

doi:10.19306/j.cnki.2095-8110.2020.06.007

## 基于局部几何特征的稠密点云配准方法

朱一帆<sup>1</sup>, 裴凌<sup>1</sup>, 吴奇<sup>1</sup>, 夏宋鹏程<sup>1</sup>, 李涛<sup>1</sup>, 陈雷<sup>1,2</sup>, 郁文贤<sup>1</sup>

(1. 上海交通大学上海市北斗导航与位置服务重点实验室, 上海 200240;

2. 北京跟踪与通信技术研究所, 北京 100094)

**摘要:**针对现有的稠密点云配准方法依赖初始位置设定、计算成本高、配准成功率不高等问题,提出了一种基于点云局部几何特征的稠密点云配准方法。采用深度卷积神经网络模型提取点云的局部几何特征,从而减少了三维点云数据的噪声、低分辨率和不完备性等带来的影响。在此基础上,使用K维树搜索完成局部几何特征描述子的关联工作。最后,通过随机采样一致算法对点云的相对位姿进行鲁棒的估计。通过对开源数据集上5个典型场景中的数据测试表明,该方法的配准成功率达到92.5%,配准精度达到0.0434m,配准时间相对最邻点迭代配准算法缩短了74.7%,实验结果验证了该方法的有效性、实时性和鲁棒性。

**关键词:**室内定位;三维点云配准;三维点云描述子;深度学习

中图分类号:TN959.3 文献标志码:A 开放科学(资源服务)标识码(OSID):

文章编号:2095-8110(2020)06-0053-07



## A Dense Point Cloud Registration Method Based on Local Geometry Features

ZHU Yi-fan<sup>1</sup>, PEI Ling<sup>1</sup>, WU Qi<sup>1</sup>, XIA-Song Pengcheng<sup>1</sup>, LI Tao<sup>1</sup>, CHEN Lei<sup>1,2</sup>, YU Wen-xian<sup>1</sup>

(1. Shanghai Key Laboratory of Navigation and Location-based Services,

Shanghai Jiao Tong University, Shanghai 200240, China;

2. Beijing Institute of Tracking and Telecommunication Technology, Beijing 100094, China)

**Abstract:** In order to solve the problems of existing dense point cloud registration methods, such as the dependence on initial location setting, high computational cost, and low registration success rate, a dense point cloud registration method based on local geometric features of the point cloud is proposed. A deep convolutional neural network is used to extract local features of a point cloud, to reduce the influence of noise, low resolution, and incompleteness of 3D point cloud data. On this basis, a k-dimensional tree search is used to complete the association of local geometric feature descriptors. Finally, the random sampling consensus algorithm is used to estimate the relative pose of the point cloud robustly. The experimental results by testing 5 typical scenarios from open-source data sets show that the registration success rate and the accuracy of the proposed method reach 92.5%, 0.0434m, and the registration time is 74.7% shorter than the nearest point iterative registration algorithm. Experimental results show that the proposed method is effective, real-time and robust.

**Key words:** Indoor localization; 3D point cloud registration; 3D point cloud descriptor; Deep learning

收稿日期:2020-06-24;修订日期:2020-07-13

基金项目:国家自然科学基金(61873163);装备预研领域基金(61405180205,61405180104)

作者简介:朱一帆(1994-),男,博士研究生,主要从事室内定位算法方面的研究。E-mail:yifanzhu@sjtu.edu.cn

通信作者:裴凌(1977-),男,博士生导师,副教授,主要从事室内定位与融合导航方面的研究。E-mail:ling.pei@sjtu.edu.cn

## 0 引言

近年来,随着传感器技术的进步,三维点云数据在精度和稠密度方面获得了大幅提升<sup>[1]</sup>,三维点云数据作为重要的空间结构数据,被广泛地应用于自主导航和三维场景重建等。对稀疏的三维激光点云配准问题已经进行了较为深入的研究,稠密的三维点云的配准问题成为了研究热点。

迭代最邻近点 (Iterative Closest Point, ICP) 算法是解决点云配准问题的核心算法。该算法采用点点(点面)距离寻找邻近点,再通过最小二乘法求取点云间的旋转和平移矩阵,以达到点云配准的目的,其实质是一种迭代收敛的算法<sup>[2]</sup>。随着三维点云数据稠密程度的提高,现有的基于 ICP 算法的三维点云配准方法由于计算量大、依赖初始位置设定等因素,配准成功率不高。

在视觉同时定位与建图 (Visual Simultaneous Localization and Mapping, VSLAM) 中<sup>[3-4]</sup>,通常对点云数据进行局部特征抽取,再基于特征进行配准,可以大幅减少点云数量,提高配准的鲁棒性。由于三维点云的无序性和传感器的噪声,点云局部特征的描述工作相对图像特征要困难很多,这也造成了现有的点云描述子的鲁棒性不足,在进行点云配准的过程中位姿恢复精度较低<sup>[5]</sup>。随着深度学习技术的兴起,基于数据驱动模型被用于三维点云局部特征的描述上,并且表现非常出色。实验证明,基于数据驱动模型对点云局部的几何结构能够进行有效的描述,并在特征空间上能够很好地进行聚类,效果优于现有的手动设计的描述子<sup>[6]</sup>。

基于上述原因,本文提出了一种基于点云局部几何特征的稠密点云配准方法。该方法借鉴 VSLAM 算法中图像匹配的思路<sup>[7]</sup>,对点云进行局部特征抽取和描述,然后进行位姿估算。在局部特征提取方面,使用深度卷积网络对特征进行描述,以减少三维点云数据的噪声、低分辨率和不完备性等带来的影响。该方法的优势在于精度高、计算量低,且能够匹配位姿差异大的点云。实验结果验证了该方法的有效性、实时性和鲁棒性。

## 1 算法设计

点云的配准工作主要可以描述为:求解两帧三维点云的旋转平移矩阵(6个自由度),使两帧点云能够对齐到同一个坐标系上。本文提出的点云配

准方法技术路线如图 1 所示。对于给定的两帧点云,分别计算其特征点和特征描述之后,通过随机采样一致(Random Sample Consensus, RANSAC)算法对两帧三维点云的旋转平移矩阵进行鲁棒的估计。

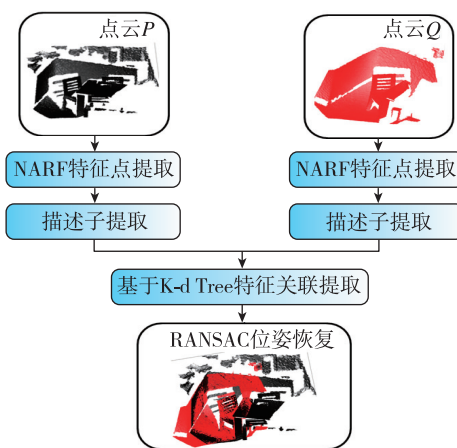


图 1 3D 点云配准方法算法流程

Fig. 1 3D point cloud registration algorithm flow

### 1.1 特征点检测

三维点云  $(P = \{p_1, p_2, \dots, p_n\})$  可以被描述为一些离散三维点  $(p_i = [x_i, y_i, z_i]^T, x_i, y_i, z_i \in R)$  的集合。其中特征点检测算法的目的是寻找该集合的一个子集  $(K \subseteq P)$ , 使其能够尽可能地代表原来集合的信息。对于点云配准这一具体应用, 所选取的关键点要满足以下要求: 1) 特征点的提取算法要求效率高; 2) 在不同的视点下都能提取到大部分相同的特征点; 3) 提取出的特征点应位于表面稳定的区域, 以保证稳定的特征提取。

法线对齐的径向特征 (Normal Aligned Radial Feature, NARF) 是一种 3D 特征点检测和描述算法<sup>[8]</sup>。其特征点选取算法能够很好地满足上述要求, 因此, 在本文的点云配准方法中选用 NARF 特征点。首先, 将目标点云转化为距离图像便于快速检索以保证要求 1); 然后, 对于每一个三维点  $p_i$ , 选择其在距离图像上的一个方形窗 (窗宽为:  $s$ ) 内的邻域点, 并计算其与  $p_i$  的三维距离; 之后按照式 (1) 计算三维点  $p_i$  的分数

$$s_i = \max\left(0, 1 - \frac{d_M}{d_i}\right) \quad (1)$$

其中,  $d_i$  是  $p_i$  在距离图像上与其上下左右 4 个方向上的邻接像素点的平均三维距离;  $d_M$  是方形窗内一系列点中距离  $p_i$  第  $M$  远的点与  $p_i$  的三维距

离,其中  $M = (0.5(s + 1))^2$ 。当分数高于一定阈值时,认为三维点  $p_i$  满足要求 2),并将其列入候选关键点列表。对于候选关键点列表中的  $p_i$ ,在点云中找到其在半径  $\sigma$  中的所有领域点:  $n_0, \dots, n_k$ 。评分函数  $I(p)$  被用以评估三维点  $p_i$  对要求 3) 的满足情况,定义为

$$I(p) = I_1(p)I_2(p) \quad (2)$$

$$I_1(p) = \min_i (1 - \omega_{n_i} \max(1 - 10 \|p - n_i\|/\sigma, 0))$$

$$I_2(p) = \max_{i,j} (f(n_i)f(n_j)(1 - |\cos(\alpha_{n_i} - \alpha_{n_j})|))$$

$$f(n) = \sqrt{\omega_n (1 - |2 \|p - n_i\|/\sigma - 0.5|)}$$

其中,  $\alpha$  是  $p_i$  和其所有领域点中不是边界点的主方向;  $\omega_n$  是一个权重,对于边缘点取值为 1,非边缘点取值为  $1 - (1 - \lambda)^3$ ,  $\lambda$  代表非边缘点的曲率大小。当候选关键点列表中的某个  $p_i$  的分数  $I(p_i)$  大于一定阈值时,该点被选为特征点。NARF 特征点提取流程如图 2 所示。




图 2 NARF 特征点提取流程

Fig. 2 NARF feature point extraction process

## 1.2 特征描述

特征描述的作用在于对属于特征点序列中的每一个三维点 ( $p_i \in K$ ) 进行编码,该编码便于在不同帧之间进行匹配。对于点云配准这一具体应用,选取的关键点要满足以下要求:1)提取的描述子具有一定的抗噪声性能,且能够克服点云低分辨率和不完备性等带来的影响;2)提取的点云具有一定的角度不变性,能够在不同视角下完成匹配。对于要求 1),本文提出将特征点的邻域信息以体素格的数据形式进行表征,以克服噪声带来的影响;对于要求 2),本文使用基于数据驱动的描述子,以保证描述子的旋转不变性。




图 4 描述子计算网络

Fig. 4 Descriptor extraction network

### 1.2.1 特征点体素化

对于一个特征点  $p_i \in K$ ,在点云中找到其在半径  $\sigma$  (在本文中  $\sigma = 0.15\text{m}$ ) 内的所有领域点:  $n_0, \dots, n_k$ 。以  $p_i$  为中心构造一个  $n \times n \times n$  的体素格 (在本文中  $n = 30$ ), 每个体素格中存储截断距离函数 (Truncated Distance Function, TDF) 值。TDF 值代表了每个体素格中心相对最近的三维点云表面的距离。同时,这些 TDF 值被截断在 1 (在点云表面上) 和 0 (远离点云表面) 之间。对于体素  $v_i$ , 其 TDF 值由式 (3) 进行计算

$$TDF(v_i) = 1 - \min_{j=1, \dots, k} (\|v_i - n_j\|) / \beta \quad (3)$$

其中,  $\beta$  是一个比例系数 (在本文中  $\beta = 0.05\text{m}$ );  $\min_{j=1, \dots, k} (\|v_i - n_j\|)$  代表体素  $v_i$  中心相对最近的三维点云表面的距离。图 3 所示为 TDF 体素格计算流程。

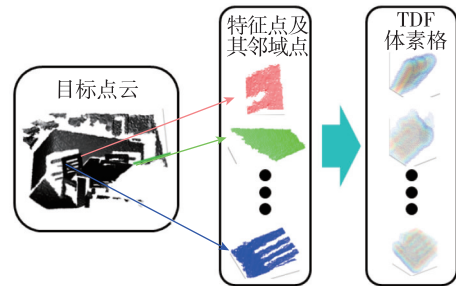


图 3 TDF 体素格计算流程

Fig. 3 TDF voxel lattice calculation process

### 1.2.2 描述子计算

对于每个特征点生成大小为  $n \times n \times n$  的 TDF 体素格,包含了该特征点的局部几何特征,描述子计算的目的在于给该特征进行编码,以便于后续的特征匹配。受到 3DMatch 工作的启发<sup>[9]</sup>,本文使用 3D 卷积网络对 TDF 进行特征抽取,网络结构如图 4 所示。该网络包含 8 个卷积层和 1 个池化层,能够将一个  $30^3$  的 TDF 体素格转化为 512 维的描述向量 (卷积层与池化层的卷积核大小和通道数已标注于图中)。

描述子被用于鉴别 TDF 体素的相似性。为了达到这一目的,使用孪生网络的训练方法对该 3D 卷积网络进行训练。首先,建立大量匹配和不匹配的  $30^3$  的 TDF 体素格对,其数量占比大致为 1:1,作为训练数据库;之后对每对 TDF 体素格利用相同的网络权重参数计算描述子  $Des_1^i$  与  $Des_2^i$ ;最后最小化损失函数式(4),以得到训练后的网络权重

$$L = \frac{1}{2N} \sum_{i=1}^N yd^2 + (1-y)\max(Q-d,0)^2 \quad (4)$$

其中,  $d = \|Des_1^i - Des_2^i\|$ ,代表 2 个描述子的欧式距离; $y$  为 2 个样本是否匹配的标签; $Q$  为设定的阈值。当  $y=1$ (样本相似)时,损失函数是关于  $d$  的单调减函数;当  $y=0$ (样本不相似)时,损失函数是关于  $d$  的单调增函数。通过最小化损失函数能够达到在欧氏空间上区分样本相似性的目的。

### 1.3 基于 K-d Tree 的特征关联

特征关联的目的是在待配准的点云  $P$  与  $Q$  的关键点子集  $K_P$  和  $K_Q$  中找到特征最为相近的点,以完成两帧点云的特征匹配。其本质是一个通过距离函数(欧式距离)在高维矢量之间进行相似性检索的问题,使用 K 维树搜索算法能够高效地实现上述过程,该算法的具体流程叙述如下,流程图如图 5 所示。

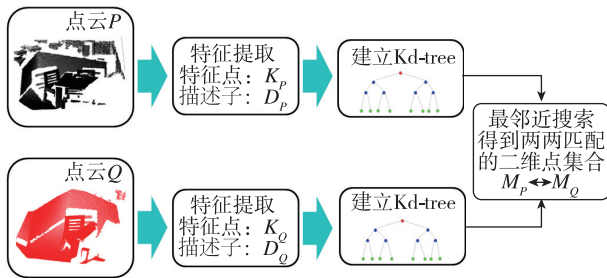


图 5 基于 K-d Tree 的特征关联算法流程图

Fig. 5 Flow chart of feature association algorithm based on K-d Tree

首先,利用 1.1 节与 1.2 节提到的算法分别对点云  $P$  与  $Q$  提取关键点构成集合  $K_P$  和  $K_Q$ ,并计算每个特征点的描述子分别构成集合  $D_P$  和  $D_Q$ 。Kd-tree 是每个节点都为  $k$  维点的二叉树。由于本文的描述子维度为 512 维,因此在 Kd-tree 构建部分对应为根据  $D_P$  和  $D_Q$  分别构建 512 维空间的二叉树,

其构建过程可以参考 Bentley 提出方法<sup>[10]</sup>中的第 3 节。

在构建完成 Kd-tree 之后,分别在  $D_P$  和  $D_Q$  中进行最邻近搜索,以确定在特征空间中最靠近的特征点,并得到相互匹配的三维点的集合  $M_P$  与  $M_Q$ ,其实现过程可以参考 Bentley 提出方法<sup>[10]</sup>中的第 4 节。

### 1.4 基于 RANSAC 算法的位姿恢复

在基于 K-d Tree 的特征关联之后,可以得到两帧点云中两两匹配的点云集合。基于上述结果,可以得到目标点云  $P$  与点云  $Q$  的相对位姿,进一步可以得到点云配准的结果。该算法具体叙述流程如下。

首先,利用 1.3 节提到的特征关联方法得到两帧点云中两两匹配的三维点集合  $M_P$  与  $M_Q$ ;然后对于  $M_P$  与  $M_Q$  中的三维点,计算 2 组点的质心坐标  $p$  和  $q$ ;再计算每个点的去质心坐标,如式(5)所示

$$q_i \leftarrow q_i - q \quad p_i \leftarrow p_i - p \quad (5)$$

最后,对矩阵  $W = \sum_{i=1}^n p_i q_i^T$  进行奇异值分解(Singular Value Decomposition, SVD),得到  $W = U\Sigma V^T$ ,之后点云  $P$  与  $Q$  的相对旋转矩阵和平移向量可以由式(6)获得

$$R_P^Q = UV^T \quad (6)$$

$$t_P^Q = p - R_P^Q q$$

在现实世界中,由于场景和特征的多样性,本来应该一一匹配的  $M_P$  与  $M_Q$  不可避免地存在误匹配。考虑到这一情况,本文使用 RANSAC<sup>[11]</sup>机制对  $M_P$  与  $M_Q$  的点进行过滤,以获得目标点云准确的位姿。RANSAC 机制可以从一组包含局外点的观测数据集中,通过迭代方式估计数学模型的参数。在本文的应用中,可以利用迭代和概率的方法,从有误匹配的数据中估计出点云的相对位姿。引入 RANSAC 机制的目标点云的位姿恢复算法的伪代码如下表 1 所示。

## 2 实验和分析

为了充分评估所提方法的性能,本文设计并进行了一系列实验,主要验证以下 3 个方面:1)所提点云配准方法的成功率;2)所提方法位姿估计的准确性;3)所提方法的配准效率。

表 1 基于 RANSAC 算法的位姿恢复算法

Tab. 1 Position recovery algorithm based on RANSAC algorithm

---

Input: 2 组匹配的特征三维点  $M_P$  与  $M_Q$ ; 最大迭代次数  $k$ ; 阈值  $T_r$ ; 每次被选中特征点个数  $n$ .

Output: 最优的旋转矩阵  $\mathbf{R}$  与平移向量  $t$ .

- 1: 初始化  $iteration = 0; numpoint = |M_Q|$ ;
- 2: *repeat* :
- 3: 从  $M_P$  与  $M_Q$  中随机选取  $n$  对匹配三维点;
- 4: 利用 SVD 方法计算该针对  $n$  对匹配三维点的旋转矩阵  $\mathbf{R}_{tmp}$  与平移向量  $t_{tmp}$ ;
- 5:  $totalerror = 0$ ;
- 6: *for*  $i=0; numpoint$  :
- 7:  $error = M_Q$  的三维点经过旋转矩阵  $\mathbf{R}_{tmp}$  与平移向量  $t_{tmp}$  进行刚体变换之后与  $M_P$  中对应三维点的欧式距离;
- 8:  $totalerror += error$ ;
- 9: *end*
- 10: *if* ( $totalerror < T_r$ ):
- 11:  $\mathbf{R} = \mathbf{R}_{tmp}$   $t = t_{tmp}$  *break*;
- 12: *end*;
- 13: *until* ( $iteration > k$ )

---

## 2.1 实验设置

本文在公开数据集 7-Scenes<sup>[12]</sup>与 SUN3D<sup>[13]</sup>上对所提出的方法进行验证和评估。实验中的几个场景样例如图 6 所示,每个场景都包含了不同的分辨率、使用不同的重构算法创建。这些场景具备不同的传感器噪声、视角和遮挡方式等情况,能够很好地验证算法。值得注意的是,图中的颜色信息只被用于可视化,在实验中没有用到。



图 6 实验数据集

Fig. 6 Data sets for experiment

本文同时给出了一些参与运算的关键参数和阈值,具体如表 2 所示。

表 2 关键参数设计

Tab. 2 Key parameter design

参数说明	符号	取值
特征点选取窗宽	$s$	5
特征点邻域搜寻半径	$\sigma$	0.15m
体素格大小	$n$	30
体素格比例因子	$\beta$	0.05m

## 2.2 成功率分析

本节对所提出的点云配准算法的稳定性进行

了评估,并与传统 NARF 描述子和 ICP 算法进行了比较。本文从 7-Scenes 与 SUN3D 数据集中选取了 8 个场景,并从每个场景中选取 5 对不连续点云(平移和旋转较大)进行配准的评估(一共有 40 对点云参与评估)。本文使用 Choi 提出的评判标准判断点云配准是否成功。对于两帧待匹配的点云 ( $P_i, P_j$ ),如果满足式(7)的条件,则认为算法所估计的  $T_{ij}$  是正确的

$$\frac{1}{|K_{ij}^*|} \sum_{(p^*, q^*) \in K_{ij}^*} \|T_{ij} p^* - q^*\|^2 < \tau^2 \quad (7)$$

式中,  $T_{ij}$  是算法预测的平移旋转矩阵;  $K_{ij}^*$  是两帧点云中正确匹配点对构成的集合;  $p^*$  和  $q^*$  是正确匹配的三维点的坐标。公式的左边可以被理解为匹配点对的均方根误差(Root Mean Squard Error, RMSE),公式的右边是一个阈值,在本文中取  $\tau = 0.2$ 。

将本文提出的算法与 ICP 算法、NARF 算法进行对比,并将三种算法在数据集上的成功率列举如表 3 所示。同时,图 7 给出了数据集中一些具有挑战性的配准案例的示意图,其中第一列为本文提出的配准结果,第二列为 NARF 配准结果,第三列为 ICP 配准结果。

表 3 点云配准成功率

Tab. 3 Point cloud registration success rate

方法	总对数	匹配成功对数	成功率
NARF	40	25	62.5%
ICP	40	15	37.5%
本文提出	40	37	92.5%




图 7 配准结果样例

Fig. 7 Samples of point cloud registration results

实验结果表明:在给定的数据集上,本文提出的算法配准成功率最高。其中 ICP 算法表现最差,其原因在于数据集中待配准点云稠密且相对旋转和平移较大,该条件不适应 ICP 算法的工作(点云稀疏且相对旋转与平移较小)<sup>[14]</sup>。本文提出的算法能够在给定数据集中鲁棒性优于 NARF 算法的原因在于描述方法的稳定性。在实验中可以观察到,使用本文的描述子进行匹配特征点对数是使用 NARF 描述子的 1.61 倍。

### 2.3 配准精度的比较

本节对所提出的点云配准算法的精度进行了评估,并与传统 NARF 描述子和 ICP 算法进行了比较。本文选取了 2.2 节中各个算法的成功案例进行精度的评估。同样使用 RMSE 对精度进行评价,定义如式(8)所示

$$RMSE = \frac{1}{N} \sum \sqrt{\frac{1}{|K_{ij}^*|} \sum_{(p^*, q^*) \in K_{ij}^*} \|T_{ij} p^* - q^*\|^2} \quad (8)$$

式中,  $N$  是正确匹配点云对的数量;  $T_{ij}$  是正确匹配点云预测的平移旋转矩阵;  $K_{ij}^*$  是两帧点云中正确匹配点对构成的集合;  $p^*$  和  $q^*$  是正确匹配的三维点的坐标。对比的实验结果统计如表 4 所示。

表 4 点云配准精度

Tab. 4 Accuracy of point cloud registration

	NARF	ICP	本文提出
参与计算点云对数	25	15	37
RMSE	0.0526	0.1269	0.0434

试验结果表明:在配准精度上,本文提出算法相对使用 NARF 描述的方法略优,这是由于关键点的稳定匹配的原因。更多的正确匹配点对能够促进更为准确的位姿估计。ICP 算法在精度上差于经典算法,其原因在于:由于点云的稠密性,ICP 算法在最优结果的邻近位置难以找到正确的对应点对,导致无法进一步迭代优化。

### 2.4 配准时间的比较

本节对所提出的点云配准算法的效率进行了评估,并与传统 NARF 描述子和 ICP 算法进行了比较。本文进行实验的计算机平台的软件硬件环境列举如表 5 所示。

表 5 实验条件

Tab. 5 Software and hardware environment

软件	硬件
系统:Ubuntu16.04	核心处理器: Intel i5-8500
特征点选取: PCL1.8.0 <sup>[15]</sup>	显卡: NVIDIA-GTX-1660Ti
NARF 特征提取: PCL1.8.0	内存: DDR4-32G
ICP 算法实现: PCL1.8.0	硬盘: SSD-512G
描述子抽取: Marvin	—
RANSAC 位姿恢复: MATLAB2018	—

本文同时统计了三种算法在该环境下进行点云配准的平均时间,结果如表 6 所示。

表 6 配准时间比较

Tab. 6 Comparison of registration time

	NARF	ICP	本文提出
配准时间/s	9.4655	42.25	10.7021

试验结果表明,在稠密点云上,基于特征匹配方法的配准时间优于基于迭代算法。本文提出的算法在数据集上能够基本做到 10.7021s/帧的配准速度,与 NARF 基本在一个水平。

## 3 结论

随着点云传感器的发展,三维点云数据的稠密性和测量精度将会在未来得到显著提高。本文提出了一种基于点云局部几何特征的稠密点云配准方法,探讨了将基于深度学习的点云描述子运用于点云配准的问题。实验结果表明,针对稠密非连续点云的配准问题,基于特征匹配的方法在效率和精度上都优于基于 ICP 的方法;同时基于数据驱动的点云描述子在不损失配准精度的情况下,鲁棒性明显优于手动设计的点云描述子。

该算法目前存在的问题有:为保证实时性需要 GPU 的支持、描述子提取需要进行前期训练等。在未来,我们将改进算法,使之可进一步应用于不同类型的点云(激光雷达);同时提升算法的实时性,将其应用于重定位、轨迹推算、回环检测等问题中。

### 参考文献

- [1] Lin J, Zhang F. Loam\_livox: a fast, robust, high-precision LiDAR odometry and mapping package for LiDARs of small FoV[J]. arXiv:1909.06700, 2019.

- [2] Besl P J. A method for registration of 3D shapes[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 1992, 14(2): 239-256.
- [3] 孙博雅. 移动机器人 SLAM 技术[J]. 电子技术与软件工程, 2018(2): 95.  
Sun Boya. Mobile robot SLAM technology[J]. Electronic Technology and Software Engineering, 2018(2): 95(in Chinese).
- [4] Zou D, Wu Y, Pei L, et al. StructVIO: visual-inertial odometry with structural regularity of man-made environments[J]. IEEE Transactions on Robotics, 2019, 35(4): 999-1013.
- [5] 郭杭, 漆钰晖, 裴凌, 等. 基于体素格尺度不变特征变换的快速点云配准方法[J]. 中国惯性技术学报, 2019, 27(1): 77-82.  
Guo Hang, Qi Yuhui, Pei Ling, et al. Fast point cloud registration method based on voxel-SIFT feature[J]. Chinese Journal of Inertial Technology, 2019, 27(1): 77-82(in Chinese).
- [6] Dube R, Cramariuc A, Dugas D, et al. SegMap: 3D segment mapping using data-driven descriptors[J]. arXiv:1804.09557v1, 2018.
- [7] Pei L, Liu K, Zou D, et al. IVPR: an instant visual place recognition approach based on structural lines in manhattan world[J]. IEEE Transactions on Instrumentation and Measurement, 2019(99): 1.
- [8] Steder B, Rusu B, Konolige K, et al. NARF: 3D range image features for object recognition[C]// Proceedings of IEEE/RSJ International Conference on Intelligent Robots and Systems, 2010.
- [9] Zeng A, Song S, Nießner M, et al. 3DMatch: learning local geometric descriptors from RGB-D reconstructions[C]// Proceedings of Computer Vision and Pattern Recognition, 2017: 199-208.
- [10] Bentley J L. Multidimensional binary search trees used for associative searching[J]. Communications of the ACM, 1975, 18(9): 509-517.
- [11] Fischler M A, Bolles R C. Random sample consensus: a paradigm for model fitting with applications to image analysis and automated cartography[J]. Communications of the ACM, 1981, 24(6): 381-395.
- [12] Antonio Criminisi. MSRC RGBD 7-Scenes dataset [J]. 2016.
- [13] Xiao J, Owens A H, Torralba A. SUN3D: a database of big spaces reconstructed using SfM and object labels[C]// Proceedings of 2013 IEEE International Conference on Computer Vision (ICCV). IEEE, 2013.
- [14] 陈春旭, 漆钰晖, 朱一帆, 等. ICP 配准算法的影响因素及评价指标分析[J]. 导航定位与授时, 2018, 5(5): 67-72.  
Chen Chunxu, Qi Yuhui, Zhu Yifan, et al. The analysis of influence factors and evaluation indexes on ICP algorithm[J]. Navigation Positioning and Timing, 2018, 5(5): 67-72(in Chinese).
- [15] Rusu R B, Cousins S. 3D is here: point cloud library (PCL)[C]// Proceedings of IEEE International Conference on Robotics and Automation(ICRA). Shanghai, China. IEEE, 2011.