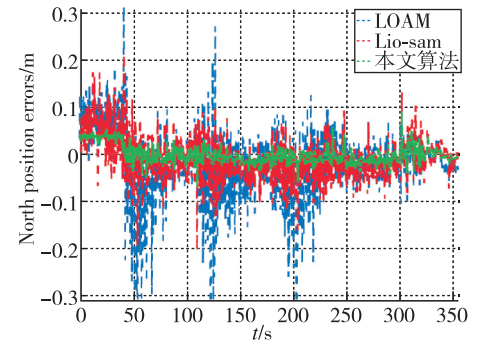
Fig. 9 Point cloud segmentation and processing effect of ours method

过聚类评估模块提取的点云,可以看到本文算法成功地剔除了扫描点云中中和地图不匹配的部分。

图 10 展示了 LOAM、Lio-sam 和本文所提改进匹配方法的定位结果的误差对比,表 2 列出了均方根误差(RMSE)的对比结果,可以看到,在剔除了匹配度较差的聚类点云后,相较于 LOAM,本文算法的定位误差减小了近 70%,相较于 Lio-sam,本文算法的定位误差减小了 48%。



(a) 东向误差



(b) 北向误差

图 10 试验场景下定位误差对比

Fig. 10 Comparison of positioning errors in experiment scenarios

表 2 试验场景下定位均方根误差 (RMSE) 对比

Tab. 2 Comparison of positioning RMSE in experiment scenarios

方法	东向误差 RMSE/m	北向误差 RMSE/m	总误差 RMSE/m
LOAM	0.026	0.076	0.080
Lio-sam	0.022	0.045	0.050
本文方法	0.017	0.020	0.026

2. 2. 2 算法运行时间分析

图 11 所示为本文算法各主要模块运行时间,表

3 列出了各模块运行的平均时间,可以看到,加入的点云分割模块平均耗时为 6.59ms,聚类评估模块平均耗时为 4.54ms,点云匹配 I 和 II 的总时间为 62.58ms,算法总体平均运行时间为 73.71ms,激光雷达扫描频率为 10Hz,因此本文算法可以实时处理每帧点云数据。




图 11 各模块运行时间

Fig. 11 Running time of each module

表 3 各模块运行平均时间

Tab. 3 Average running time of each module

算法模块	点云分割	点云匹配 I	聚类评估	点云匹配 II
平均运行时间/ms	6.59	31.11	4.54	31.47

2.2.3 匹配评估试验

本文选取了 8 个典型场景对比本文匹配评估方法和上述两种传统方法,如图 12 所示,1~4 号为匹配成功的情况,5~8 号为匹配失败的情况,表 4 列出了对应的评估指标的计算值。在诸如 1 号的一般情形下,三种方法均能正确进行评估;然而在 2、3、4 中,当传感器附近经过大型车辆,视野被大量遮挡或环境点云较为嘈杂时,基于残差或匹配率的方法出现了较大波动,而本文算法则受影响较小。5~8 中模拟了点云匹配失败的情形,在 5 中当点云和环境差别较大时,三种方法均能正确评估出匹配失败;然而在 6、7、8 中,通过将点云从正确位置平移数米模拟匹配失败的情形中(实际运行过程中通过卫星定位或是其他全局定位算法可能会出现的情况),误匹配的点云和环境相似度较高,此时 6、7 中点云匹配的残差甚至低于在 3、4 中的残差值,7、8 中的点云匹配率高于 2、4 中的匹配率,从而无法正确评估出匹配结果是否成功,而本文算法在匹配失败时的匹配率明显小于匹配成功时的匹配率,即使是点云和环境的相似度较高时,也能正确做出评估。图 12 中 5(b)~8(b)的黄色点云为传统仅基于距离阈值筛选所提取的成功匹配的点云,红色点云为本文算法经过聚类评估后提取的成功匹配的点云。可以看到,如果仅仅基于距离阈值进行筛选,哪怕是在匹配错误的情况下,依旧有很多点会被认为是正确配对的点云,从而可能出现最终将匹配错误的情况误判断为正确;但在经过聚类评估后,尽管单独的某些点在匹配错误时可能仍能找到距离较近的点作为对应点,但聚类中所有点的总体误差在匹配错误时通常会显著变大,从而能够剔除多数误匹配的点云,最终可以更为准确地对匹配结果进行评估。




图 12 点云匹配成功(1~4)和失败(5~8)情况

Fig. 12 Matching success (1~4) and failure (5~8) situations

表 4 图 12 中各情况对应评估指标的计算值

Tab. 4 Indicators of the evaluating methods corresponding to situations in Fig12

方法	序号	1	2	3	4	5	6	7	8
	匹配成功				匹配失败				
残差评估/m ²		0.0454	0.0614	0.0716	0.0885	0.114	0.0868	0.0715	0.117
匹配率评估/%		76.9	38.3	73.5	41.7	22.6	28.7	50.6	50.4
本文方法/%		76.9	63.1	74.2	62.4	8.6	26.7	25.6	35.4

3 结论

本文针对动态环境下的激光雷达定位问题,提出了一种基于点云聚类评估的三维激光雷达鲁棒定位方法。主要工作为以下几点:

1) 基于双阈值的区域增长法对点云进行分割聚类,提高了聚类结果对噪声的鲁棒性;

2) 通过卡方检验剔除误匹配的动态点云聚类,以提高匹配精度;

3) 通过聚类的匹配成功比例,评估匹配结果的正确性。

经过公开数据集与实际试验验证,结果表明,相较于传统匹配方法,本文方法有效提高了在行人、车辆等移动物体较多的动态场景下的定位精度和匹配结果评估的准确度。在后续工作中,将会针对激光雷达全局重定位方法开展研究,以提高无人车全局位姿初始化的速度和准确率。

参考文献

- [1] 石鹏, 赖际舟, 吕品, 等. 复杂环境下微小飞行器惯性/激光雷达 Robust-SLAM 方法[J]. 导航定位与授时, 2019, 6(1): 14-21.
Shi Peng, Lai Jizhou, Lyu Pin, et al. A robust-SLAM method for MAVs using LIDAR and IMU in complex environment[J]. Navigation Positioning and Timing, 2019, 6(1): 14-21(in Chinese).
- [2] 何洪磊, 赖际舟, 吕品, 等. 面向结构化场景的激光雷达点云高精度配准与定位方法[J]. 导航定位与授时, 2021, 8(1): 133-142.
He Honglei, Lai Jizhou, Lyu Pin, et al. High precision registration and positioning method of LIDAR point cloud for structured scene[J]. Navigation Positioning and Timing, 2021, 8(1): 133-142(in Chinese).
- [3] Zhang J, Singh S. LOAM: lidar odometry and mapping in real-time[C]// Robotics: Science and Systems Conference, 2014.
- [4] Zhang J, Singh S. Low-drift and real-time lidar

odometry and mapping [J]. Autonomous Robots, 2017, 41(2): 401-416.

- [5] Shan T, Englot B. LeGO-LOAM: lightweight and ground-optimized lidar odometry and mapping on variable terrain[C]// Proceedings of 2018 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS). IEEE, 2018: 4758-4765.
- [6] Mur-Artal R, Montiel J M M, Tardos J D. ORB-SLAM: a versatile and accurate monocular SLAM system[J]. IEEE Transactions on Robotics, 2015, 31(5): 1147-1163.
- [7] Rublee E, Rabaud V, Konolige K, et al. ORB: an efficient alternative to SIFT or SURF[C]// Proceedings of 2011 International Conference on Computer Vision. IEEE, 2011: 2564-2571.
- [8] Ding X, Wang Y, Li D, et al. Laser map aided visual inertial localization in changing environment [C]// Proceedings of 2018 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS). IEEE, 2018: 4794-4801.
- [9] Wolcott R W, Eustice R M. Visual localization within lidar maps for automated urban driving[C]// Proceedings of 2014 IEEE/RSJ International Conference on Intelligent Robots and Systems. IEEE, 2014: 176-183.
- [10] Koide K, Miura J, Menegatti E. Aportable 3D LIDAR-based system for long-term and wide-area people behavior measurement[J]. International Journal of Advanced Robotic Systems, 2019, 16(2): 1-13.
- [11] Biber P, Straßer W. The normal distributions transform: a new approach to laser scan matching[C]// Proceedings of 2003 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS 2003) (Cat. No. 03CH37453). IEEE, 2003: 2743-2748.
- [12] Zhu Y, Xue B, Zheng L, et al. Real-time, environmentally-robust 3D LiDAR localization[C]// Proceedings of 2019 IEEE International Conference on Imaging Systems and Techniques (IST). IEEE, 2019: 1-6.
- [13] Grisetti G, Kümmerle R, Strasdat H, et al. g2o: a general framework for (hyper) graph optimization[C]//

- Proceedings of IEEE International Conference on Robotics and Automation (ICRA). Shanghai, China: IEEE, 2011: 9-13.
- [14] Chetverikov D, Svirko D, Stepanov D, et al. The trimmed iterative closest point algorithm[C]// Proceedings of 2002 International Conference on Pattern Recognition. IEEE, 2002: 545-548.
- [15] Steinke N, Ritter C N, Goehring D, et al. Robust LiDAR feature localization for autonomous vehicles using geometric fingerprinting on open datasets[J]. IEEE Robotics and Automation Letters, 2021, 6(2): 2761-2767.
- [16] Li K, Ouyang Z, Hu L, et al. Robust SRIF-based LiDAR-IMU localization for autonomous vehicles [C]// Proceedings of IEEE International Conference on Robotics and Automation (ICRA). IEEE, 2021.
- [17] Himmelsbach M, Hundelshausen F V, Wuensche H J. Fast segmentation of 3D point clouds for ground vehicles[C]// Proceedings of 2010 IEEE Intelligent Vehicles Symposium. IEEE, 2010: 560-565.
- [18] Bogoslavskyi I, Stachniss C. Fast range image-based segmentation of sparse 3D laser scans for online operation[C]// Proceedings of 2016 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS). IEEE, 2016: 163-169.
- [19] Kim G, Kim A. Scan context: egocentric spatial descriptor for place recognition within 3D point cloud map [C]// Proceedings of 2018 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS). IEEE, 2018: 4802-4809.
- [20] Shan T, Englot B, Meyers D, et al. Lio-sam: tightly-coupled lidar inertial odometry via smoothing and mapping [C]// Proceedings of 2020 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS). IEEE, 2020: 5135-5142.
- [21] Pfreundschuh P, Hendrikx H F C, Reijgwart V, et al. Dynamic object aware LiDAR SLAM based on automatic generation of training data[J]. arXiv preprint arXiv:2104.03657, 2021.

(编辑:孟彬)