

# 一种基于关键点选择的快速点云配准算法

张哲, 许宏丽, 尹辉

北京交通大学计算机与信息技术学院, 北京 100044

**摘要** 为了提高三维点云数据配准的效率, 提出一种基于法向量分布特征的关键点初始匹配与迭代最近点(ICP)的精确配准的两步点云配准算法。首先, 定义点云的邻接区域和法向量分布特征计算模型, 提出基于该模型的关键点选择算法; 其次, 为每个关键点建立局部坐标系, 计算关键点的快速点特征直方图, 使用采样一致性配准算法匹配关键点的特征, 去除错误匹配点, 求解出变换矩阵, 完成初始配准; 最后, 使用 ICP 算法, 对多视点云的初始配准结果进行精确配准。实验结果表明, 在散乱点云数据和自获取的深度点云数据配准中, 该算法能够在确保配准精度的同时有效提升配准效率。

**关键词** 图像处理; 点云配准; 关键点; 快速点特征直方图; 迭代最近点算法

**中图分类号** TP391 **文献标识码** A

**doi:** 10.3788/LOP54.121002

## A Fast Point Cloud Registration Algorithm Based on Key Point Selection

Zhang Zhe, Xu Hongli, Yin Hui

*School of Computer and Information Technology, Beijing Jiaotong University, Beijing 100044, China*

**Abstract** In order to improve the registration efficiency of three-dimensional point cloud, a two-step point cloud registration algorithm is proposed based on the key point initial matching using the normal vector distribution feature and the accurate registration using the iterative closest point (ICP). Firstly, the definition of the adjacency region and the normal vector distribution feature model of point cloud are presented, and a key point selection algorithm is proposed based on the model. Secondly, the fast point feature histograms of key points are calculated using the local coordinate system, and the false matches are eliminated by the sampling conformance registration algorithm. According to the corresponding relation, the rotation and translation matrices are calculated and the initial registration is completed. Finally, the final registration result is obtained using ICP algorithm. The experimental results show that the proposed algorithm can effectively improve the registration efficiency while ensuring the accuracy of the registration in the data of unordered point cloud and the self-acquired depth point cloud.

**Key words** image processing; point cloud registration; key point; fast point feature histogram; iterative closest point algorithm

**OCIS codes** 100.2000; 100.3008; 100.6890

## 1 引言

高精度快速点云配准方法是基于点云的三维建模和逆向工程领域的研究热点和难点, 在逆向工程、计算机视觉、文物数字化等领域均有着十分重要的意义。但是目前, 点云配准技术依旧不成熟。其中, 最经典的是 Besl<sup>[1]</sup>提出的迭代最近点(ICP)算法以及其改进算法<sup>[2-4]</sup>, 在初始位置相近的情况下, 其配准精度较高, 但初始位置相差较大时, 会使配准点云陷入局部极小值, 并且该算法对大型点云数据计算时间较长, 算法效率

**收稿日期:** 2017-06-27; **收到修改稿日期:** 2017-07-09

**基金项目:** 国家自然科学基金(61472029, 61473031)、科技部国家重点研发计划(2016YFB1200100)、北京市自然科学基金(4152042)、中央高校基本科研业务费专项资金(2016JBZ005, 2016JBM019, 2016JBM016)

**作者简介:** 张哲(1993—), 女, 硕士研究生, 主要从事三维点云处理方面的研究。E-mail: 15120470@bjtu.edu.cn

**导师简介:** 许宏丽(1963—), 女, 博士, 教授, 主要从事信息检索、视频和图像处理、高维数据检索等方面的研究。

E-mail: hlxu@bjtu.edu.cn(通信联系人)

低,故常作为二次配准使用。

为了提高配准精度和配准效率,国内许多学者提出了许多其他方法<sup>[5-7]</sup>。其中,基于特征寻求对应关系的点云配准方法应用最为广泛。Rusu等<sup>[8]</sup>提出的快速点特征直方图(FPFH),相比于其他直方图特征<sup>[9-10]</sup>,其描述性强、特征维度低、计算速度快,广泛应用于点云配准中。但对于稠密点云,计算每个点的特征会严重影响点云配准的整体效率,并且稠密点云中包含大量特征相近的点云数据,影响不同视角下的点云对应点匹配。因此,需要考虑提取点云的关键点。现有的关键点特征提取方法有NARF特征、Harris特征等<sup>[11-12]</sup>,但 these 方法只适用于处理深度点云。对散乱点云的关键点检测,马骊溟等<sup>[13]</sup>提出先计算曲面片模型,利用梯度法搜索曲面上的高斯曲率极值点来提取点云的关键点;王丽辉等<sup>[14]</sup>将曲率和密度信息融合,实现对稀疏点云的准确关键点检测。这些方法描述性强,但模型存在较多参数,不同的参数值组合获得的关键点差别较大,若将其应用到配准中,不能保证配准算法的稳健性。陈西江等<sup>[15]</sup>通过法向量(NV)夹角局部熵的方法,将表面划分成不同特征区域,对不同区域的点云逐层精简。但该方法计算过于复杂,降低了关键点选择效率。

鉴于此,本文提出一种基于关键点选择的快速点云配准算法,构建一种基于法向量分布特征的关键点初始匹配,结合基于ICP的精确配准算法,构建两步点云配准算法。并且,从配准精度和配准效率等方面来验证该算法的有效性。

## 2 NV 关键点定义和选择

点云关键点提取是指从点云数据集中检测出具有较强表面形状描述性能的点。点云NV特征是描述点云局部区域几何表面形状的重要特征,能够准确地表现出区域姿态,因此,本文采用点云法向量分布特征来提取关键点并将其定义为NV关键点。

### 2.1 NV 特征定义

本文算法根据邻域的概念计算点云中探寻点 $P_i$ 的法向量。因此,对邻域的定义尤为重要。点云局部区域的近邻点分布可以体现探寻点表面特征和非特征区域,若探寻点与周围近邻点距离比较小,则为特征区域;反之,若近邻点分布比较稀疏,各点间距离较远,则为模型的平滑区域。此时,若仍考虑后者,很容易引入噪声点或影响局部特征正确性的点。

因此,本文将探寻点 $P_i$ 的近邻点定义为:以 $P_i$ 为中心、 $R$ 为半径的搜索空间包含的 $k_i$ 个与 $P_i$ 点欧氏距离最近的点,其中 $k_i$ 为点云在探索半径 $R$ 内的近邻点个数。设 $P_i$ 在 $R$ 内点云个数为 $N$ ,探寻近邻点个数 $k=7$ 。如图1所示,若 $N < k$ ,则只考虑 $R$ 内的点,即 $k_i = N$ ;否则,选取 $R$ 内距离 $P_i$ 最近的 $k$ 个点作为近邻点,即 $k_i = k$ 。




图1 点云数据。(a)  $k_i = 4$ ; (b)  $k_i = 7$

Fig. 1 Point cloud data. (a)  $k_i = 4$ ; (b)  $k_i = 7$

设 $\mathbf{n}_{P_i}$ 为点云中 $P_i$ 点的法向量,定义 $P_i$ 点的法向均值特征为 $v_N$ ,计算公式为

$$C = \frac{1}{k_i} (\mathbf{p}_i - \bar{\mathbf{p}}_i) \cdot (\mathbf{p}_i - \bar{\mathbf{p}}_i)^T, \quad (1)$$

$$C \cdot \mathbf{n}_{P_{ij}} = \lambda_j \cdot \mathbf{n}_{P_{ij}}, j \in \{1, 2, 3\}, \quad (2)$$

$$v_N = \frac{1}{k_i} \sum_{j=0}^{k_i^j} \arccos \left( \frac{\mathbf{n}_{P_i} \cdot \mathbf{n}_{P_i^j}}{\|\mathbf{n}_{P_i}\| \cdot \|\mathbf{n}_{P_i^j}\|} \right), \quad (3)$$

式中 $\mathbf{p}_i$ 表示 $P_i$ 的第 $i$ 个近邻点, $\bar{\mathbf{p}}_i$ 为 $P_i$ 点近邻元素的质心, $\lambda_j$ 是协方差矩阵的第 $j$ 个特征值, $\mathbf{n}_{P_{ij}}$ 是 $P_i$ 点

的第  $j$  个特征向量,  $k_i^j$  为  $k_i$  个近邻点中的第  $j$  个点的索引,  $n_{p_i}^{k_i^j}$  为  $P_i$  点在局部区域内的第  $k_i^j$  个近邻点的法向量,  $\|\mathbf{x}\|$  为向量  $\mathbf{x}$  的模长。

由于  $v_N$  是对邻近点的点云法向量夹角均值的描述, 只要空间  $P_i$  点与其近邻点之间的空间位置不变, 空间的缩放和旋转对  $P_i$  点与其近邻点之间的法向夹角特征就不变, 因此,  $v_N$  具有尺度不变性和旋转不变性。

使用  $v_N$  来描述该点所在区域特性, 若  $v_N$  较大则说明  $P_i$  点所在区域的几何特征变化较大, 在其近邻附近的点曲率变化较大, 存在突出的几何特征。反之, 若  $v_N$  较小则说明  $P_i$  点所在区域几何特征变化平缓, 该区域内点云的特征接近, 配准过程中容易相互干扰。因此, 可根据每个点的  $v_N$  表征该点所在区域的变化程度。

## 2.2 NV 关键点选择

$v_N$  的大小直接反映了其所在实物表面局部区域起伏情况, 因此可以利用  $v_N$  值来提取特征点。

首先计算每一个点的  $v_N$ , 其次根据输入点云集合  $P$  和  $Q$  的先验结构信息, 对  $v_N$  设置一个初始阈值  $\varepsilon_1$  与其比较, 若  $v_N < \varepsilon_1$ , 则表示所在区域起伏变化平缓, 特征不明显, 不作为特征点考虑; 反之, 若  $v_N \geq \varepsilon_1$ , 则表示该点与近邻点的法向量夹角均值较大, 特征明显, 将其作为提取的关键点。使用该  $\varepsilon_1$  值提取出关键点集合  $K_p$  和  $K_q$  进行初始匹配, 计算匹配的均方根误差  $E_{\varepsilon_1}$ , 并将其作为配准误差, 若此时配准误差不能满足约束条件(4)式, 则减小  $\varepsilon_1$  值, 重新计算相应的关键点及其均方根误差, 直到得到最优关键点集合  $\hat{K}_p$  和  $\hat{K}_q$ 。

$$\begin{cases} |E_{\varepsilon_1} - E_{\varepsilon_1 - 0.01}| \leq \delta \\ E_{\varepsilon_1} < \nabla \end{cases}, \quad (4)$$

其中,

$$\begin{cases} H_{pq}^{\varepsilon_1} = \{(x_{p_1}^{\varepsilon_1}, x_{q_1}^{\varepsilon_1}), (x_{p_2}^{\varepsilon_1}, x_{q_2}^{\varepsilon_1}), \dots, (x_{p_n}^{\varepsilon_1}, x_{q_n}^{\varepsilon_1})\}, x_{p_i}^{\varepsilon_1} \in K_p, x_{q_i}^{\varepsilon_1} \in K_q \\ E_{\varepsilon_1} = \sqrt{\frac{\sum_{i=0}^n (x_{p_i}^{\varepsilon_1} - x_{q_i}^{\varepsilon_1})^2}{n}} \end{cases}, \quad (5)$$

式中  $\delta$  为设定的配准误差收敛值,  $\nabla$  是允许的最大配准误差,  $H_{pq}^{\varepsilon_1}$  为阈值  $\varepsilon_1$  下点云关键点集合  $K_p$  和  $K_q$  中的对应点集合,  $(x_{p_i}^{\varepsilon_1}, x_{q_i}^{\varepsilon_1})$  为具体的对应点对,  $E_{\varepsilon_1}$  为阈值  $\varepsilon_1$  下的配准误差。

选择关键点的算法伪代码如下:

- 1) 输入:  $P = \{p_1, p_2, \dots, p_m\}, Q = \{q_1, q_2, \dots, q_m\}, k, R, \varepsilon_1$
- 2) 计算点云法向量
- 3) 构建  $k$ -d tree
- 4) do
- 5)     初始化  $K_p, K_q$
- 6)     for  $i = 1$  to  $m$
- 7)         计算点  $i$  与近邻点的法向夹角
- 8)         按(3)式计算  $v_N$  特征
- 9)         if  $v_N > \varepsilon_1$
- 10)             更新关键点集合  $K_p, K_q$
- 11)         end if
- 12)     end for
- 13)     基于关键点  $K_p, K_q$  的初始配准, 得到对应点对
- 14)     按(5)式计算  $E_{\varepsilon_1}, \varepsilon_1 = \varepsilon_1 - 0.01$
- 15) while  $\text{abs}(E_{\varepsilon_1 + 0.02} - E_{\varepsilon_1 + 0.01}) \leq \delta$
- 16) 输出:  $\hat{K}_p = \{k_{p1}, k_{p2}, \dots, k_{pl}\}, \hat{K}_q = \{k_{q1}, k_{q2}, \dots, k_{ql}\}$

分别对待配准点云和参考点云选择关键点, 并将获取的关键点称为 NV 关键点。

### 3 基于 NV 关键点的点云配准算法

点云配准的关键是确定合适的坐标变换,将待配准点云和参考点云统一到同一个坐标系下,构成完整的点云数据。基于关键点选择的快速点云配准算法分为初始配准和精确配准,其流程如图 2 所示。

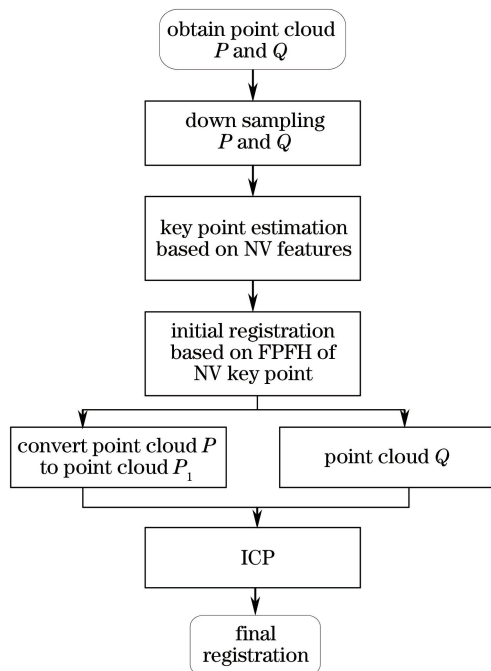


图 2 基于关键点选择的快速点云配准算法流程图

Fig. 2 Overview of the fast point cloud registration algorithm based on key point selection

首先,利用激光扫描仪或三维相机获取多个视角下的三维点云数据。设待配准点云为  $P$ ,参考点云为  $Q$ ,对于庞大的点云数据,在点云配准前,使用体素网格滤波器实现点云下采样,选取重心点最近邻来代替栅格区域内部其他点云数据,以保证点云化简后的真实性。

计算化简后点云的 NV 特征,并基于 NV 特征选择关键点。NV 关键点集合能较好地表征整个点云的真实形状特征,但可能丢失一些细节信息。FPFH 特征通过参数化查询点云与近邻点的空间差异,形成一个多维统计特征直方图,该描述子可以较好地捕捉点云局部区域变化情况。因此,将 NV 关键点与 FPFH 相结合能够加强点云的特征描述能力,保证配准精度。

算法步骤如下:

1) 计算每个 NV 关键点  $P_i$  与其近邻点  $P_k$  组成的参数三元组  $(\alpha, \varphi, \theta)$ ,建立  $P_i$  与其近邻点  $P_k$  之间的  $UVW$  局部坐标系,如图 3 所示,得到简化点特征直方图(SPFH)。




图 3  $UVW$  局部坐标系

Fig. 3  $UVW$  local coordinate system

图 3 中  $(u, v, w)$  为



$$\begin{cases} u = N \\ v = u \times \frac{(P_i - P_k)}{d}, \\ w = u \times v \end{cases} \quad (6)$$

那么,三元组 $(\alpha, \varphi, \theta)$ 可以表示为

$$\begin{cases} \alpha = v \cdot N \\ \varphi = u \cdot \frac{P_i - P_k}{d} \\ \theta = \arctan(w \cdot N, u \cdot N) \end{cases}, \quad (7)$$

式中  $d$  表示  $P_i$  和  $P_k$  之间的欧氏距离  $\|P_i - P_k\|$ 。

2) 在 NV 关键点  $P_i$  的近邻内,计算每一个近邻点的 SPFH 特征,得到最终的 FPFH,即

$$\text{FPFH}(P_i) = \text{SPFH}(P_i) + \frac{1}{k} \sum_{i=1}^k \left[ \frac{1}{w_k} \times \text{SPFH}(P_k) \right], \quad (8)$$

式中  $w_k$  为权值,表示近邻点  $P_k$  与 NV 关键点  $P_i$  之间的距离对关键点的影响范围。

分别计算  $P$  和  $Q$  集合中 NV 关键点的 FPFH 特征,使用采样一致性配准算法(SAC-IA)获取旋转矩阵  $\mathbf{R}$  和平移矢量  $\mathbf{T}$ ,将  $P$  转换到  $P_1$ ,完成点云的初始配准。最后,使用钟莹等<sup>[2]</sup>提出的改进 ICP 算法完成  $P_1$  到  $Q$  的精确配准。

## 4 实验结果

### 4.1 散乱点云数据配准实验

为验证本文算法对散乱点云数据的有效性,选用斯坦福 Bunny、Dragon 以及 Happy 数据集来说明本文算法的配准过程。将不同视角下的点云数据 bun1 和 bun2、drag1 和 drag2、hap1 和 hap2 分别作为待配准点云和参考点云,可视化结果如图 4 所示。




图 4 点云可视化。(a) Bun1 和 bun2;(b) drag1 和 drag2;(c) hap1 和 hap2

Fig. 4 Point cloud visualization. (a) Bun1 and bun2; (b) drag1 and drag2; (c) hap1 and hap2

原始数据及下采样数据等的点云个数如表 1 所示。

表 1 点云个数比较

Table 1 Comparison of number of point cloud

Item	bun1	bun2	drag1	drag2	hap1	hap2
Original	40097	40256	41841	43467	78056	75583
Down sampling	11114	11607	11523	12154	9259	8664
NV key point	4847	4133	3708	4731	4404	4678

#### 4.1.1 选择 NV 关键点

首先,使用下采样后的数据集 bun1 和 bun2 来说明 NV 特征中对阈值  $\epsilon_1$  的设置。阈值  $\epsilon_1$  直接决定着提取关键点的个数,影响初始配准的时间和配准误差。设置不同的  $\epsilon_1$  值,得到其与初始配准时间和配准误差的变化曲线如图 5 所示。可以看出,随着  $\epsilon_1$  值的减小,剩余的 NV 关键点个数逐渐增加,计算剩余点的特

征计算时间变长,总的初始配准时间持续上升。而配准误差的变化表现为下降趋势,当 $\epsilon_1 < 0.11$ 时,配准误差曲线变化趋于平稳。

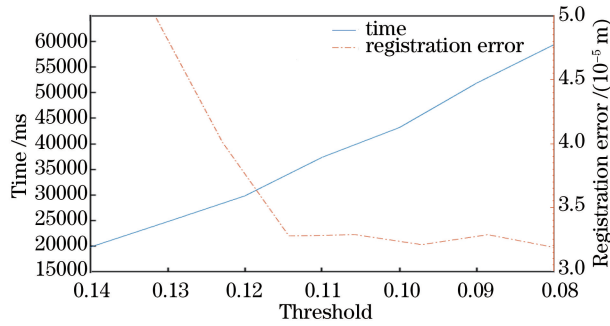


图5 阈值 $\epsilon_1$ 与初始配准时间和配准误差变化曲线

Fig. 5 Initial registration time and registration error changed with  $\epsilon_1$

综合考虑 NV 特征对配准时间和配准精度的影响,选取图 5 中配准误差曲线的近似收敛处为设置的 $\epsilon_1$ 值,即 $\epsilon_1 = 0.11$ ,得到 bun1 的 NV 关键点示意图,如图 6(b)所示。同理,将 Happy 和 Dragon 数据集的阈值 $\epsilon_1$ 分别设为 0.08 和 0.06,得到的 NV 关键点个数见表 1 所示,可视化结果如图 6(d)、图 7(b)和图 7(e)所示。使用王丽辉等<sup>[14]</sup>提出的特征提取算法分别对 drag1、drag2 提取关键点,结果如图 7(c)、(f)所示。由于使用到了不同的点云数据集,需要重新考虑距离、曲率、夹角等条件对判别关键点的约束。因此,如何设置多个参数的复杂组合成为了一个难题,另外,由此带来的繁杂计算也降低了提取效率。相比而言,本文只考虑法向量分布特征的约束,算法简单、计算量小,并对不同视角的点云数据集具有一定的稳健性。本文对点云数据集提取得到的 NV 关键点集,既包括非边缘区域的关键点也包括边缘关键点,能较好地表征整个点云的真实形状特征,因此,将提取的 NV 关键点替代原始点云数据集,在初始配准中使用。




图6 (a) Bun1 原始点云;(b) bun1 NV 关键点;(c) hap1 原始点云;(d) hap1 NV 关键点

Fig. 6 (a) Original point cloud of bun1; (b) NV key points of bun1; (c) original point cloud of hap1; (d) NV key points of hap1

#### 4.1.2 基于 NV 关键点的快速配准实验

将本文算法应用于点云 Bunny、Dragon 和 Happy,初始配准结果如图 8(a)~(c)所示,初始配准误差分别为 $3.27605 \times 10^{-5}$ , $1.20518 \times 10^{-5}$ , $2.06316 \times 10^{-5}$  m。

为了进一步验证本文算法的有效性,对基于 NV 关键点的初始配准(NV-FPFH-SAC-IA)与直接使用 FPFH 的初始配准(FPFH-SAC-IA)的结果进行对比。统计结果如表 2 所示。

由表 2 可知,相比于直接使用 FPFH 的初始配准算法,本文算法优化了初始点云数据,克服了特征相近的点求取对应点的干扰。在迭代次数相同的情况下,不仅保证了配准精度,而且明显减少了配准耗时,显著提高了配准效率。

完成初始配准后,再使用 ICP 精确配准,最终完成基于关键点选择的快速点云配准算法,其结果如图 8(d)~(f)所示,配准误差分别为 $1.48438 \times 10^{-5}$ , $8.0666 \times 10^{-6}$ , $9.72895 \times 10^{-6}$  m。对于 Bunny、Dragon 和 Happy 点云数据集,直接使用 ICP 算法的单步配准,得到的配准误差分别为 $1.62231 \times 10^{-5}$ , $7.72603 \times 10^{-5}$ , $1.28465 \times 10^{-5}$  m。可以看出,本文算法相比于单步配准算法,配准结果更加精确。




图 7 (a) Drag1 原始点云;(b) drag1 NV 关键点;(c)文献[14]算法提取的 drag1 关键点;  
(d) drag2 原始点云;(e) drag2 NV 关键点;(f)文献[14]算法提取的 drag2 关键点  
Fig. 7 (a) Original point cloud of drag1; (b) NV key points of drag1; (c) key points of drag1 obtained  
by the algorithm in Ref. [14]; (d) original point cloud of drag2; (e) NV key points of drag2;  
(f) key points of drag2 obtained by the algorithm in Ref. [14]




图 8 点云配准结果。(a) Bunny 初始配准;(b) Dragon 初始配准;(c) Happy 初始配准;  
(d) Bunny 精确配准;(e) Dragon 精确配准;(f) Happy 精确配准

Fig. 8 Registration results of point cloud. Initial registration results of (a) Bunny, (b) Dragon and (c) Happy;  
accurate registration results of (d) Bunny, (e) Dragon and (f) Happy

表 2 初始配准结果比较

Table 2 Comparison of initial registration results

Algorithm	Dataset	Registration point cloud number	Reference point cloud number	Number of iterations	Time /ms	First registration error /( $10^{-5}$ m)
NV-FPFH-SAC-IA	(bun1 ,bun2)	4847	4133	100	37296	3.27605
FPFH-SAC-IA	(bun1 ,bun2)	11114	11607	100	118310	10.0778
NV-FPFH-SAC-IA	(drag1 ,drag2)	3708	4731	100	120192	1.20518
FPFH-SAC-IA	(drag1 ,drag2)	11523	12154	100	519484	0.893576
NV-FPFH-SAC-IA	(hap1 ,hap2)	4404	4678	100	138930	2.06316
FPFH-SAC-IA	(hap1 ,hap2)	9259	8664	100	376389	2.3366

## 4.2 自获取深度点云数据配准实验

为验证本文算法的普适性,使用 Kinect 2.0 获取两片真实点云深度图像,如图 9 所示。进一步验证本文算法的有效性。图 9(a)为获取的两片真实稠密点云数据,个数分别为 679779 和 512678。

### 4.2.1 选择 NV 关键点

首先,经滤波去除背景和噪声,使用基于体素网格滤波器的点云下采样方法简化点云,得到下采样后的点云数目分别为 119756 和 93214。选取 NV 特征的阈值  $\epsilon_1 = 0.12$ ,得到 NV 关键点的数目为 67893 和 65486,如图 9(b)、(c)所示。




图 9 使用 Kinect 2.0 获取的点云数据。(a)原始点云;(b)视角 1 下 NV 关键点;(c)视角 2 下 NV 关键点

Fig. 9 Point cloud data sensed by Kinect 2.0. (a) Original point cloud;

(b) NV key points in view 1; (c) NV key points in view 2

### 4.2.2 基于 NV 关键点的快速配准实验

将本文算法应用于真实深度点云数据,使用基于 NV 关键点的初始配准算法,配准结果如图 10(a)所示,配准误差为  $9.29124 \times 10^{-3}$  m,而直接使用 FPFH 的初始配准算法的配准误差为  $9.97191 \times 10^{-3}$  m。说明了在真实深度点云数据中,本文算法可以克服特征相近点的干扰,在迭代次数相同的情况下,保证配准精度,完成初始配准。

进一步再使用 ICP 算法完成精确配准后,配准误差为  $1.11756 \times 10^{-4}$  m,配准结果如图 10(b)所示。若直接使用 ICP 算法单步配准,由于初始位置相差较大,并且两片点云数据中有重叠区域,配准误差陷入局部极小值,导致配准错误,配准误差为  $2.22907 \times 10^{-2}$  m。

综上,基于关键点选择的快速点云配准算法全面考虑了点云的空间特征,应用在深度点云数据的配准中,有效地解决了配准错误问题,保证了配准精度,有力地验证了本文算法的普适性。




图 10 配准结果。(a)初始配准;(b)精确配准

Fig. 10 Registration results. (a) Initial registration; (b) accurate registration

## 5 结 论

针对三维点云配准效率问题,提出一种基于关键点选择的快速点云配准算法。该算法对关键点的提取方法简单,计算速度快,选择的关键点集合能较好地表征整个点云的真实形状特性,适用于不同类型点云数据的关键点提取。该算法将提取的关键点作为初始配准的重要依据,能够加强点云的特征描述能力,减轻稠密点云数据对点云配准的不利影响,保证配准结果的正确性。实验证明,该算法在提高效率的同时,还能实

现不同类型点云数据的高精度配准。

### 参 考 文 献

- [1] Besl P J. A method for registration of 3D shapes[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 1992, 14(3): 239-256.
- [2] Zhong Ying, Zhang Meng. Automatic registration technology of point cloud based on improved ICP algorithm[J]. Control Engineering of China, 2014, 21(1): 37-40.  
钟莹, 张蒙. 基于改进 ICP 算法的点云自动配准技术[J]. 控制工程, 2014, 21(1): 37-40.
- [3] Yang J, Li H, Campbell D, *et al.* Go-ICP: a globally optimal solution to 3D ICP point-set registration[J]. IEEE Transactions on Pattern Analysis & Machine Intelligence, 2016, 38(11): 2241-2254.
- [4] Zeng Fanxuan, Li Liang, Diao Xinpeng. Iterative closest point algorithm registration based on curvature features[J]. Laser & Optoelectronics Progress, 2017, 54(1): 011003.  
曾繁轩, 李亮, 刁鑫鹏. 基于曲率特征的迭代最近点算法配准研究[J]. 激光与光电子学进展, 2017, 54(1): 011003.
- [5] Chen Maolin, Lu Weixin, Wan Youchuan, *et al.* Automatic registration of terrestrial point clouds without additional information[J]. Chinese J Lasers, 2016, 43(4): 0414003.  
陈茂霖, 卢维欣, 万幼川, 等. 无附加信息的地面激光点云自动拼接方法[J]. 中国激光, 2016, 43(4): 0414003.
- [6] Lu Jun, Peng Zhongtao, Xia Guihua. Point cloud registration algorithm based on neighborhood features of multi-scale normal vectors[J]. Journal of Optoelectronics • Laser, 2015(4): 780-787.  
陆军, 彭仲涛, 夏桂华. 点云多法向量邻域特征配准算法[J]. 光电子 • 激光, 2015(4): 780-787.
- [7] He F, Ayman H. A closed-form solution for coarse registration of point clouds using linear features[J]. Journal of Surveying Engineering, 2016, 142(3): 04016006.
- [8] Rusu R B, Blodow N, Beetz M. Fast point feature histograms (FPFH) for 3D registration[C]. IEEE, 2009: 3212-3217.
- [9] Rusu R B, Blodow N, Marton Z C, *et al.* Aligning point cloud views using persistent feature histograms[C]. IEEE, 2008: 3384-3391.
- [10] Tombari F, Salti S, Stefano L D. Unique signatures of histograms for local surface description[J]. Lecture Notes in Computer Science, 2010, 6313: 356-369.
- [11] Bastian S, Rusu R B, Konolige K, *et al.* NARF: 3D range image features for object recognition[C]. Workshop on Defining and Solving Realistic Perception Problems in Personal Robotics at the IEEE/RSJ Int. Conf. on Intelligent Robots and Systems (IROS), 2010: 44.
- [12] Zhang Y, Yu H Y. 3D point cloud registration based on the assistant camera and Harris-SIFT [C]. International Workshop on Pattern Recognition, 2016, 10011: 100110U.
- [13] Ma Liming, Xu Yi, Li Zexiang. Extracting feature points for scattered points based on Gauss curvature extreme point [J]. Journal of System Simulation, 2008, 20(9): 2341-2344.  
马骊溟, 徐毅, 李泽湘. 基于高斯曲率极值点的散乱点云数据特征点提取[J]. 系统仿真学报, 2008, 20(9): 2341-2344.
- [14] Wang Lihui, Yuan Baozong. Feature point detection for 3D scattered point cloud model[J]. Signal Processing, 2011, 27(6): 932-938.  
王丽辉, 袁保宗. 三维散乱点云模型的特征点检测[J]. 信号处理, 2011, 27(6): 932-938.
- [15] Chen Xijiang, Zhang Guang, Hua Xianghong. Point cloud simplification based on the information entropy of normal vector angle[J]. Chinese J Lasers, 2015, 42(8): 0814003.  
陈西江, 章光, 花向红. 于法向量夹角信息熵的点云简化算法[J]. 中国激光, 2015, 42(8): 0814003.