

# 基于多尺度特征及点距离约束的点云配准

张旭春<sup>1</sup>, 周洪军<sup>2</sup>, 郑津津<sup>1\*</sup>, 金一<sup>1\*\*</sup>

<sup>1</sup>中国科学技术大学精密机械与精密仪器系, 安徽 合肥 230026;

<sup>2</sup>中国科学技术大学国家同步辐射实验室, 安徽 合肥 230027

**摘要** 已有匹配算法对低重叠度点云的配准精度较低,且对不同尺度的点云比较敏感,为了达到较好的配准效果,需要对点云进行预处理或调节较多参数。快速点特征直方图(FPFH)的复杂度较低,且能保留点云的大部分特征,因此,基于点云的 FPFH 提出了一种改进的配准算法。首先,基于 FPFH 提取多尺度特征的关键点,以适应不同规模的点云数据集,同时降低需要调节的参数数量。然后,对经过 FPFH 匹配初步筛选的对应点关系进行精确提取,增加点云内的距离约束条件,降低算法对重叠度的敏感性,获取配准的初步变换矩阵。最后,经过迭代最近点算法进行微调,达到精确配准的目的。实验结果表明,该算法在不同重叠度以及不同规模的点云数据集上均具有较好的配准精度。

**关键词** 机器视觉; 点云配准; 快速点特征直方图; 迭代最近点; 欧氏距离

中图分类号 TP391.9

文献标志码 A

doi: 10.3788/LOP202158.2415004

## Point Cloud Registration Based on Multi-Scale Feature and Point Distance Constraint

Zhang Xuchun<sup>1</sup>, Zhou Hongjun<sup>2</sup>, Zheng Jinjin<sup>1\*</sup>, Jin Yi<sup>1\*\*</sup>

<sup>1</sup>Department of Precision Machinery and Precision Instrumentation, University of Science and Technology of China, Hefei, Anhui 230026, China;

<sup>2</sup>National Synchrotron Radiation Laboratory, University of Science and Technology of China, Hefei, Anhui 230027, China

**Abstract** The existing matching algorithm has a low registration accuracy of point clouds with low overlap, and is more sensitive to different scales. In order to achieve a better registration effect, it is necessary to preprocess or adjust more parameters to the point cloud. Fast point feature histogram (FPFH) has a low complexity, and retains most of the features of the point cloud. Therefore, we propose an improved registration algorithm based on FPFH of the point cloud. First, extracting key points with multi-scale features based on FPFH to adapt to different scales point cloud datasets, while reducing the number of parameters that require adjustment. Then, the corresponding point relationship after the initial screening of FPFH matching is accurately extracted, the distance constraint condition in the point cloud is added, which reduces sensitivity of the algorithm to overlap and the preliminary transformation matrix of registration is obtained. Finally, the iterative closest point algorithm is subjected to fine-tuning to achieve the purpose of accurate registration. The experimental results show that the algorithm has good registration accuracy on different overlap and different scales of point cloud datasets.

**Key words** machine vision; point cloud registration; fast point feature histogram; iterative closest point; Euclidean distance

**OCIS codes** 150.6910; 110.6880; 100.6890

收稿日期: 2021-01-03; 修回日期: 2021-02-09; 录用日期: 2021-03-03

基金项目: 国家自然科学基金联合基金(U1713206)、国家自然科学基金重大科研仪器研制项目(61727809)

通信作者: \*jjzheng@ustc.edu.cn; \*\*jinyi08@ustc.edu.cn

# 1 引言

三维扫描技术的发展,使点云配准技术广泛应用于反求测量、三维模型重建、点云目标定位等领域。点云配准的目的是找到一个三维刚体变换,将同一物体在不同视角下的两片或多片点云变换至同一坐标系下,从而将其匹配为完整的点云模型。传统点云配准算法的步骤包括输入待配准点云、滤波、提取关键点、关键点特征描述、关键点匹配、去除错误点对以及精确配准。

经典的迭代最近点(ICP)算法<sup>[1]</sup>在两片待配准点云中寻找欧氏距离最近的点,并以此为对应关系求解变换矩阵,不断迭代直到误差符合预期值。但该算法对点云的初始位姿有一定要求,当位姿差异较大时,很难进行正确匹配,且容易陷入局部最优情况<sup>[2]</sup>。因此,人们在 ICP 算法的基础上研究了多种改进算法,如 Segal 等<sup>[3]</sup>提出一种广义 ICP(GICP)算法,降低了不正确对应关系对匹配结果的影响,提高了匹配精度;Yang 等<sup>[4]</sup>提出了全局最优 ICP(GoICP)算法,将分支界定与 ICP 融合,保证了全局最优;赵夫群<sup>[5]</sup>在粗配准中增加几何哈希变化并在 ICP 算法中增加迭代因子,提高了算法的收敛速度;王勇等<sup>[6]</sup>提出了一种多分辨率 ICP(MR-ICP)算法,通过引入多分辨率匹配点对提高匹配精度与速度。ICP 算法由最初的点对点对应关系,逐渐扩展到点对线(Point to line)<sup>[7]</sup>、点对面(point to plane)<sup>[8]</sup>等对应关系,且都取得了很好的配准效果,一定程度上弥补了 ICP 算法的局限性。此外,点云配准领域也出现了很多脱离 ICP 算法的配准技术,如 Aiger 等<sup>[9]</sup>提出的四点全等集(4PCS)算法用四点构建特征查找匹配关系,并在此基础上提出了 Super-4PCS<sup>[10]</sup>算法;唐志荣等<sup>[11]</sup>提出了多维混合柯西分布(MMC)算法,提高了配准算法的鲁棒性;Zhou 等<sup>[12]</sup>构建了一种基于体素的加权二维描述子(VBBD),并结合 KM(Kuhn-Munkres)算法进行匹配,鲁棒性较高;Le 等<sup>[13]</sup>提出了基于半正定的随机采样方法,提高了配准精度;李昌华等<sup>[14]</sup>结合卷积神经网络和改进的哈里斯-尺度不变特征变换(Harris-SIFT),提高了配准效率;詹旭等<sup>[15]</sup>提出了一种基于余弦相似度的配准算法,解决了干扰和数据丢失问题。这些算法均从独特的角度对点云特征进行处理,寻找点云之间的对应关系,提高了算法的配准精度和鲁棒性。上述大部分算法对不同重叠度的点云配准效果不佳,且对于不同尺寸的点云,需要进行预

处理或重复调节较多参数;部分算法对点云数据集的敏感度较高,对不同数据集的配准效果不同。

为了提高不同重叠度以及不同尺寸规模的点云配准精度,本文基于快速点特征直方图(FPFH)<sup>[16]</sup>提出了一种参数调节简单的多尺度特征关键点提取算法,并改进了基于 FPFH 寻找对应关系的方法,用 ICP 算法进行微调,使算法在小规模数据集上取得了符合预期的配准精度。此外,还关注了不同重合度的点云配准以及大场景环境点云的配准。实验结果表明,本算法在不同点云数据集上均能取得很好的配准效果。

## 2 多尺度特征关键点的提取

通常认定目标点云保持不动,将源点云进行变换,则对于点数为  $N$  的源点云( $X$ )和点数为  $M$  的目标点云( $Y$ ),配准后的旋转变换矩阵为  $\mathbf{R}$ ,平移变换矩阵为  $t$ 。常用的点云配准误差度量方法为平方距离误差  $E(\mathbf{R}, t)$ ,可表示为

$$E(\mathbf{R}, t) = \sum_{i=1}^N \|\mathbf{R}\mathbf{x}_i + t - \mathbf{y}_{j^*}\|^2, \quad (1)$$

式中,  $\mathbf{x}_i$  为点云  $X$  中的点,  $\mathbf{y}_{j^*}$  为变换后  $Y$  点云中与  $\mathbf{x}_i$  距离最近的点,可表示为

$$\mathbf{y}_{j^*} = \operatorname{argmin}_{j \in \{1, \dots, M\}} \|\mathbf{R}\mathbf{x}_i + t - \mathbf{y}_j\|. \quad (2)$$

点云的关键点指能表示点云模型表面基本形状的特征点或点云内部特征差异较大的点。提取关键点的过程近似于对原始点云依据特征进行下采样,关键点的提取效果在一定程度上影响着配准效果。常用的关键点提取方法有三维哈里斯(Harris 3D)<sup>[17]</sup>、三维尺度不变特征变换(SIFT 3D)<sup>[18]</sup>、内部形状签名(ISS)<sup>[19]</sup>等方法,但这些方法需要调节的参数较多,如 SIFT 3D 方法在 PCL(Point cloud library)<sup>[20]</sup>环境下实现需要调节四个参数。在输入不同尺寸规模的点云时,需要调节的参数过多会增加关键点提取的难度。文献[12]对比几种关键点提取方法发现,为了达到最佳关键点提取效果,不同的点云模型需要用不同的提取方法。文献[21]提出了一种基于邻域内平均 FPFH 的关键点提取方法,提取效果较好,但该方法仍旧是基于单一尺度的算法。因此,基于 FPFH 提出了一种多尺度特征关键点提取算法,既能保证提取到的点云数量,也能保证点云完整的几何特征,同时易于调参,降低了算法对点云规模的敏感度。

### 2.1 FPFH 的原理

FPFH 描述子是一种常用的点特征表示法,采

用特征直方图形式描述局部点的区域特征,进而减少全局特征,降低特征提取的复杂度。同时,FPFH 保留了大部分的点云特性,特征识别效果较好,在点云配准领域得到了广泛应用。文献[22]研究了几种传统配准方法的效果,结果表明,基于 FPFH 的配准效果在整体上具有较高的精度和效率。FPFH 描述子的基本计算步骤如下。

1) 构建邻域。方法一:假定点云中的一点为中心点,以该点为圆心,构造圆球形区域,该区域内的点即为该中心点的邻域点;方法二:用  $K$  维树在点云中寻找距离中心点最近的  $K$  个点,用这  $K$  个点组成中心点的邻域点。

2) 参数化中心点与其邻域点之间的空间差异,对局部区域内的中心点 ( $p_q$ ) 及其邻域点 ( $p_k$ ) 之间的角度三元组 ( $\alpha, \theta, \Phi$ ) 进行描述,并将中心点与其所有邻域点间的三元组以统计方式建立多维直方图,即  $p_q$  的简化点特征直方图 (SPFH),如图 1 所示。其中,  $n_q$  为  $p_q$  的法向量,  $n_k$  为  $p_k$  的法向量,  $d$  为  $p_q$  到  $p_k$  的距离向量,  $u, v, w$  是由  $n_q$  和  $d$  定义的局部坐标系。




图 1 SPFH 的原理

Fig. 1 Principle of the SPFH

3) 重新确定  $p_q$  的邻域,并用其邻域点  $p_k$  的 SPFH 特征计算最终  $p_q$  点的 FPFH,可表示为

$$X_{FPFH}(p_q) = X_{SPFH}(p_q) + \frac{1}{k} \sum_{i=1}^k \frac{1}{\omega_k} X_{SPFH}(p_k), \quad (3)$$

式中,  $X_{FPFH}$  为点的 FPFH,  $X_{SPFH}$  为点的 SPFH,  $\omega_k$  为中心点  $p_q$  和  $p_k$  之间的欧氏距离,  $k$  为邻域点的数量。

### 2.2 基于 FPFH 的多尺度特征关键点提取

FPFH 仅表征了点云一个局部邻域内的表面信息,为了将其扩展到多个尺度,提出了一种基于 FPFH 的多尺度特征关键点提取算法,具体步骤如下。

1) 对于一片点云中的点,计算中心点  $p$  局部邻域的 FPFH,邻域半径为  $2d$ 。其中,  $d$  为整个点云

中的点与其最近点之间欧氏距离的平均值。

2) 定义  $n$  个环形尺度,尺度 1 ( $n_1$ ) 为距离中心点  $d$  到  $2d$  的环形范围,尺度 2 ( $n_2$ ) 为距离中心点  $2d \sim 3d$  的环形范围,如图 2 所示。




图 2 中心点  $p$  的邻域尺度

Fig. 2 Neighbor scale of center point  $p$

3) 计算每个环形尺度内所有点的平均 FPFH (mFPFH),得到  $n$  个 mFPFH。

4) 对中心点  $p$  计算每相邻两个尺度之间 mFPFH 的欧氏距离,得到全部欧氏距离的标准偏差  $\sigma$ ,该标准偏差即是在多尺度下确定的特征值。

5) 提取关键点,设定阈值  $\sigma_1$ ,将  $\sigma$  在阈值范围内的中心点保留为关键点,该关键点保持了周围球形区域的多尺度特征,也被称为多尺度特征点。

该算法考虑了中心点  $p$  周围更广泛区域(从中心点向外  $n$  个尺度)的特征变化情况。若  $\sigma$  值较小,表明点云表面变化平缓;反之,则表明点云表面变化剧烈。选取邻域半径时,本算法考虑了点云数据内点之间的平均距离,可根据不同数据集自适应调整参数,且仅需调整参数  $\sigma_1$ 。相比大多数只选取单一尺度特征的算法,本算法综合了中心点附近多个尺度的差异性,对点云规模的敏感度较低。不同规模点云在三维坐标上的体现是点间的距离不同,大规模点云的点间距离通常较大,小规模点云的点间距通常较小。因此,计算局部特征时需要考虑邻域大小,而邻域大小受到点云规模的影响,文献[21]的研究表明,邻域搜索范围会影响特征点的提取。本算法以点云中点间的平均距离为尺度和邻域划分标准,同时考虑了尺度间的特征差异,不需要调节邻域大小,一定程度上降低了点云规模对特征提取的影响。

### 3 特征及关键点匹配

在点云配准中,两片点云之间的正确对应关系



对配准精度具有重要作用。传统算法一般通过匹配点的邻域特征寻找对应点对,以此确定对应关系,然后求出变换矩阵。但当点云的点数较多、尺寸较大时,会出现不同区域点云特征相似的情况,错误的匹配点对数量增多,需要额外进行去除误匹配点对的操作。此外,对于重叠度低的点云,正确匹配点对的比例较低,依靠特征寻找对应点对时,误匹配点对的比例更高。因此,本算法结合点特征匹配增加了距离约束条件,提高了点云粗配准的精度,对较低重叠度点云的配准精度也较高。

### 3.1 FPFH 特征匹配

分别提取源点云和目标点云的关键点,得到 2 组关键点云  $src\_keys$  和  $tgt\_keys$ 。计算每个点的 FPFH 并进行初步匹配,特征的相似度用两个 FPFH 的欧氏距离度量,距离越小,表明特征越相似,从而找到初步对应关系,欧氏距离  $d$  可表示为

$$d = \sqrt{\sum_{k=1}^n [X_{src}^{FPFH}(k) - X_{tgt}^{FPFH}(k)]^2}, \quad (4)$$

式中,  $n$  为 FPFH 的维度,  $X_{src}^{FPFH}(k)$  为  $src\_keys$  中点的 FPFH,  $X_{tgt}^{FPFH}(k)$  为  $tgt\_keys$  中点的 FPFH。文献[23]在源点云和目标点云之间搜索特征最相似的点对,以确定对应关系,通过随机采样一致(RANSAC)算法[24]可以初步得到正确对应关系。但只根据点特征匹配得到的点对对应关系存在较多错误匹配,根据变换矩阵确定的内点数量过多,从而增加了一些没有必要的计算。因此,采用相互搜索方法并在 FPFH 匹配寻找对应点对的基础上增加新的约束,减少了非必要的计算过程,从而确定正确对应关系。

### 3.2 距离约束条件

对于两片点云,设源点云中点  $x_i$  和目标点云中点  $y_i$  为初步确定的对应点对,且在理想条件下对应关系是正确的,则

$$d_{x_1x_2} - d_{y_1y_2} = d_{x_1x_3} - d_{y_1y_3} = d_{x_2x_3} - d_{y_2y_3} = 0, \quad (5)$$

式中,  $d_{x_1x_2}$  为  $x_1$  和  $x_2$  两点间的欧氏距离。可以发现,由 3 组匹配点对就能确定两片点云之间的变换矩阵,即初步配准变换矩阵。同一点云内,无论点云位置如何变换,其内部任意固定两点之间的距离总是不变的,因此可将两点间的距离作为特征约束。此外,该算法只需选取一片点云内的三个点,所需点数量少且对整体点云的点分布没有任何要求。即使两片点云的重合度较低,也可以在重叠的局部区域

内找到点对进行匹配,降低了配准对点云重叠度的敏感度。对于输入点云的尺寸规模,不需要考虑点数量和点间距,都能得到两片点云中存在的 3 组正确匹配点。由(5)式可知,对应点之间距离的差值总是趋于 0,即该约束条件对输入点云尺寸规模的敏感度也较低。

图 3 为关键点的匹配原理,  $src\_match$  和  $tgt\_match$  根据 FPFH 相互搜索后,确定两片对应点云。其中,虚线表示 FPFH 匹配,实线表示欧氏距离。两片点云中每次选取 3 组对应点,并根据(5)式判断 3 组点是否正确对应。当距离差值均小于阈值时,认为对应关系近似正确,计算变换矩阵,然后将源点云通过变换矩阵进行变换,再根据(1)式得到初步配准误差。若误差小于预期值,则认为对应关系正确,迭代结束;否则,重新选取 3 组对应点进行迭代。迭代结束后得到点云的初步变换矩阵,即粗配准结果。




图 3 关键点的匹配原理

Fig. 3 Matching principle of key points

### 3.3 点云配准的微调

经过特征及关键点匹配得到精度较高的初步变换矩阵,变换后的源点云和目标点云的匹配精度已经达到较高水平。虽然 ICP 算法在点云位姿差异过大时基本无法得到正确配准点对,且容易陷入局部最优情况,但对于匹配度较高的点云,两片点云的位姿基本保持一致,ICP 算法的适用性较强,精度也较高,可用于微调部分。因此,选用 ICP 算法进行微调,完整的配准流程:1)输入待配准的源点云和目标点云;2)基于 FPFH 的多尺度特征提取关键点,得到两片关键点云;3)根据 FPFH 匹配和距离约束条件确定两片点云之间的对应关系;4)由步骤 3)中得到的对应关系确定初步变换矩阵;5)用 ICP 算法对初步配准后的两片点云进行微调,确定精确变换矩阵。

## 4 实验结果与分析

本算法在 C++ 及 PCL 1.8.1 环境下实现,用 The Stanford 3D Scanning Repository<sup>[25]</sup> 数据集和 Redwood 3D Dataset<sup>[26]</sup> 验证算法的配准精度。首

先,用本算法对 The Stanford 3D Scanning Repository 数据集中的四个点云模型 Bunny、Armadillo、Buddha 和 Dragon 片段进行配准;然后,以 Bunny 模型中的三片点云片段为例,与部分点云配准算法进行对比实验;最后,将本算法应用到 Redwood 3D Dataset 中,验证其在较大场景规模环境点云配准中的效果。配准精度的度量指标均为点云之间的均方根距离误差。

#### 4.1 点云片段的配准

The Stanford 3D Scanning Repository 数据集中每片点云的点数相对较少,实验选取的点云片段

表 1 The Stanford 3D Scanning Repository 数据集中部分点云模型的片段尺寸

Table 1 Size of partial segments of point cloud models in The Stanford 3D Scanning Repository dataset

Serial number	Point cloud model	Segments of model	Number of points
1	Bunny	bun000	40256
		bun045	40097
2	Armadillo	armadilloSide_60	23404
		armadilloSide_45	20647
3	Buddha	happySideRight_336	68890
		happySideRight_312	57499
4	Dragon	dragonStandRight_336	43467
		dragonStandRight_288	24573




图 4 本算法的点云配准结果。(a)原始点云;(b)关键点;(c)匹配点对及对应关系;(d)配准结果

Fig. 4 Point cloud registration result of our algorithm. (a) Original point cloud; (b) key points; (c) matching points and corresponding relations; (d) results of registration

尺寸如表 1 所示。其中,前 2 组点云的重叠度较高,后 2 组点云的重叠度较低,每组数据的点云尺寸规模均不相同,且第 4 组点云中两个片段的点数相差很大。用本算法提取点云片段中的关键点后确定对应关系,并进行配准,实验结果如图 4 所示。可以发现,本算法提取的点云关键点能描述原始点云的整体轮廓,关键点数量足够、几何特征完整,且最终确定的点对对应关系基本正确,配准效果在视觉上达到了预期要求。对点云进行可视化后,每两片点云都重叠得很好,位姿保持一致,没有出现点云错位情况,验证了本算法的可行性。

#### 4.2 Bunny 模型中不同重叠度点云片段的配准实验

为了验证本算法的配准精度,将本算法与传统点云配准算法在不同重叠度点云片段中进行对比实验,选取的点云片段尺寸如表 2 所示。对三片原始点云片段进行可视化,结果如图 5 所示。其中,bun000 和 bun045 片段的重叠度接近 90%,且两者的初始位姿比较接近;bun045 和 bun090 片段的重叠度相对较低,约为 50%,且初始位姿角度相对较大。

表 2 Bunny 模型的部分点云片段尺寸

Table 2 Size of partial point cloud segments of Bunny model

Point cloud model	Segments of model	Number of points
Bunny	bun000	40256
	bun045	40097
	bun090	30379




图 5 Bunny 点云模型中的片段。(a)bun000 和 bun045;(b)bun090 和 bun045

Fig. 5 Fragment of the Bunny point cloud model. (a) bun000 and bun045; (b) bun090 and bun045

表 3 不同算法的配准结果

Table 3 Registration results of different algorithms

unit: mm

Serial number	Algorithm	Root mean square distance error	
		bun000 and bun045	bun045 and bun090
1	ICP	0.000900	0.017943
2	4PCS	0.004802	0.010270
3	Super-4PCS	0.003803	0.010086
4	GICP	0.001229	0.010159
5	Ours-CR	0.000984	0.007196
6	Ours-FR	0.000896	0.006465

由于 ICP 算法对低重叠度点云的配准效果很差,因此,仅将本算法与 4PCS、Super-4PCS、GICP 算法进行对比。可以发现,对于高重叠度点云(bun000 和 bun045),相比效果较好的 GICP 算法,本算法的粗配准精度提升了约 20%,精配准精度提

实验分为两组,第一组输入的点云片段为 bun000 和 bun045,第二组输入的点云片段为 bun045 和 bun090。本算法与 ICP、4PCS、Super-4PCS、GICP 算法对两组点云片段的配准结果如表 3 所示。其中,第 5 组数据为本算法的粗配准(CR)结果,即添加距离约束后得到的初步配准结果;第 6 组数据为本算法的精配准(FR)结果,即将初步配准经过 ICP 算法微调后的结果。本算法、ICP、4PCS 和 GICP 均使用 C++ 环境下的库 PCL1.8.1 实现,Super-4PCS 算法由相关文献提供的 Demo 实现。可以发现,相比其他算法,无论是粗配准还是精配准部分,本算法都具有较好的配准精度。虽然本算法的粗配准精度在 bun000 和 bun045 片段上略差于 ICP 算法,但精配准后的效果优于单一 ICP 算法。原因是 bun000 和 bun045 片段的重叠度较高,初始位姿差异很小,ICP 算法在这类点云中的适应性较强。对重叠度较低且位姿差异较大的 bun045 和 bun090 片段的配准中,ICP 算法明显陷入局部最优的情况。相比 ICP 算法,本算法的粗配准精度提升了约 60%,精配准精度提升了约 64%。此外,本算法更注重对不同重叠度点云配准精度的提升。配准精度提升的百分比可表示为

$$P = \frac{|e_1 - e_2|}{e_2} \times 100\%, \quad (6)$$

式中, $P$  为一种方法相对另一种配准精度提升的百分比, $e_1$  为一种配准方法的均方根距离误差, $e_2$  为另一种配准方法的均方根距离误差。

升了约 27%;对于低重叠度点云(bun045 和 bun090),相比效果较好的 Super-4PCS 算法,本算法的粗配准精度提升了约 29%,精配准精度提升了约 36%。这表明本算法对于不同重叠度的点云都达到了较好的配准效果,具有一定的通用性和准确度。



图 6 为不同算法的点云配准的结果,可以发现,




图 6 Bunny 点云的配准结果。(a) bun000 和 bun045;  
(b) bun090 和 bun045

Fig. 6 Registration result of the Bunny point cloud.  
(a) bun000 and bun045; (b) bun090 and bun045




图 7 office 点云配准实验结果。(a)原始点云;(b)4PCS;(c)Super-4PCS;(d)本算法

Fig. 7 Experimental results of office point cloud registration. (a) Original point cloud; (b) 4PCS; (c) Super-4PCS;  
(d) our algorithm

只用 ICP 算法对 bun045 和 bun090 进行配准后,两片点云完全不重合,配准不正确。原因是 ICP 算法对于低重叠度的点云配准效果很差。除 ICP 算法外,其他算法的配准结果也明显可以看到错位情况,尤其是对于重叠度较低点云。而本算法配准的两片点云匹配度和位姿均高度一致。

#### 4.3 Redwood 3D Dataset 点云配准对比实验

为了验证本算法对其他数据集的配准效果,采用 Redwood 3D Dataset 中的 office 场景点云进行配准实验。Redwood 3D Dataset 是一个较大场景室内环境的点云数据集,相比上述实验使用的点云片段,该数据集内点云片段的点数更多,尺寸规模更大,且重叠度参差不齐,可用于检验算法的配准效果。实验所用的点云片段为 office 场景点云中的 1、2 片段,点数分别为 193851 和 160368。为了加快配准时间,先对点云进行随机采样,每片点云最终均采样得到 10000 个点,作为本算法的输入。由于均方距离误差是在原始点云片段上进行计算的,因此用 4PCS 和 Super-4PCS 作为对比实验,两者的配准结果为官方数据集中得到的变换矩阵,对变换后的点云计算均方根距离误差,结果如表 4 所示。可以发现,本算法对这两片点云片段的配准效果均优于 4PCS 和 Super-4PCS 算法,精度分别提高了 32% 和 30%。实验结果的可视化如图 7 所示,可以发现,图 7(b)和图 7(c)中左侧立方体存在明显的错位,而本算法匹配后的两片点云片段位姿基本重叠,这表明本算法的配准精度更高,且对不同数据集均具有较好的配准效果,通用性较强。

表 4 office 环境点云配准算法对比实验结果

Table 4 Experimental results of registration algorithm for the point cloud of office environment

Serial number	Algorithm	Root mean square distance error /mm
1	4PCS	0.139283
2	Super-4PCS	0.135356
3	ours	0.094396

## 5 结 论

针对低重叠度点云难以配准及不同尺寸规模点云配准的通用性差问题,提出了一种基于 FPFH 的点云配准算法。首先,通过多尺度特征提取关键点,得到的关键点可以很好地表征点云的表面特征并描述原始点云的整体轮廓,同时降低了需要调节的参数数量。然后,在 FPFH 匹配的基础上,增加点云内对应点的距离约束条件,确定初步变换矩阵,降低算法对点云尺寸规模和重叠度的敏感性。最后,用 ICP 算法进行微调,从而达到较高的配准精度和较好的点云配准效果。实验结果表明,本算法在不同重叠度以及不同规模的点云数据集上均具有较高的配准精度,且配准效果超过了一些传统点云配准算法。但本算法存在时间复杂度高的问题,后续还需进行深入研究,进一步优化算法,降低时间成本。

### 参 考 文 献

- [1] Besl P J, McKay N D. A method for registration of 3-D shapes[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 1992, 14(2): 239-256.
- [2] Li X C, Yan Z Y, Lin S, et al. Point cloud registration based on neighborhood characteristic point extraction and matching [J]. Acta Photonica Sinica, 2020, 49(4): 0415001.  
李新春, 闫振宇, 林森, 等. 基于邻域特征点提取和匹配的点云配准 [J]. 光子学报, 2020, 49(4): 0415001.
- [3] Segal A, Haehnel D, Thrun S. Generalized-ICP[C]// Robotics: Science and Systems V, June 28-July 1, 2009, Seattle, USA. Cambridge: MIT Press, 2009.
- [4] Yang J L, Li H D, Campbell D, et al. Go-ICP: a globally optimal solution to 3D ICP point-set registration[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2016, 38(11): 2241-2254.
- [5] Zhao F Q. Point cloud registration algorithm based on improved ICP[J]. Information Technology, 2017, 41(5): 64-66, 71.  
赵夫群. 基于改进 ICP 的点云配准算法[J]. 信息技术, 2017, 41(5): 64-66, 71.
- [6] Wang Y, Zou H, He Y M, et al. ICP algorithm based on multi-resolution registration point[J]. Journal of Chinese Computer Systems, 2018, 39(3): 406-410.  
王勇, 邹辉, 何养明, 等. 多分辨率配准点的 ICP 算法[J]. 小型微型计算机系统, 2018, 39(3): 406-410.
- [7] Censi A. An ICP variant using a point-to-line metric [C]//2008 IEEE International Conference on Robotics and Automation, May 19-23, 2008, Pasadena, CA, USA. New York: IEEE Press, 2008: 19-25.
- [8] Low K L. Linear least-squares optimization for point-to-plane ICP surface registration [J]. Chapel Hill, University of North Carolina, 2004, 4(10): 1-3.
- [9] Aiger D, Mitra N J, Cohen-Or D. 4-points congruent sets for robust pairwise surface registration[J]. ACM Transactions on Graphics, 2008, 27(3): 1-10.
- [10] Mellado N, Aiger D, Mitra N J. Super 4PCS fast global pointcloud registration via smart indexing[J]. Computer Graphics Forum, 2014, 33(5): 205-215.
- [11] Tang Z R, Liu M Z, Wang C, et al. Point cloud registration based on multi-dimensional mixed Cauchy distribution[J]. Acta Optica Sinica, 2019, 39(1): 0115005.  
唐志荣, 刘明哲, 王畅, 等. 基于多维混合柯西分布的点云配准[J]. 光学学报, 2019, 39(1): 0115005.
- [12] Zhou R Q, Li X X, Jiang W S. 3D surface matching by a voxel-based buffer-weighted binary descriptor [J]. IEEE Access, 2019, 7: 86635-86650.
- [13] Le H M, Do T T, Hoang T, et al. SDRSAC: semidefinite-based randomized approach for robust point cloud registration without correspondences[C]// 2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), June 15-20, 2019, Long Beach, CA, USA. New York: IEEE Press, 2019: 124-133.
- [14] Li C H, Shi H, Li Z J. Point cloud registration method based on combination of convolutional neural network and improved Harris-SIFT [J]. Laser & Optoelectronics Progress, 2020, 57(20): 201102.  
李昌华, 史浩, 李智杰. 基于卷积神经网络结合改进 Harris-SIFT 的点云配准方法 [J]. 激光与光电子学进展, 2020, 57(20): 201102.
- [15] Zhan X, Cai Y. Point cloud registration algorithm based on cosine similarity[J]. Laser & Optoelectronics Progress, 2020, 57(12): 121503.  
詹旭, 蔡勇. 基于余弦相似度的点云配准算法 [J]. 激光与光电子学进展, 2020, 57(12): 121503.
- [16] Rusu R B, Blodow N, Beetz M. Fast point feature histograms (FPFH) for 3D registration [C] // 2009 IEEE International Conference on Robotics and Automation, May 12-17, 2009, Kobe, Japan. New York: IEEE Press, 2009: 3212-3217.
- [17] Sipiran I, Bustos B. Harris 3D: a robust extension of the Harris operator for interest point detection on 3D meshes [J]. The Visual Computer, 2011, 27(11):



- 963-976.
- [18] Flint A, Dick A, Hengel A V D. Thrift: local 3D structure recognition[C]//9th Biennial Conference of the Australian Pattern Recognition Society on Digital Image Computing Techniques and Applications (DICTA 2007), December 3-5, 2007, Glenelg, SA, Australia. New York: IEEE Press, 2007: 182-188.
- [19] Zhang Z Y. Microsoft Kinect sensor and its effect [J]. IEEE MultiMedia, 2012, 19(2): 4-10.
- [20] Rusu R B, Cousins S. 3D is here: point cloud library (PCL)[C]//2011 IEEE International Conference on Robotics and Automation, May 9-13, 2011, Shanghai, China. New York: IEEE Press, 2011: 1-4.
- [21] Jia W, Shu Q, Huang Y Q. Feature point extraction algorithm of point cloud based on FPFH [J]. Computer Applications and Software, 2020, 37(7): 165-169, 245.  
贾薇, 舒勤, 黄燕琴. 基于 FPFH 的点云特征点提取算法[J]. 计算机应用与软件, 2020, 37(7): 165-169, 245.
- [22] Hou B, Jin S Z, Wang Y, et al. Comparison of point cloud registration methods in coarse registration[J]. Laser & Optoelectronics Progress, 2020, 57(8): 081502.  
侯彬, 金尚忠, 王赞, 等. 点云配准方法在粗配准中的比较[J]. 激光与光电子学进展, 2020, 57(8): 081502.
- [23] Peng Z, Lü Y J, Qu C, et al. Accurate registration of 3D point clouds based on keypoint extraction and improved iterative closest point algorithm[J]. Laser & Optoelectronics Progress, 2020, 57(6): 061002.  
彭真, 吕远健, 渠超, 等. 基于关键点提取与优化迭代最近点的点云配准[J]. 激光与光电子学进展, 2020, 57(6): 061002.
- [24] 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.
- [25] The Stanford 3D scanning repository [EB/OL]. [2021-02-01]. <http://graphics.stanford.edu/data/3Dscanrep>.
- [26] Choi S, Zhou Q Y, Koltun V. Robust reconstruction of indoor scenes[C]//2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), June 7-12, 2015, Boston, MA, USA. New York: IEEE Press, 2015: 5556-5565.