

DOI: 10.19650/j.cnki.cjsi.J2413624

基于语义辅助的强度扫描上下文回环检测方法

刘名星, 徐晓苏

(东南大学仪器科学与工程学院 南京 210096)

摘要:在同步定位与建图(SLAM)中,回环检测是提高定位精度的重要环节。通过识别回环并校正累计误差,能够有效增强定位的精度和稳定性。然而,目前大多数基于 LiDAR 的回环检测方法主要依赖坐标和反射强度等低层次特征来构建描述子,未能充分利用场景中的语义信息,从而在复杂场景中面临精度和可靠性不足的问题。针对这一不足,提出了一种基于语义辅助的强度扫描上下文方法,以弥补现有方法的局限性。首先,该方法利用 ICP 算法对两帧点云进行粗配准,减少角度和位移对回环检测的影响。在此基础上,将语义信息与点云的几何信息及强度信息相结合,构建多层次特征的全局描述子。最后,通过描述子相似度计算判断回环是否存在,从而实现更可靠的回环检测。在公开数据集 KITTI 上的实验结果表明,该研究方法的最大 F_1 分数较 scan context 算法提升了 19.71%,平均均方根误差较 lego-loam 算法降低了 36%。此外,在校园环境的实测结果显示,该研究方法的最大 F_1 分数较 lio-sam 算法提升了 19.23%,较 lego-loam 算法提升了 70.62%;平均均方根误差较 lio-sam 算法降低了 56.68%,较 lego-loam 算法降低了 20.7%。这些结果表明,该方法不仅能够有效提升回环检测的准确性,还能在多样化场景下展现出更强的鲁棒性。通过引入语义信息,该方法显著改善了描述子在复杂场景中的区分能力,为 SLAM 技术的发展提供了新的思路和方法支持。

关键词: 同步定位与建图;回环检测;语义分割;描述子

中图分类号: TH701 文献标识码: A 国家标准学科分类代码: 520.60

A semantic-assisted intensity scan context loop closure detection method

Liu Mingxing, Xu Xiaosu

(School of Instrument Science and Engineering, Southeast University, Nanjing 210096, China)

Abstract: In simultaneous localization and mapping (SLAM), the loop closure detection is a critical step to improve localization accuracy. By identifying loop closures and correcting accumulated errors, the accuracy and robustness of localization can be significantly enhanced. However, most existing LiDAR-based loop closure detection methods primarily rely on low-level features such as coordinates and reflectivity to construct descriptors, failing to fully utilize semantic information within the scene. As a result, these methods often face challenges in terms of accuracy and reliability in complex scenarios. To address these limitations, this article proposes a semantic-assisted intensity scan context method to overcome the insufficiencies of existing approaches. First, the proposed method employs the iterative closest point (ICP) algorithm for coarse registration of two-point clouds, reducing the impact of angular and translational errors on loop closure detection. On this basis, semantic features are integrated with the three-dimensional coordinates and reflectivity information of the point clouds to generate a global descriptor that incorporates multi-level features. Finally, loop closures are determined by calculating the similarity of the descriptors, enabling more reliable detection. Experimental results on the publicly available KITTI dataset show that the proposed method achieves a maximum F_1 score improvement of 19.71% compared with the Scan Context algorithm, while reducing the average root mean square error (RMSE) by 36% compared with the lego-loam algorithm. Additionally, real-world experiments in a campus environment show that the proposed method improves the maximum F_1 score by 19.23% compared with the LIO-SAM algorithm and by 70.62% compared with the lego-loam algorithm. Furthermore, the average RMSE is reduced by 56.68% compared with LIO-SAM and by 20.7% compared with lego-loam. These results show that the suggested method not only greatly improves the accuracy of loop closure detection but also exhibits greater robustness in diverse scenarios. By incorporating semantic

information, this method markedly improves the discriminative capability of descriptors in complex environments, providing new perspectives and methodological support for the development of SLAM technologies.

Keywords: simultaneous localization and mapping; loop closure detection; semantic segment; descriptor

0 引言

随着科技的不断进步,同步定位与建图(simultaneous localization and mapping, SLAM)技术已经逐渐成为机器人导航和自动驾驶系统中的核心组成部分^[1-3]。SLAM的核心原理是通过传感器数据,让移动机器人在未知环境中实时构建地图的同时进行位置识别。借助这一机制,SLAM能够具备闭环检测和重定位等能力。回环检测作为SLAM中的重要环节,允许机器人判断是否曾到达过某个地点。此功能有助于减少里程计的误差,优化全局地图并提高定位精度^[4]。大多数基于图像的回环检测方法通过提取特征描述子,例如基于词袋(bag-of-words)^[5]、局部聚合描述子向量(vector of locally aggregated descriptors, VLAD)^[6]和语义Fisher向量^[7]等算法对视觉特征进行编码。随后,通过分析全局描述符之间的相似性,来识别是否存在回环现象。然而,这些方法在剧烈光照变化、季节更替等外部条件干扰下可靠性较低。此外,由于视觉的回环检测方法视场角较窄,导致在回环判断过程中容易出现识别错误。

与视觉传感器不同,LiDAR通过生成高分辨率的三维点云并提供精确测量,能够更好地感知周围环境。其优势在于即使在光照条件不佳的情况下,依然能够正常运行,同时提供丰富的几何信息,对季节变化和光照差异表现出更高的鲁棒性。2018年Kim等^[8]提出了扫描上下文(scan context, SC)方法,该方法将三维点云转换到二维平面表示,仅保留最大高度信息,并通过逐行计算列偏移来确保旋转的不敏感性。然而,该方法不能充分挖掘点云的几何结构特征,且需要耗费大量时间来处理旋转不变性问题。2018年Shan等^[9]提出了一种高效、轻量级的实时定位与建图算法(lightweight and ground-optimized LiDAR odometry and mapping, lego-loam)。2020年基于lego-loam框架,Shan等^[10]又发展出激光惯性紧耦合SLAM算法(LiDAR inertial odometry via smoothing and mapping, lio-sam)。这两种算法均基于几何距离的大小来判断是否出现回环,但在经过长距离后再次回到曾经到达过的位置时,由于累计误差的积累,基于几何距离的检测可能失败,导致漏检现象。2020年Wang等^[4]提出了激光雷达虹膜(LiDAR iris, LI),通过从每帧点云中提取二进制签名图像,计算两个签名图像的Hamming距离来比较点云之间的一致性。随后,Wang等^[11]在SC的基础上融合反射强度信息设计出强

度扫描上下文(intensity scan context, ISC)描述子,使其能够更准确地区分点云中的细微特征。2023年马哲伟等^[12]在SC的基础上结合LiDAR与惯性测量单元(inertial measurement unit, IMU),使得系统能够更快速地识别回环并进行准确的定位。此外,2024年徐晓苏等^[13]提出了一种基于三角词袋的回环检测方法,该方法利用点云的LinK3D特征生成三角描述子,并通过构建三角词袋和基于LinK3D特征的帧间匹配,实现了精确的帧间位姿估计。基于上述技术,研究人员进一步提出了一系列方法用于回环检测^[14-16]。然而,以上基于描述子的方法主要依赖于点云的几何结构、强度等局部特征信息。当点云存在角度偏差或遮挡时,这些方法的性能往往不尽如人意,在实际应用中精度和鲁棒性不足。

为探索更具表达能力的特征描述方法,近年来研究者们提出了多种基于神经网络的方案。2018年Uy等^[17]结合PointNet^[18]和PointNetVLAD^[19],提出一种端到端的方法,用于从3D点云提取全局描述子。2019年Lu等^[20]通过从给定点云中选取关键点,并利用PointNet学习每个关键点的局部描述子。2018年Schaupp等^[21]提出了OREOS,该方法通过将3D点云投影到2D距离图像,利用卷积神经网络提取全局描述子。2020年Yin等^[22]提出SeqSphereVLAD,通过将点云投影到球面视图并提取特征,对这些特征进行排序后生成描述子。2020年Chang等^[23]提出SpoxelNet,利用球面坐标系对点云数据进行体素化,并结合多方向特征融合,显著提高了在复杂场景中的识别性能。2021年Komorowski等^[24]提出了Minkloc3D,采用稀疏体素化点云表示,并通过稀疏3D卷积提取辨识能力强的点云特征描述子。2024年姚万业等^[25]将注意力机制引入局部描述子的构建中,增强了环境特征提取能力。上述方法在结合高级特征与几何特征方面取得了显著进展,但大多数方法依赖于神经网络来提取抽象特征,这不仅使得特征编码更加复杂,还因缺乏清晰的解释而难以被理解。

目前,回环检测的主要挑战之一是基于全局描述子的方法通常依赖点云的部分信息,难以确保检测准确性。为此,研究者通过结合语义信息,主要包括两类方法:一是基于语义图,Kong等^[26]提出基于语义图的场景识别(semantic graph based place recognition, SGPR),通过语义图相似度判断回环,虽能利用全局语义结构,但在动态场景中构建语义图复杂度较高;二是基于全局描述子,Zhu等^[27]提出的语义关系全局描述子方法,结合逐步精细化的策略提高检测效率并提供平移和旋转的估计,但

因小物体特征丢失影响准确性。针对上述不足,故提出语义辅助的强度扫描上下文回环检测方法,引入强度信息不仅增强了点云的细节表现,还有效区分了物体表面的反射特性;融合语义信息有助于捕捉场景中的语义关系,使回环检测能够识别更多相似区域。点云几何结构则提供了精确的空间布局,进一步提升了描述子的空间分辨率。通过综合利用多模态信息,生成的描述子在环境变化、物体差异和复杂场景下依然保持较强的鲁棒性和高准确性,从而显著提高了回环检测的效果。

1 算法整体框架

该研究算法的整体框架如图1所示,整个算法的输入为LiDAR扫描得到的三维点云数据。首先,当前时

刻点云 P_1 和候选帧 P_2 被输入到轻量级语义分割模块^[28]中,生成带有逐点类别标签的语义点云 P_{1l} 和 P_{2l} 。动态分割模块剔除语义标签为行人和车辆的点云,并将处理后的点云数据及其语义标签重新发布。其次,点云对齐模块接收去除动态物体后的点云数据及其语义标签,使用语义辅助的ICP方法获得当前帧点云 P_{1l} 和候选帧点云 P_{2l} 的偏航角 θ 以及 x - y 平面的相对位移量 (Δ_x, Δ_y) ,使用 $(\theta, \Delta_x, \Delta_y)$ 对齐候选帧点云 P_{2l} 得到 P'_{2l} 。最后,语义辅助的强度扫描上下文模块将点云 P_{1l} 和 P'_{2l} 的三维坐标、强度、语义标签映射为全局描述子,并计算两帧点云的相似度得分。最终,将相似度得分超过设定阈值的回环对进行几何验证,并将验证通过的回环因子加入因子图优化,从而获得全局一致的激光雷达位姿估计。




图1 算法整体框架

Fig. 1 The overall framework of the algorithm

1.1 语义辅助的ICP算法

对于给定的点云 P ,语义分割的任务是部署一个轻量级前向传播网络 $\mathcal{Y}$ 来预测每一个点的语义标签 l_i ,该问题定义如式(1)所示:

$$l_i = \mathcal{Y}(P, \ell) \quad (1)$$

其中, ℓ 表示前向传播网络学习的网络权重。

在对点云进行语义分割并初步剔除环境中潜在的动态物体后,将每一帧点云表示为 $P = \{p_1, p_2, \dots, p_n\}$,其中每一个点表示为 $p_i = [x_i, y_i, z_i, \xi_i, l_i]$,其中, ξ_i 表示这个点的强度, l_i 表示这个点的语义标签。对于给定的当前帧点云 P_{1l} 和候选帧点云 P_{2l} ,首先计算两帧点云的偏航角 θ ,再计算水平面的相对偏移量 (Δ_x, Δ_y) ,这样得到了两帧点云之间的3D位姿 $[\theta, \Delta_x, \Delta_y]$ 。随后,将候选帧点云 P_{2l} 对齐到当前帧点云 P_{1l} ,将经过对齐处理后的候选

帧点云命名为 P'_{2l} 。

具体来说,为了有效地分析和处理点云数据,提出了一种基于二维扇形投影的方法,将当前帧点云 P_{1l} 和候选帧点云 P_{2l} 投影到二维矩阵 R_1 和 R_2 中,以简化后续处理,计算公式如式(2)~(5)所示。

$$r_i = \sqrt{x_i^2 + y_i^2} \quad (2)$$

$$\varphi_i = \pi + \arctan\left(\frac{y_i}{x_i}\right) \quad (3)$$

$$s_i = \left\lfloor \frac{\varphi_i}{\text{sector_num}} \right\rfloor \quad (4)$$

$$\mathbf{R}[s_i] = [r_i, x_i, y_i, l_i] \quad (5)$$

其中, r_i 和 φ_i 分别表示 p_i 的极径和极角, s_i 表示扇区序列号, sector_num 表示扇区数量, $\mathbf{R}$ 表示二维矩阵,存储了点云的极径 r_i 、坐标 (x_i, y_i) 及语义值 l_i 。偏航角的估

计与二维矩阵 $\mathbf{R}$ 的列向量偏移关系紧密相关,如式(6)所示。

$$\begin{cases} \delta = \operatorname{argmin} \Gamma(\mathbf{R}_1, \mathbf{R}_2^i) \\ \theta = 360^\circ - \frac{360^\circ \times \delta}{\text{sector_num}} \end{cases} \quad (6)$$

其中, $\mathbf{R}_2^i$ 是 $\mathbf{R}_2$ 经过偏移 i 个元素后得到的结果, Γ 表示向量 $\mathbf{R}_1$ 与向量 $\mathbf{R}_2^i$ 的曼哈顿距离,其定义如式(7)所示。

$$\Gamma(\mathbf{R}_1, \mathbf{R}_2^i) = \|\mathbf{R}_1 - \mathbf{R}_2^i\|_1 \quad (7)$$

根据计算得到的偏航角 θ 将点云 P_{l_2} 旋转到与 P_{l_1} 相同的方向,得到 $P_{l_2}^a$ 。其转换过程如式(8)所示。

$$\begin{cases} x_i^a = x_i \cos(\theta) - y_i \sin(\theta) \\ y_i^a = x_i \sin(\theta) + y_i \cos(\theta) \end{cases} \quad (8)$$

其中, (x_i, y_i) 和 (x_i^a, y_i^a) 分别表示 P_{l_2} 和 $P_{l_2}^a$ 的第 i 个点的二维坐标,其中偏移量 (Δ_x, Δ_y) 的计算公式如式(9)所示。

$$(\Delta_x, \Delta_y) = \operatorname{argmin} L = \operatorname{argmin} \sum_{i=1}^{N_a} \Psi(l_i^a, \xi_i^a, l_i^r, \xi_i^r) \times \frac{(x_i^a + \Delta_x - x_i^r)^2 + (y_i^a + \Delta_y - y_i^r)^2}{2} \quad (9)$$

其中, (x_i^r, y_i^r) 来自点云 P_{l_1} , 是 (x_i^a, y_i^a) 对应的最近点,当语义值 l_i^a 与 l_i^r 相等且强度值 ξ_i^a 与 ξ_i^r 的差值 < 30 , 则 $\Psi(l_i^a, \xi_i^a, l_i^r, \xi_i^r)$ 为 1, 否则为 0。

最后,候选帧点云通过位姿 $(\theta, \Delta_x, \Delta_y)$ 与当前帧点云对齐,为后续生成描述子做好准备。

1.2 语义辅助的强度扫描上下文回环检测

为了进一步提升描述子的表达能力,该研究方法融合了点云的语义标签、三维坐标以及强度信息,将其共同编码为全局描述子。这种设计充分利用了点云的几何结构特征与语义信息的互补性,同时引入强度信息(intensity),为描述子提供了更多细节特征,从而显著增强了描述子的区分能力。

具体而言,语义标签能够有效反映场景中的语义信息,例如建筑物、树木等静态特征的类别;三维坐标描述了点云在空间中的几何分布,提供了场景的结构化特征;而强度信息则反映了激光雷达信号的反射强度,可以在特定条件下辅助分辨不同材质的物体。通过将这 3 种信息结合编码,描述子不仅可以捕获点云的局部几何和全局语义特性,还能够应对复杂环境中的动态变化。

本研究算法受语义扫描上下文(semantic scan context, SSC)^[29]和 ISC^[11]启发,在点云数据的语义信息基础上引入了强度信息,优化场景描述子的区分能力。如图 2、3 所示,对于同一场景,激光雷达对柱状建筑物和冬青的扫描中,强度值存在显著差异。这一特性表明,强

度信息能够在已有的语义信息之上进一步增强描述子之间的差异,使其在表征能力上优于仅依赖扫描上下文或语义辅助扫描上下文的描述子。在移动机器人再次到达相同场景时,结合强度信息构建的描述子能够获得更高的相似度得分,显著提升回环检测的准确性。而对于具有相似特征但并非回环的场景,强度信息的引入则能进一步拉大描述子之间的差异,避免误匹配。这种改进不仅提升了场景识别的精确性,同时对复杂环境下的鲁棒性也有重要作用,为移动机器人完成高精度的定位提供了技术支撑。




图2 不同环境部分的激光雷达强度值对比

Fig. 2 Comparison of LiDAR intensity values across different parts of the environment



图3 不同环境部分对应的图像

Fig. 3 Images corresponding to different parts of the environment

此外,强度信息的引入具有较强的通用性,能够与语义信息形成互补,在点云描述子的构建中为特征提取提供了新的视角。因此,该研究方法在处理包含复杂几何特征的场景时,表现出更高的适应性和稳定性,即使在包含动态物体的复杂环境中,移动机器人仍能保持稳定运行,展现出较高的可靠性。

综合利用点云三维坐标、语义标签以及强度值构建特征描述子,其原理如图 4 所示。通过将点云的空间信息与其语义和强度特征相结合,该方法能够更全面地表征点云的关键特性,从而提高描述子的表达能力和区分能力。这样的特征描述子不仅适用于复杂环境下的点云匹配和场景重建,还能显著提升回环检测和目标识别等任务的鲁棒性。




图 4 语义辅助的强度扫描上下文描述子

Fig. 4 Semantic intensity scan context descriptor

3D 点云信息、强度信息、语义标签按照极坐标系被划分为 $sector_num$ 个扇形区域, N_r 个环, 通过计算点到原点的距离和角度, 将点映射到以原点为中心的多个距离环和角度扇区中, 其公式如式 (10) 所示。

$$S(r_i, s_j) = \begin{cases} l_i, & \omega(l_i) > \omega(S(r_i, s_j)) \\ S(r_i, s_j), & \text{其他} \end{cases} \quad (10)$$

其中, $1 \leq s_j \leq sector_num, 1 \leq r_i \leq N_r, \omega(l_i)$ 表示语义标签 l_i 的优先级权重, 这样得到的全局描述子 S 是一个 N_r 行, $sector_num$ 列的二维矩阵, 其包含了点云 3D 坐标、语义标签和强度。最后, 通过计算二维矩阵之间的匹配度来决定两帧点云之间能否满足回环条件, 具体的匹配度计算公式如式 (11) 所示。

$$Score = \frac{\sum_{i=1}^{N_a} \sum_{j=1}^{N_r} \delta(S_A(i, j), S_B(i, j)) \times \Theta(|\xi_A(i, j) - \xi_B(i, j)| \leq 50)}{\sum_{i=1}^{N_a} \sum_{j=1}^{N_r} (S_A(i, j) \neq 0, S_B(i, j) \neq 0)} \quad (11)$$

其中, $S_A(i, j)$ 和 $S_B(i, j)$ 分别表示两帧点云描述子在第 i 行第 j 列的数值。

当 $S_A(i, j) = S_B(i, j)$ 时, $\delta(S_A(i, j), S_B(i, j))$ 的值为 1, 否则为 0。同时, $\Theta(|\xi_A(i, j) - \xi_B(i, j)| \leq 50)$ 表示这两个描述子对应点的强度值差异为 50 (该参数可调), 进一步筛选描述子对应点的强度值差异。若匹配度得分超过阈值, 即认为两帧点云之间存在闭环关联, 并将其加入因子图进行优化。

该研究方法通过将点云的三维坐标、语义标签和强度值投影到二维表示, 显著降低了数据复杂度, 同时有效保留了点云的空间分布特征。所提出的描述子兼具高分度和计算效率, 为点云回环检测提供了强有力的支持。

2 实验结果与分析

该研究在 KITTI 数据集和东南大学无锡国际校区实地采集数据对所提出的算法进行了实验验证。其中, KITTI 数据集实验运行平台为搭载 Intel Xeon E5-2696 v4 处理器的服务器, 配备 64 GB 运行内存, 操作系统为 ubuntu 20.04 LTS, 使用的机器人操作系统版本为 ROS noetic。

KITTI 数据集利用 64 线 LiDAR (velodyne HDL-64E) 采集点云数据, 涵盖了 22 个不同的序列。选择其中具有回环的 00、05、06、07 和 08 序列进行评估, 其中 08 序列包含反向回环场景。定位精度使用绝对轨迹误差平移部分的均方根误差 (root mean square error, RMSE) 来进行量化评估, 相关公式如式 (12) 所示。

$$E = \sqrt{\frac{1}{N} \sum_{i=1}^N \|trans(Q_i^{-1} S P_i)\|^2} \quad (12)$$

其中, S 为推测姿态 P_i 到参考姿态 Q_i 的矩阵变换, $trans(\cdot)$ 为该变换矩阵中的平移分量, N 为估计位姿的数目。

2.1 KITTI 数据集验证实验

1) 位姿估计性能实验

在 KITTI 数据集挑选了多个具有代表性回环特征的典型场景进行实验分析, 对比了开启回环检测的 lego-loam 算法 (下文简称 LG-Loops)、scan-context-lego-loam (下文简称 SC-LG), 以及本研究算法的定位精度, 旨在系统验证所提算法在不同场景下的实用性和鲁棒性。具体而言, 00、05~07 序列主要包含同向回环与垂直视角回环路段, 能够测试算法在常见回环类型下的检测性能; 而 08 序列主要包含反向回环路段, 进一步考察算法在复杂回环场景中的表现。通过选择这些序列进行实验, 既保证了场景的代表性, 又涵盖了多种回环类型, 有助于全面验证算法的鲁棒性与精度表现。因此, 在所选的序列上进行实验能够有效评估本研究算法的性能, 各序列详细信息如表 1 所示。

5 个序列轨迹如图 5~9 所示。

本研究及各算法在 00、05~08 序列的绝对轨迹误差 (平移部分) 的均方根误差统计结果如表 2 所示。

由表 2 可知, 本研究算法的平均绝对轨迹误差 RMSE 相对 LG 减少 62.62%、相对 LG-Loops 减少 36%、相对 SC-LG 减少 54.29%, 说明本研究算法能够实时检测正确且足够数量的回环, 并为后端优化提供有效的回环约束, 可有效减少累积误差。

表 1 KITTI 数据集场景信息

Table 1 Information on KITTI datasets scenarios			
序列	轨迹全长/m	持续时间/s	回环路段/次
00	3 724. 187	470. 6	5
05	2 205. 576	287. 5	3
06	1 232. 876	114. 3	1
07	694. 697	114. 3	1
08	3 222. 795	422. 9	3




图 5 KITTI 00 序列轨迹

Fig. 5 KITTI 00 sequence trajectories




图 8 KITTI 07 序列轨迹

Fig. 8 KITTI 07 sequence trajectories




图 9 KITTI 08 序列轨迹

Fig. 9 KITTI 08 sequence trajectories

表 2 各算法绝对轨迹误差 RMSE 对比

Table 2 RMSE comparison of absolute trajectory error among various algorithms (m)

序列	LG ^[9]	SC-LG ^[8]	LG-Loops ^[10]	本文算法
00	11. 605	7. 695	5. 584	1. 932
05	3. 758	2. 896	2. 890	1. 949
06	0. 978	0. 867	0. 967	0. 967
07	1. 253	1. 057	0. 593	0. 408
08	5. 548	6. 412	3. 485	3. 395

2) 回环检测性能实验

采用 SemanticKITTI 数据集提供的语义标签, 并对比了多种方法的性能, 包括 SC^[8]、ISC^[11]、LI^[4] 和 SSC^[29]。与 SSC 类似, 将两帧点云的欧式距离 < 3 m 且时间间隔 > 30 s 的回环场景作为正样本, 而将欧式距离 > 20 m 的点云对作为负样本。通过精确度和召回率的计算, 评估了不同算法的最大 F_1 分数。 F_1 分数在统计学中常用来评价多任务分类的模型性能, 它综合考虑了准确率 (precision, P) 与召回率 (recall, R), 通过计算两者的调和平均值来衡量模型的表现, 其计算公式如式 (13) 所示。

$$F_1 = 2 \times \frac{P \times R}{P + R} \quad (13)$$




图 6 KITTI 05 序列轨迹

Fig. 6 KITTI 05 sequence trajectories




图 7 KITTI 06 序列轨迹

Fig. 7 KITTI 06 sequence trajectories

其中, P 代表精确率, R 代表召回率, 其计算公式如式 (14)、(15) 所示。

$$Precision = \frac{TP}{TP + FP}$$

(14)

$$Recall = \frac{TP}{TP + FN}$$

(15)

其中, TP 表示正确预测的回环数, FP 表示误判为回环的非回环数, FN 表示漏检的回环数。精确率衡量在所有被预测为回环的样本中, 正确预测的比例, 召回率则衡量了在所有真实回环样本中, 成功预测为回环的比例。 F_1 分数结合精确率和召回率, 广泛用于衡量模型的整体效果。文献[29]中不同算法的 F_1 分数与本文算法对比结果如表 3 所示。

表 3 几种回环检测算法的最大 F_1 分数对比

Table 3 Comparison of maximum F_1 scores of several loop detection algorithms

方法	00	05	06	07	08
SC ^[8]	0.750	0.895	0.968	0.662	0.607
ISC ^[11]	0.657	0.771	0.842	0.636	0.408
LI ^[4]	0.668	0.768	0.913	0.629	0.478
SSC-RN ^[29]	0.939	0.941	0.986	0.870	0.881
本文算法	0.951	0.954	0.981	0.868	0.893

由表 3 可知, 本研究所提出的方法在大多数测试序列中表现优于对比方法, 即使在包含反向回回路段的 08 序列中, 也能达到较高的识别精度。对于 06 和 07 序列, 由于轨迹呈环形, 且全程仅包含一段同向回环路段, 因此, 该研究方法在 F_1 分数上与 SSC 算法表现接近。

总体来看, 本研究算法在精度上具有显著优势。尤其是相比仅考虑三维坐标的 SC 方法, 以及在其基础上改进的 ISC 方法, 本研究算法的 F_1 分数分别提升了 19.72% 和 40.12%。这些结果充分证明了本研究算法在精度上的显著提升和鲁棒性的增强。

2.2 校园数据集验证实验

1) 位姿估计性能实验验证

校园实测平台如图 10 所示, 为一款无人四轮机器人系统, 配备了 16 线激光雷达 (RS-Helios), 9 轴 IMU 传感器 (CH110) 以及工控机 (Nvidia Xavier), 工控机搭载的 CPU 为 Intel i7-1165G7, GPU 为 Nvidia 2060, 操作系统为 Ubuntu 18.04 LTS。

在校园数据集验证实验中, 室内外定位的真值采用锚点法。通过选取移动机器人运动轨迹上的一些固定点, 作为定位参考。如图 11 所示, 使用德力西生产的




图 10 四轮机器人平台

Fig. 10 Four-wheeled robotic platform



图 11 激光测距仪和水平仪

Fig. 11 Laser range finder and level instrument

的激光测距仪和水平激光仪进行测量。具体操作中, 在地下场地利用黑色记号笔标记锚点位置, 并精确测量锚点间的距离。为了确保高精度定位, 锚点之间的关系通常采用直角或同一直线的布局, 确保测量过程中距离的准确性与一致性。该方法提供了可靠的定位真值, 能够有效地作为机器人定位系统中误差评估和算法验证的基准。

选取4个序列进行实验,包括2个室内走廊场景(indoor1和indoor2)以及2个室外场景,其中一个为绕教学楼的场景(building),另一个为室外环建筑群场景(long road)。这4个序列涵盖了室内外环境,包含长短距离、正向回环、反向回环以及垂直角度回环等多种场景,具备代表性和全面性,有助于合理评估各算法的回环检测性能。由于室内环境和教学楼之间的GPS信号可能丢失或接收不稳定,从而导致定位准确性下降或出现定位失败,因此前3个场景的位姿真值均采用锚点法获取,其主要信息如表4所示。

表4 校园实测场景信息

Table 4 Information on campus testing scenarios			
场景	轨迹全长/m	持续时间/s	回回路段/次
indoor1	118.914	233	2
indoor2	288.37	405	3
building	193.3	254	1
long road	770	589	1

实验选择启用回环的lio-sam、启用回环的lego-loam以及SC-lio-sam进行对比分析。

indoor1序列轨迹如图12、13所示。仅SC-lio-sam出现大量错误的回环检测,导致整体轨迹偏移显著,最终定位失败。而lio-sam在(0 m, -20 m)处发生了一次错误的回环检测,导致轨迹出现一定偏移。其余方法的轨迹表现差异较小。




图12 序列 indoor1 的轨迹

Fig. 12 Trajectories of sequence indoor1

indoor2序列轨迹如图14、15所示,整个序列共存在3处回环。第1处回环所有方法均能正确识别。然而,在绕行较长距离后重新回到图14放大位置时,仅该方法能够正确检测到回环并生成回环约束。然而,开启回环的lio-sam和lego-loam在返回图14放大位置时均在




图13 序列 indoor1 的三轴轨迹

Fig. 13 Three axis trajectories of sequence indoor1




图14 序列 indoor2 的轨迹

Fig. 14 Trajectories of sequence indoor2




图15 序列 indoor2 的三轴轨迹

Fig. 15 Three axis trajectories of sequence indoor

z 轴上出现明显偏移,导致未能检测到回环,从而引起整体轨迹的较大偏移。

building 序列和 long road 序列的轨迹如图 16~19 所示。




图 16 序列 building 的轨迹

Fig. 16 Trajectories of sequence building




图 17 序列 building 的三轴轨迹

Fig. 17 Three axis trajectories of sequence building

在 building 序列中,各算法整体轨迹一致性较高,难以体现该研究方法的优点。相较之下, long road 序列的轨迹特征如图 18、19 所示,该序列仅在起点和终点处包含反向回环。如图 18 的放大位置所示,开启回环检测的 lego-loam 由于累计误差过大,未能检测出回环。而开启回环检测 lio-sam 虽能检测出回环,但在真实回环发生前出现误检,导致轨迹被提前优化,从而影响整体准确性。该研究方法则能够在合适的时机检测出回环,并通过因子图更新全局位姿,最终生成更精确的轨迹。




图 18 序列 long road 的轨迹

Fig. 18 Trajectories of sequence long road




图 19 序列 long road 的三轴轨迹

Fig. 19 Three axis trajectories of sequence long road

从图 19 可以看出,在 long road 场景中,只有开启回环检测的 lio-sam 和该研究方法对 Z 轴实现了显著约束,其他方法的起点和终点在 Z 轴上存在明显偏移,进一步验证了该研究方法的优越性。

各算法的均方根误差统计结果汇总于表 5。

由表 5 可知,该研究方法在室内序列中的定位精度全面优于对比方法。其中,在 indoor1 序列中,仅有 SC-lio-sam 因为出现过多错误回环而导致定位失败。而在室外环境的 building 序列中,各算法的定位精度相差不大,未能显著体现出该研究方法的优点。总体而言,该研究方法的 RMSE 与 lio-sam 算法相比下降了 56.68%,

表 5 实测实验中各算法定位误差的对比

Table 5 Comparison of positioning error among various algorithms in actual testing experiments (m)

算法	indoor1	indoor2	building
lego-loam ^[9]	0.185	1.652	0.530
lio-sam ^[10]	1.274	2.470	0.589
SC-lio-sam ^[8]		1.583	0.447
本研究	0.124	1.235	0.518

与 lego-loam 算法相比下降了 20.7%,充分证明了所提方法的可靠性和有效性,能够显著减少累计误差。

2) 不同场景下描述子性能实验验证

为了深入验证语义辅助的强度扫描上下文在不同环境下的描述子识别能力,设计了以下对比试验:首先,选择室内走廊序列 indoor1 和室外开阔序列 long road 的部分场景作为实验对象,确保 2 个场景中具有不同的光照、视距、材质等特征。随后,对比了 SSC^[29] 和 ISC^[11] 在这些场景中的相似度得分。

具体而言,在室内环境 indoor1 下选择了走廊内具有不同材质的障碍物(如墙壁、隔板、门等),并在图 12 所示轨迹的(0 m, -5 m)和(12 m, -20 m)处 2 个位置设置了对比场景,其视觉图像如图 20 所示。




图 20 室内相似场景

Fig. 20 Indoor similar scene image

在室外环境 long road 中,选取了移动机器人出发点和返回点的两帧点云作为对比,位置如图 18 所示轨迹的(0 m, 0 m)处,两帧点云的视角相差 180°,但均具有建筑、道路、植被等信息,其视觉图像如图 21 所示。



图 21 室外相似场景

Fig. 21 Outdoor similar scene image

最后,统计并比较了 3 种方法在室内外场景下的相似度得分,具体结果如表 6 所示。

表 6 室内外场景下不同算法的相似度得分

Table 6 Similarity score of different algorithms in indoor and outdoor scenes

算法	indoor1	road
ISC ^[11]	0.684	0.739
SSC ^[29]	0.771	0.812
本研究	0.613	0.882

由表 6 可知,在室内环境 indoor1 序列下,由于走廊场景的相似度较高,环境中的点云语义标签大多数相同,因此 SSC 描述子的相似度得分最高。这意味着,即使在非重复路段,描述子的相似度得分依然较高。而该研究方法的相似度得分最低,其区分度优于对比方法,能够更好地区分不同场景。在室外场景 long road 中,该研究方法的相似度得分最高,表明回环的可能性较大。最后,该研究方法在室内外场景下综合考虑了不同材质的强度信息和点云的高级语义信息,因此区分度明显优于对比方法,充分表明了所提出的描述子的优势。

3) 回环检测性能实验验证

indoor1 序列轨迹包含 1.5 圈路径,其中 0.5 圈为反向回环路段;indoor2 序列包含同向回环和反向回环;building 序列包含反向回环;long road 序列仅在终点处存在反向回环。

本次实验对比了启用回环检测的 lio-sam 算法、SC-lio-sam 算法以及启用回环检测的 lego-loam 算法,其回环数量及最大 F_1 分数统计结果如表 7 所示。

表 7 校园实测数据集的回环数量和最大 F_1 分数对比

Table 7 Comparison of the number of loop closures and the maximum F_1 score in the campus experimental dataset

序列	lio-sam ^[10]	SC-lio-sam ^[8]	lego-loam ^[9]	本研究
indoor1	48/0.912	92/0.432	51/0.923	52/0.931
indoor2	5/0.377	114/0.225	12/0.348	32/0.927
building	39/0.928	81/0.925	41/0.929	37/0.934
long road	15/0.924	75/0.523	0/0	14/0.953

根据表 7 的结果,在室内走廊环境中,由于走廊的高度较为相似,而 SC 算法仅利用了高度信息,这导致了较多的错误回环判断。尽管回环数量较其他方法更多,但整体的 F_1 分数较低。在序列 indoor2 的长距离走廊环境中,lio-sam 和 lego-loam 算法仅在第 1 个回环处成功检测回环。随着车辆行驶较长距离后,Z 轴出现明显偏移,导致最终回到原点时无法准确检测回环。在室外场景

building 序列中,各算法的回环数量差异不大, F_1 分数也未出现显著变化。而在室外场景 long road 序列中,只有 lio-sam 和该研究方法能够正确检测回环数量,且该研究方法的整体 F_1 分数高于 lio-sam 算法。相比之下,SC-lio-sam 算法在整个过程中存在一定数量的误检,因此其整体 F_1 分数最低。总体而言,本研究的回环检测性能明显优于其他算法,充分证明了该研究方法的有效性。

3 结 论

本研究提出了一种基于语义辅助的强度扫描上下文回环检测算法。首先,通过使用 ICP 算法对两帧不同时刻的点云进行几何对齐,从而减少角度和位移对回环检测的影响。随后,将语义特征与点云的三维坐标和强度信息进行融合,生成全局描述子,并根据描述子相似度判断回环,从而提高 SLAM 算法的定位精度。

在 KITTI 数据集进行的实验表明,本研究算法的最大 F_1 分数相较于 SC 算法提升了 19.71%,相比于 ISC 算法提升了 13.71%。在校园环境下采集的数据中,本算法的最大 F_1 分数与 lio-sam 算法相比提升了 19.23%,与 lego-loam 算法相比提升了 70.62%。实验结果表明,本研究算法在多种场景下具有较强的鲁棒性和可区分性,充分验证了方法的有效性与优势。然而,在室内走廊等特定场景中,由于环境特征的高重复性或语义信息不足,算法在处理较长距离回环时可能会出现一定的偏移,尤其在 Z 轴方向出现显著漂移。

参考文献

- [1] 周治国,邸顺帆,冯新. 语义信息增强的 3D 激光 SLAM 技术进展[J]. 仪器仪表学报,2023,44(3): 209-220.
ZHOU ZH G, DI SH F, FENG X. Advances in SIE 3D LiDAR SLAM technology [J]. Chinese Journal of Scientific Instrument, 2023,44(3):209-220.
- [2] 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.
- [3] 陈耀华,何丽,王宏伟,等. 基于可视点法剔除动态目标的激光-惯导 SLAM[J]. 仪器仪表学报,2023, 44(9):248-256.

- CHEN Y H, HE L, WANG H W, et al. LiDAR-inertial SLAM based on visible point method to remove dynamic objects [J]. Chinese Journal of Scientific Instrument, 2023,44(9):248-256.
- [4] WANG Y, SUN ZH, XU CH ZH, et al. LiDAR iris for loop-closure detection[C]. 2020 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS), 2020:5769-5775.
- [5] LAZEBNIK S, SCHMID C, PONCE J. Beyond bags of features: Spatial pyramid matching for recognizing natural scene categories [C]. 2006 IEEE Computer Society Conference on Computer Vision and Pattern Recognition, 2006:2169-2178.
- [6] JÉGOU H, DOUZE M, SCHMID C, et al. Aggregating local descriptors into a compact image representation[C]. 2010 IEEE Computer Society Conference on Computer Vision and Pattern Recognition, 2010:3304-3311.
- [7] DIXIT M, CHEN S, GAO D SH, et al. Scene classification with semantic fisher vectors [C]. 2015 IEEE Conference on Computer Vision and Pattern Recognition, 2015:2974-2983.
- [8] 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), 2018:4802-4809.
- [9] SHAN T X, 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, 2018: 4758-4765.
- [10] SHAN T X, ENGLLOT B, MEYERS D, et al. Lio-sam: Tightly-coupled LiDAR inertial odometry via smoothing and mapping[C]. 2020 IEEE/RSJ International Conference on Intelligent Robots and Systems, 2020: 5135-5142.
- [11] WANG H, WANG CH, XIE L H. Intensity scan context: Coding intensity and geometry relations for loop closure detection[C]. 2020 IEEE International Conference on Robotics and Automation, 2020: 2095-2101.

- [12] 马哲伟,周福强. 一种改进回环的多传感器融合SLAM算法[J]. 电子测量技术,2023,46(22):131-138.
- MA ZH W, ZHOU F Q. An improved loopback multi-sensor fusion SLAM algorithm[J]. Electronic Measurement Technology, 2023,46(22):131-138.
- [13] 徐晓苏,何宇明. 基于三角词袋回环检测的激光惯性SLAM算法[J]. 中国惯性技术学报,2024,32(9):898-906,917.
- XU X S, HE Y M. LiDAR-inertial SLAM algorithm based on triangle bag of words loop closure detection[J]. Journal of Chinese Inertial Technology, 2024,32(9):898-906,917.
- [14] 刘铭,魏国亮,王耀磊. 一种多信息作用下的激光回环检测算法[J]. 控制工程,2024,31(9):1626-1633.
- LIU M, WEI G L, WANG Y L. A LiDAR loop detection algorithm with multiple information effects[J]. Control Engineering of China, 2024,31(9):1626-1633.
- [15] 王池华,陈倩,胡大开,等. 基于点云反射强度的船载激光SLAM回环检测算法[J]. 现代电子技术,2024,47(23):113-118.
- WANG CH H, CHEN Q, HU D K, et al. Shipborne LiDAR SLAM loop detection algorithm based on point cloud reflection intensity[J]. Modern Electronics Technique, 2024,47(23):113-118.
- [16] 黄良沛,胡志豪,杨天龙,等. 基于优化回环检测的激光雷达SLAM算法[J]. 信息技术,2024(12):26-31,38.
- HUANG L P, HU ZH H, YANG T L, et al. LiDAR SLAM algorithm based on optimized loop closure detection[J]. Information Technology, 2024(12):26-31,38.
- [17] UY M A, LEE G H. Pointnetvlad: Deep point cloud based retrieval for large-scale place recognition [C]. 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2018:4470-4479.
- [18] QI C R, SU H, MO K CH, et al. Pointnet: Deep learning on point sets for 3D classification and segmentation[C]. 2017 IEEE Conference on Computer Vision and Pattern Recognition, 2017:77-85.
- [19] ARANDJELOVIC R, GRONAT P, TORII A, et al. NetVLAD: CNN architecture for weakly supervised place recognition[C]. 29th IEEE Conference on Computer Vision and Pattern Recognition, 2016:5297-5307.
- [20] LU W X, ZHOU Y, WAN G W, et al. L3-net: Towards learning based LiDAR localization for autonomous driving[C]. 2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition. 2019:6382-6391.
- [21] SCHAUPP L, BÜRKI M, DUBÉ R, et al. OREOS: Oriented recognition of 3D point clouds in outdoor scenarios[C]. 2019 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS), 2019:3255-3261.
- [22] YIN P, WANG F Y, EGOROV A, et al. Seqspherevlad: Sequence matching enhanced orientation-invariant place recognition[C]. 2020 IEEE/RSJ International Conference on Intelligent Robots and Systems, 2020:5024-5029.
- [23] CHANG M Y, YEON S, RYU S, et al. SpoxelNet: Spherical voxel-based deep place recognition for 3D point clouds of crowded indoor spaces [C]. 2020 IEEE/RSJ International Conference on Intelligent Robots and Systems, 2020:8564-8570.
- [24] KOMOROWSKI J. Minkloc3D: Point cloud based large-scale place recognition[C]. 2021 IEEE Winter Conference on Applications of Computer Vision, 2021:1789-1798.
- [25] 姚万业,杨振辉,王祝. 融合卷积注意力的激光同步定位与建图回环检测网络[J]. 电力科学与工程,2024,40(2):50-60.
- YAO W Y, YANG ZH H, WANG ZH. Loop closure detection network fused with convolutional attention for LiDAR SLAM [J]. Electric Power Science and Engineering, 2024,40(2):50-60.
- [26] KONG X, YANG X M, ZHAI G Y, et al. Semantic graph based place recognition for 3d point clouds[C]. 2020 IEEE/RSJ International Conference on Intelligent Robots and Systems, 2020:8216-8223.
- [27] ZHU Y CH, MA Y Y, CHEN L, et al. Gosmatch: Graph-of-semantics matching for detecting loop closures in 3D LiDAR data [C]. 2020 IEEE/RSJ International Conference on Intelligent Robots and Systems, 2020:5151-5157.
- [28] XU X, KONG L D, SHUAI H, et al. FRNet: Frustum-

range networks for scalable LiDAR segmentation [J].
ArXiv preprint arXiv:2312.04484, 2023.

[29] LI L, KONG X, ZHAO X R, et al. SSC: Semantic scan context for large-scale place recognition [C]. 2021 IEEE/RSJ International Conference on Intelligent Robots and Systems, 2021:1624-1634.

作者简介



刘名星, 2021 年于鲁东大学获得学士学位, 现为东南大学硕士研究生, 主要研究方向为激光雷达感知与定位。
E-mail:17852610296@163.com

Liu Mingxing received his B.Sc. degree from Ludong University in 2021. He is currently a mater student at Southeast University. His main research interests include LiDAR-based perception and localization.



徐晓苏 (通信作者), 1982 年于东南大学获得学士学位, 1985 年于东南大学获得硕士学位, 1991 年于东南大学获得博士学位。现为东南大学仪器科学与工程学院教授, 主要研究方向为惯性导航、组合导航、卫星导航、视觉导航、智能滤波技术。
E-mail:xxs@seu.edu.cn

Xu Xiaosu (Corresponding author) received his B.Sc. degree from Southeast University in 1982, received his M.Sc. degree from Southeast University in 1985, and received his Ph.D. degree from Southeast University in 1991. He is currently a professor with the School of Instrument Science and Engineering at Southeast University. His main research interests include inertial navigation, integrated navigation, satellite navigation, visual navigation, and intelligent filtering technologies.