

# 基于角度约束的跨源点云配准算法

阎翔鑫<sup>1</sup>, 蒋峥<sup>1,2\*</sup>, 刘斌<sup>1,2</sup>

<sup>1</sup>武汉科技大学冶金自动化与检测技术教育部工程研究中心, 湖北 武汉 430081;

<sup>2</sup>武汉科技大学信息科学与工程学院, 湖北 武汉 430081

**摘要** 针对现有点云配准算法在跨源点云上配准效果不佳的问题,提出一种基于角度约束的跨源点云配准算法。该算法重新定义快速点特征直方图(FPFH)算法的权重系数,以适应不同尺度的点云数据,提高匹配点对的内点率;同时使用角度约束对匹配点对进行筛选,保留兼容性良好的匹配对用于尺度估计,对两个点云的尺度进行统一。在粗配准阶段,筛选出满足距离约束的兼容三角形,计算粗配准矩阵,完成初步变换。最后利用迭代最近点(ICP)算法进行细配准,提高整体的配准精度。实验结果表明,所提算法对相同尺度和不同尺度的点云数据均具有较好的配准效果,且具备快速配准点云的能力。

**关键词** 点云配准; 跨源点云; 角度约束; 尺度估计

中图分类号 TP391.4 文献标志码 A

DOI: 10.3788/LOP230478

## Cross-Source Point Cloud Registration Algorithm Based on Angle Constraint

Yan Xiangxin<sup>1</sup>, Jiang Zheng<sup>1,2\*</sup>, Liu Bin<sup>1,2</sup>

<sup>1</sup>Engineering Research Center for Metallurgical Automation and Measurement Technology of Ministry of Education, Wuhan University of Science and Technology, Wuhan 430081, Hubei, China;

<sup>2</sup>School of Information Science and Engineering, Wuhan University of Science and Technology, Wuhan 430081, Hubei, China

**Abstract** Existing point cloud registration algorithms are not effective for cross-source point cloud registration. To address this issue, this paper proposes a cross-source point cloud registration algorithm that uses angle constraints. The algorithm redefines the weight coefficients of the fast point feature histogram (FPFH) algorithm to adapt it to point cloud data with different scales and improve the inlier rate of matching point pairs. Additionally, the algorithm uses angle constraints to filter the matching point pairs and reserves those with good compatibility to estimate scale, thus unifying the scale of two point clouds. In the coarse registration phase, the compatibility triangles satisfying the distance constraint are filtered to calculate the coarse registration matrix, thus completing the preliminary transformation. Finally, the iterative closest point (ICP) algorithm is used for fine registration to improve the overall registration accuracy. Experimental results show that the proposed algorithm has a good registration effect on point cloud data with same and different scales and can quickly register point clouds.

**Key words** point cloud registration; cross-source point cloud; angle constraint; scale estimation

## 1 引言

近年来高精度的三维传感器发展迅速,点云已成为描述三维世界的主要数据格式。目前有多种获取点云的技术,例如 Kinect 传感器、激光雷达(lidar)、测距相机、运动恢复结构(SFM)、同步定位与地图构建(SLAM)等,它们各自点云数据的配准已经达到了较高的精度。但是面对不同类型传感器采集到的点云数

据时,传统的点云配准算法无法达到良好的配准效果。在许多实际应用中<sup>[1]</sup>,经常会遇到因为传感器自身视野和现场测量环境的影响,无法正常采集点云数据的情况,此时多种类型的传感器比单一类型传感器具有更强的数据采集能力。配准单一类型传感器采集的点云数据称为同源点云配准,而配准不同类型传感器采集的点云数据称为跨源点云配准。

针对跨源点云配准中存在的问题,一些学者进行

收稿日期: 2023-01-09; 修回日期: 2023-01-30; 录用日期: 2023-03-01; 网络首发日期: 2023-03-09

通信作者: \*zjiangmail@126.com

了初步研究。Peng 等<sup>[2]</sup>首次提出了一种从粗到细的跨源点云配准方法,首先利用形状函数(ESF)描述符找到点云中的感兴趣区域,再使用迭代最近点(ICP)算法<sup>[3]</sup>完成配准,但该方法没有解决 ICP 算法对点云初始位置要求高的问题。Huang 等<sup>[4]</sup>提出了一种配准框架来处理跨源点云配准问题。该框架首先利用超体素分割提取点云的宏观结构,再使用 ESF 描述符提取点云的微观结构,通过组织这些结构将配准问题转换为图匹配问题,并通过图匹配优化来估计变换矩阵,虽然该算法可以成功配准跨源点云,但整体的效率不高。特征指标配准(FMR)<sup>[5]</sup>是第一个基于学习的方法,主要解决跨源点云配准问题。该方法将优化方法和深度神经网络相结合,通过最小化全局特征差来估计变换。由于神经网络具有良好的特征提取能力,基于深度学习的方法是解决跨源点云配准问题的一个很有前景的方向,但泛化性还有待验证。

以上方法对配准跨源点云具有一定的启发意义,但它们都缺乏解决跨源点云中的尺度差异问题的能力。Ying 等<sup>[6]</sup>把尺度因子引入到标准迭代最近点算法中,将配准公式转换为 7 维非线性空间上的约束优化问题,最后应用奇异值分解方法迭代求解此类优化问题。Lin 等<sup>[7]</sup>通过对自旋图像进行主成分分析,生成两组累积贡献率曲线,并寻找曲线的最小值来估计尺度。范怡萍等<sup>[8]</sup>将尺度因子与旋转参数和平移参数作为共同待求解的变量,利用人工蜂群算法进行求解。这些方法在点云较大的情况下计算成本较大,运行速度较慢。汪千金等<sup>[9]</sup>利用尺度滑移算法对高分辨率的点云数据进行降采样,利用基于深度学习的渐进式三维点云上采样算法对低分辨率的点云数据进行上采样,算法可以减少尺度与分辨率差异对跨源配准的干扰,提高配准精度,但当点云数据的曲率特征较少甚至没有时,配准精度将会大大下降。王玉文等<sup>[10]</sup>从有向包围盒的角度来解决点云中的尺度差异问题,通过计算两个点云的有向包围盒的对应边比例来估计尺度因子。张琮毅等<sup>[11]</sup>以包围盒尺度估计了计算特征子的半径尺度,从而使得快速点特征直方图描述子(FPFH)与带颜色的方向直方图签名描述子(CSHOT)具有在不同尺度点云间进行配准的能力。这些方法对完整点云的尺度估计效果较好,但面对点云缺失的情况时会产生较大的误差。综上所述,本文提出一种基于角度约束的跨源点云配准算法,在解决尺度问题的同时,具备快速配准跨源点云的能力。

## 2 基本原理

### 2.1 跨源点云配准问题

给定两个不同类型传感器采集到的三维点云数据,记为源点云  $\mathbf{P} = \{\mathbf{p}_i \in \mathbb{R}^3\}_{i=1}^{N_p}$  和目标点云  $\mathbf{Q} = \{\mathbf{q}_i \in \mathbb{R}^3\}_{i=1}^{N_q}$ ,其中  $\mathbf{p}_i$  和  $\mathbf{q}_i$  分别表示源点云和目标点云

中的点, $N_p$  和  $N_q$  分别表示源点云和目标点云中的点数。 $\mathbf{P}$  和  $\mathbf{Q}$  中的对应点满足

$$\mathbf{q}_i = s\mathbf{R}\mathbf{p}_i + \mathbf{t} + \mathbf{n}_i, \quad (1)$$

式中: $s > 0$  为尺度因子; $\mathbf{R} \in SO(3)$  为正交旋转矩阵; $\mathbf{t} \in \mathbb{R}^3$  为平移向量; $\mathbf{n}_i$  为测量噪声,可以假设它是未知但有界的。基于对应关系的点云配准可以表示为以下优化问题,

$$\min_{s, \mathbf{R}, \mathbf{t}} J = \sum_{i=1}^N \rho(\|\mathbf{q}_i - (s\mathbf{R}\mathbf{p}_i + \mathbf{t})\|), \quad (2)$$

式中: $\rho(\cdot)$  表示鲁棒损失函数; $\|\cdot\|$  表示二范数。三维点云配准问题的关键是寻找最佳的变换( $s^*, \mathbf{R}^*, \mathbf{t}^*$ ),使源点云和目标点云中的点尽可能重合。

跨源点云配准问题往往比同源点云配准问题更复杂,图 1 展示了其中一些主要的困难:1)数据缺失,由于成像机制的不同,同一物体在不同类型的传感器中具有不同的反射或无反射,导致采集到的点云数据部分缺失;2)密度差异,由于传感器的采样原理和采样密度不同,采集到的点云的点数存在巨大差异;3)尺度差异,不同类型传感器采集的点云数据之间通常会有尺度差异,而且由于数据缺失和密度差异,可靠地估计尺度因子是一项困难的任务。

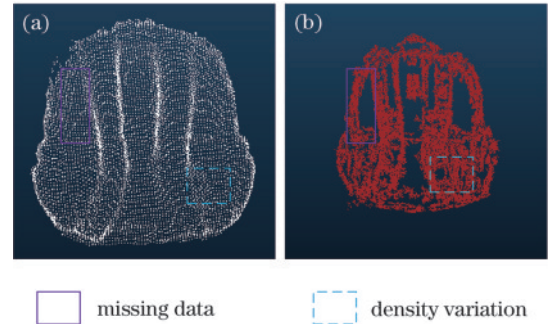


图 1 来自不同传感器的跨源点云示例。(a)Kinect 点云;  
(b)SFM 点云

Fig. 1 Examples of cross-source point clouds coming from different sensors. (a) Kinect point cloud; (b) SFM point cloud

### 2.2 基于改进 FPFH 获取匹配点对

为了建立两个跨源点云之间的点对应关系,在文献[12]算法的基础上,重新定义了 FPFH 的权重系数,提高了匹配点对的内点率。原始的 FPFH 算法计算过程如下。

1)对于每个查询点  $\mathbf{p}$ ,计算自身与其  $k$  个邻域点之间的关系,得到简化特征直方图 SPFH( $\mathbf{p}$ )。

2)对于每个邻域点  $\mathbf{p}_k$ ,重新确定其  $k$  个邻域点并计算 SPFH( $\mathbf{p}_k$ ),然后对所有的 SPFH( $\mathbf{p}_k$ ) 计算加权平均值,最后将结果与步骤 1)中的 SPFH( $\mathbf{p}$ ) 相加,得到最终  $\mathbf{p}$  的快速点特征直方图 FPFH( $\mathbf{p}$ ),公式为

$$\text{FPFH}(\mathbf{p}) = \text{SPFH}(\mathbf{p}) + \frac{1}{K} \sum_{k=1}^K \frac{1}{\omega_k} \text{SPFH}(\mathbf{p}_k), \quad (3)$$

式中:  $\omega_k$  表示查询点  $p$  和邻域点  $p_k$  之间的欧氏距离, 权重系数定义为  $1/\omega_k$ 。

图 2 表示查询点  $p$  和它的邻域点所组成的区域。从图 2 可以看出, 在不同尺度下, 同一个查询点和它的邻域点之间的欧氏距离会存在差异, 导致计算出的权重系数发生巨大变化, 进而影响到快速特征直方图的计算, 产生错误匹配。为了使权重系数具有尺度不变性, 定义一个新的 FPFH 算法的权重系数, 表达式为

$$\frac{1}{\omega'_k} = \exp\left(-\frac{d_k}{d_{\max}}\right), \quad (4)$$

式中:  $1/\omega'_k$  为新的权重系数;  $d_k$  为查询点与邻域内第  $k$  个点之间的距离;  $d_{\max}$  为查询点与最远邻域点之间的距离。从式(4)可以看出, 邻域点离查询点越近, 对应的权重就越大, 反之就越小, 因此新的权重系数保留了权重系数的原有特性。同时, 由于在不同尺度下  $d_k$  和  $d_{\max}$  的比值是恒定的, 新的权重系数还具有尺度不变性。原始 FPFH 和改进 FPFH 产生的匹配点对如图 3(a) 和图 3(b) 所示。对比图 3(a) 和图 3(b) 可知, 在




图 2 FPFH 算法的影响区域

Fig. 2 Influence region of the FPFH algorithm




图 3 两种权重系数产生的匹配点对。(a) 原始 FPFH 产生的匹配点对; (b) 改进 FPFH 产生的匹配点对

Fig. 3 Matching point pairs generated by two different weight coefficients. (a) Matching point pair produced by the original FPFH; (b) matching point pair produced by the improved FPFH

点云尺度不同时, 改进 FPFH 产生匹配点对的质量更好, 正确匹配的点对数占比大约为 80%, 与原始 FPFH 产生的正确匹配点对相比, 提高了 60% 左右。利用改进的 FPFH 算法得到一个初始匹配点对集  $I$ , 为之后的筛选作准备。

### 2.3 基于角度约束的尺度估计

针对跨源点云配准中可能存在尺度差异的问题, 提出一种基于角度约束的筛选匹配点对的方法, 保留兼容性较好的匹配点对用于尺度估计, 对两个跨源点云的尺度进行统一。在尺度估计之前, 需要先计算点云中每个点的法向量。一个点的法向量可以看作是求这个点的邻域点所拟合平面的法向量, 邻域点构成的协方差矩阵  $M$  为

$$M = \frac{1}{k} \sum_{j=1}^k (p_{ij} - \bar{p}_i)(p_{ij} - \bar{p}_i)^T, \quad (5)$$

式中:  $k$  表示邻域内点数;  $p_{ij}$  表示以  $i$  为查询点的第  $j$  个邻域点;  $\bar{p}_i$  表示当前查询点的所有邻域点的均值。利用主成分分析法计算协方差矩阵  $M$  的特征值, 得到  $\lambda_1, \lambda_2, \lambda_3$  三个特征值。令  $\lambda_1 \leq \lambda_2 \leq \lambda_3$ , 那么  $\lambda_1$  所对应的特征向量  $\xi_1$  为该查询点的法向量。

当两个点云之间存在尺度差异时, 假设  $p'_i = sp_i, p'_j$  为源点云缩放后的点云, 由  $p'_i$  求得的协方差矩阵为  $M' = s^2 M$ , 再次利用主成分分析法计算协方差矩阵  $M'$  的特征值, 得到  $\lambda'_1, \lambda'_2, \lambda'_3$  三个特征值, 根据线性代数的知识可得  $\lambda'_1 = s^2 \lambda_1, \lambda'_2 = s^2 \lambda_2, \lambda'_3 = s^2 \lambda_3$ ,  $\lambda'_1$  所对应的特征向量仍然为  $\xi_1$ 。所以, 在局部邻域内, 法向量具有尺度不变性。根据这一特性, 本文提出一种快速尺度估计算法, 具体步骤如下。

1) 首先从初始匹配点对集  $I$  中取两个点, 计算它们之间法向量夹角和它们各自匹配点之间的法向量夹角。

2) 根据两个法向量夹角计算两组匹配点对的兼容性, 兼容性的计算方法为

$$s(c_i, c_j) = \exp\left[-\frac{D(c_i, c_j)^2}{2t_{\text{cons}}^2}\right], \quad (6)$$

式中:  $t_{\text{cons}}$  为角度约束参数。  $D(c_i, c_j)$  为两个法向量夹角的差值, 计算公式为

$$D(c_i, c_j) = \left| \arccos(\mathbf{n}_i^s, \mathbf{n}_j^s) - \arccos(\mathbf{n}_i^t, \mathbf{n}_j^t) \right|, \quad (7)$$

式中:  $\mathbf{n}_i^s$  和  $\mathbf{n}_j^s$  表示源点云中两个点的法向量;  $\mathbf{n}_i^t$  和  $\mathbf{n}_j^t$  表示目标点云中与源点云中两个点相匹配的点的法向量。

3) 重复步骤 1) 和步骤 2), 筛选出所有满足角度约束的匹配点对, 并计算出尺度因子,

$$s_{ij} = \frac{d_{ij}^t}{d_{ij}^s}, \quad (8)$$

式中:  $s_{ij}$  为尺度因子;  $d_{ij}^t$  为目标点云中第  $i$  和  $j$  两个匹配点之间的欧氏距离;  $d_{ij}^s$  为源点云中与目标点云中两个

点分别匹配的点之间的欧氏距离。

4) 根据步骤 3) 计算得到一个尺度集合  $I^s$ , 利用随机一致性采样算法 (RANSAC)<sup>[13]</sup> 对  $I^s$  进行拟合, 得到一个最佳的尺度  $s^*$ , 对源点云和目标点云的尺度进行统一。

2.2 节的方法得到的匹配点对中存在部分的误匹配点对, 如果直接利用匹配点对之间距离的比值来估计尺度, 得到的尺度误差较大, 并且会大大降低之后的配准精度。所提算法考虑到两点之间的法向量夹角不会受到尺度变化的影响, 利用角度约束对匹配点对进行筛选, 在一定程度上提高匹配点对的内点率, 减小尺度估计的误差。

### 2.4 生成粗配准矩阵

由于角度约束不能保证去除所有的误匹配点对, 为了保证配准的精度, 需要对匹配点对进行再次筛选, 尽可能地去除错误的匹配点对。大多数算法使用成对距离约束来筛选匹配点对, 但成对距离约束存在模糊性, 可能会错误判断匹配点对的正确性, 如图 4 所示。受到文献 [14] 提出的 sample consensus by sampling compatibility triangles (SAC-COT) 算法的启发, 本文将成对兼容性关系扩展到三元组, 利用兼容三角形对匹配点对进行再次筛选, 有效消除成对距离约束的歧义。这样做的主要原因有两点: 首先只需要三组不共线的匹配点对就能计算出一个变换矩阵, 过多的匹配点对反而可能会降低配准的精度; 其次不需要剔除匹配点对中所有的异常值, 只要匹配点对中存在三组正确的对应关系, 就能产生正确的变换矩阵。生成粗配准矩阵的步骤如下所示。

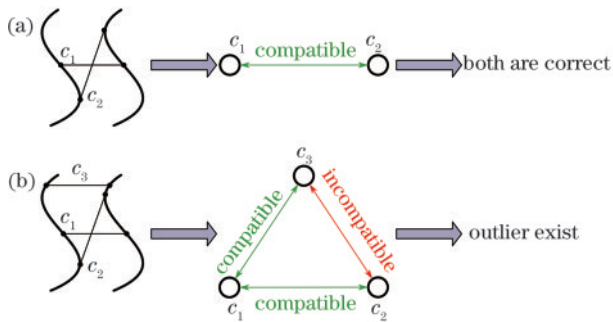


图 4 两组匹配点对和 three 组匹配点对的比较。(a) 两组匹配点对都判断为正确; (b) 成功检测出异常值

Fig. 4 Comparison of two and three sets of matching point pairs. (a) Both sets of matching point pairs are correct; (b) outliers can be detected

1) 将每组匹配点对作为一个节点, 将满足距离约束的节点连接起来, 生成一个无向图, 如图 5 所示。vi 表示一组匹配点对, 节点之间的数字表示两组匹配点对的兼容性。

2) 找出无向图中所有的兼容三角形, 如图 6 所示。




图 5 无向图

Fig. 5 Undirected graph




图 6 兼容三角形生成

Fig. 6 Compatibility triangle generation

3) 依次对无向图中兼容三角形进行采样。每个兼容三角形都可以生成一个变换矩阵, 源点云通过变换矩阵转移到目标点云的坐标系。

采样完成后, 对所有变换矩阵进行评估, 选择均方根误差最小的一个变换矩阵作为最后的粗配准矩阵。粗配准完成后, 利用 ICP 算法完成细配准, 进一步提高配准精度。

## 3 实验结果与分析

为了验证所提算法的有效性, 本实验以 Intel(R) Core(TM) i5-7300HQ CPU 和 8 GB 内存的计算机为实验平台, 利用 Visual Studio 2019 和 Matlab 2020 软件及 PCL 1.11.1 点云库进行实验。

### 3.1 实验说明

实验数据选择悉尼理工大学的跨源点云基准数据集 3DCSR 中的 chair、dustbin、lab1、lab2、lab3、corner, 点云数据信息如图 7 和表 1 所示

实验前, 利用 CloudCompare 软件中的“Space”方式对原始点云数据进行降采样, 以提高点云配准的效率, 同时使得两类点云数据的密度较为接近, 方便特征描述符的提取。根据本次的实验数据情况, 计算法向量的邻域设为 30, 计算 FPFH 描述符的邻域设为 40, RANSAC 的阈值设为 0.05, 迭代次数设为 1000。为保证角度筛选后的匹配点对的数量保持在合适的范围, 不会影响之后配准矩阵的生成, 角度参数  $t_{cons}$  分别




图 7 跨源点云数据

Fig. 7 Cross-source point cloud data

表 1 跨源点云数据信息

Table 1 Cross-source point cloud data information

Point cloud	Image to be registered	Number of points
chair	chair_kinect	10849
	chair_sfm	41650
dustbin	dustbin_kinect	25396
	dustbin_sfm	66795
lab1	lab1_kinect	15031
	lab1_sfm	65470
lab2	lab2_kinect	12863
	lab2_sfm	87808
lab3	lab3_kinect	18669
	lab3_sfm	189946
corner	corner_kinect	70819
	corner_sfm	19474

设为 1.0, 1.0, 0.5, 0.5, 0.5, 0.5, 角度兼容性阈值为 0.95。

为了验证不同三维点云算法的性能,采用均方根误差(RMSE)作为配准效果的定量评价指标,表达式为

$$E_{\text{RMS}} = \sqrt{\frac{\sum_{i=1}^n \| \mathbf{p}_i - \mathbf{q}_i \|^2}{n}}, \quad (9)$$

式中:  $\mathbf{p}_i$  和  $\mathbf{q}_i$  为一组匹配点对;  $n$  为成功配准的点对

数量。

### 3.2 同尺度跨源点云配准

针对上述的跨源点云数据,采用所提算法进行配准,并与 ICP、CPD<sup>[15]</sup>、K4PCS<sup>[16]</sup>、SDRSAC<sup>[17]</sup> 和 SAC-IA+NDT<sup>[18]</sup> 进行对比。其中 ICP、CPD 和 K4PCS 是经典的点云配准算法,SDRSAC 是一种不依赖于假定对应关系的随机点云配准方法,SAC-IA+NDT 是基于采样一致性初始配准(SAC-IA)和正态分布变换(NDT)配准融合的点云配准方法。

表 2 为同尺度下各算法所计算的 RMSE,其中最优值用加粗形式表示。从表 2 可以看出:对于 chair、dustbin、lab1、lab2 这 4 个点云来说,所提算法的精度最高;在 lab3 和 corner 点云上,所提算法的精度要略低于 SDRSAC 算法的精度,原因在于即使是同尺度点云配准,所提算法也会估计一个尺度因子,该尺度因子与点云的原始尺度之间存在一定的误差,最终会导致点云配准的精度有所下降,但相比其他算法,所提算法的精度均有较大的优势,并且结合图 8 也可以看出,利用所提算法配准后的两个点云重叠度也是最高的。表 3 为同尺度下各配准算法所用时间。在所有点云上,ICP 的配准时间最短,但精度较低。在精度接近的情况下,所提算法所用时间远远少于 SDRSAC 算法的配准时间。

表 2 同尺度下各算法所计算的 RMSE

Table 2 RMSE of each algorithm with the same scale

Point cloud	ICP	CPD	K4PCS	SDRSAC	SAC-IA+NDT	Proposed algorithm
chair	0.05644	0.05313	0.04074	0.02688	0.05434	<b>0.02662</b>
dustbin	0.05690	0.03142	0.03947	0.03066	0.04719	<b>0.02888</b>
lab1	0.04480	0.02381	0.02563	0.02255	0.02914	<b>0.02175</b>
lab2	0.05082	0.05315	0.03130	0.03168	0.04090	<b>0.02998</b>
lab3	0.04208	0.03100	0.04123	<b>0.02653</b>	0.04794	0.02720
corner	0.05858	0.05817	0.05357	<b>0.04067</b>	0.05761	0.04110

### 3.3 不同尺度跨源点云配准

为验证所提算法在不同尺度下点云配准的有效

性,保持 Kinect 传感器所采集的点云数据尺度不变,对通过 SFM 方式得到的点云数据分别进行 0.5 和 2 倍的

表 3 同尺度下各算法所用时间

Table 3 Time of each algorithm with the same scale

unit: s

Point cloud	ICP	CPD	K4PCS	SDRSAC	SAC-IA+NDT	Proposed algorithm
chair	<b>0.11</b>	4.26	0.97	126.69	16.40	0.68
dustbin	<b>0.089</b>	3.61	0.61	313.06	10.11	0.58
lab1	<b>0.17</b>	13.08	1.94	50.02	28.21	2.86
lab2	<b>0.14</b>	12.83	0.47	81.32	25.96	1.65
lab3	<b>0.41</b>	32.29	0.92	182.62	51.52	2.66
corner	<b>0.23</b>	17.88	0.32	184.14	31.14	8.68

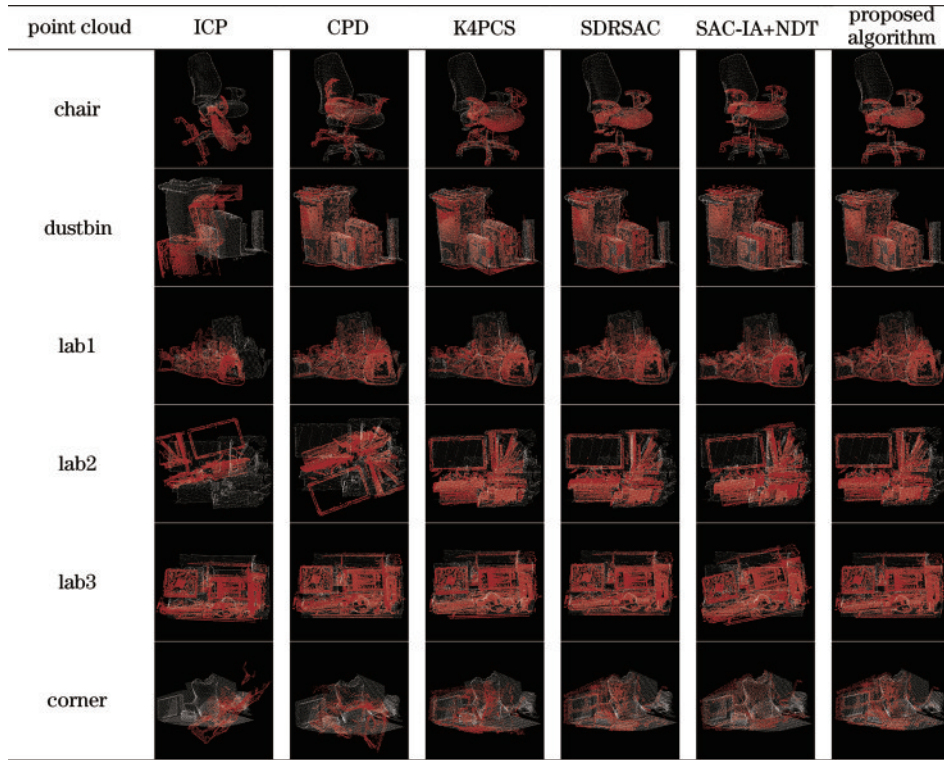


图 8 同尺度下各算法的配准结果

Fig. 8 Registration effect of each algorithm with the same scale

缩小和放大。由于 ICP、K4PCS、SDRSAC 和 SAC-IA+NDT 不具备尺度估计的能力,因此所提算法只与 Scale-ICP<sup>[19]</sup>和 CPD 进行对比。Scale-ICP 通过对原始的 ICP 算法进行扩展,可以用于各向同性拉伸数据集的点云配准。

表 4 为不同尺度下各算法所估计的尺度因子。从表 4 可以看出:所提算法估计的尺度因子比 Scale-ICP 和 CPD 估计的尺度因子更接近真实值,最大的误差为 4.25%;在不同尺度下,Scale-ICP 和 CPD 所估计的尺度因子具有相同的比例关系,而所提算法由于受到 FPFH 算法所生成匹配点集的影响,不同尺度下所得到的匹配点集会有轻微差异,所以估计的尺度因子不再具有比例关系。

表 5 为不同尺度下各算法所计算的 RMSE。从表 5 可以看出:所提算法的精度优于 Scale-ICP 和 CPD 算法,平均比 Scale-ICP 算法提高 12.9%;在 lab1 和 corner 点云配准中,当估计出的尺度误差较大时,配准

表 4 不同尺度下各算法所估计的尺度因子

Table 4 Scale factor of each algorithm with different scales

Point cloud	Scale	Scale-ICP	CPD	Proposed algorithm
chair	0.5	0.4439	0.5767	<b>0.5103</b>
	2	1.7754	2.3068	<b>2.0629</b>
dustbin	0.5	0.4798	0.5180	<b>0.5171</b>
	2	1.9193	2.0833	<b>2.0685</b>
lab1	0.5	0.4526	0.4759	<b>0.4960</b>
	2	1.8103	1.9037	<b>2.0353</b>
lab2	0.5	0.4676	0.5988	<b>0.5206</b>
	2	1.8702	2.3878	<b>2.0687</b>
lab3	0.5	0.4894	0.5263	<b>0.4922</b>
	2	1.9576	1.9601	<b>1.9932</b>
corner	0.5	0.4848	0.5618	<b>0.5046</b>
	2	1.9393	2.2467	<b>1.9150</b>

的精度也会有所下降,但结合图 9 可以看出,所提算法的配准效果同样优于其他两种算法。在表 6 算法时间

表 5 不同尺度下各算法所计算的 RMSE

Table 5 RMSE of each algorithm with different scales

Point cloud	Scale	Scale-ICP	CPD	Proposed algorithm
chair	0.5	0.03234	0.05719	<b>0.02708</b>
	2	0.03234	0.05719	<b>0.02725</b>
dustbin	0.5	0.03501	0.03090	<b>0.02900</b>
	2	0.03501	0.03090	<b>0.02900</b>
lab1	0.5	0.02580	0.02392	<b>0.02229</b>
	2	0.02580	0.02392	<b>0.02358</b>
lab2	0.5	0.03289	0.05310	<b>0.03043</b>
	2	0.03289	0.05310	<b>0.03031</b>
lab3	0.5	0.02748	0.03112	<b>0.02718</b>
	2	0.02748	0.03112	<b>0.02715</b>
corner	0.5	0.04861	0.06131	<b>0.04038</b>
	2	0.04861	0.06131	<b>0.04070</b>

表 6 不同尺度下各算法所用时间

Table 6 Time of each algorithm with different scales unit: s

Point cloud	Scale	Scale-ICP	CPD	Proposed algorithm
chair	0.5	1.96	21.01	<b>1.38</b>
	2	2.01	20.93	<b>1.13</b>
dustbin	0.5	0.79	10.01	<b>0.51</b>
	2	0.66	9.95	<b>0.53</b>
lab1	0.5	<b>1.56</b>	64.29	2.89
	2	<b>1.54</b>	63.73	2.34
lab2	0.5	<b>1.67</b>	75.18	1.73
	2	<b>1.41</b>	74.63	1.46
lab3	0.5	<b>1.61</b>	98.78	2.32
	2	<b>1.66</b>	98.82	2.60
corner	0.5	<b>1.38</b>	81.23	8.96
	2	<b>1.37</b>	79.92	8.82

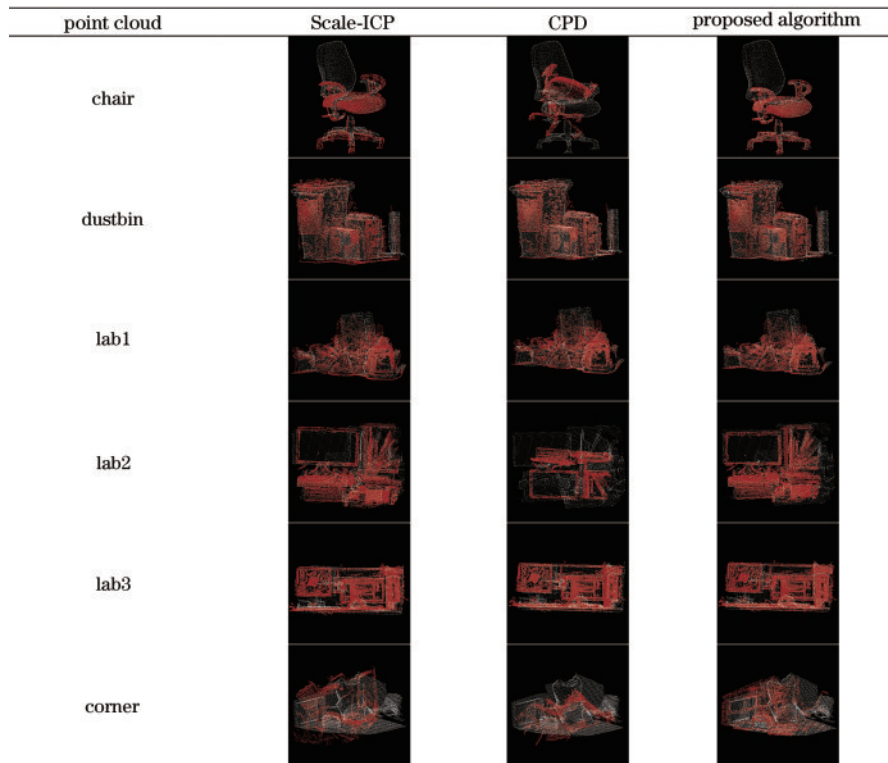


图 9 尺度因子为 0.5(2) 时各算法的配准结果

Fig. 9 Registration effect of each algorithm with scale factor  $s=0.5$  ( $s=2$ )

损耗方面,所提算法在 chair 和 dustbin 点云配准中略有优势,在其他点云配准中不及 Scale-ICP 算法,原因是经过 2 次筛选后,仍然保留了较多的匹配点对,导致计算粗配准矩阵时耗时较长,但总体时间都在可接受范围内。

## 4 结 论

提出一种基于角度约束的跨源点云配准算法。通过重新定义 FPFH 算法的权重系数,消除尺度差异对匹配点对的影响,减小误匹配率。所提算法通过 2 次

筛选来完成粗配准。第一次利用角度约束剔除部分误匹配点对,根据筛选出的匹配点对估计出尺度因子,对两个点云的尺度进行统一。第二次筛选出满足距离约束的兼容三角形,计算粗配准矩阵,完成粗配准。最后使用 ICP 进行细配准,进一步提高配准精度和配准效果。实验结果表明,所提算法在相同尺度和不同尺度的跨源点云数据上的配准精度均优于一些传统的点云配准算法,但所提算法在效率方面没有明显优势,后续可以继续改进,提高算法的运行效率。

## 参 考 文 献

- [1] Huang X, Mei G, Zhang J, et al. A comprehensive survey on point cloud registration[EB/OL]. (2021-03-03) [2022-03-05]. <https://arxiv.org/abs/2103.02690>.
- [2] Peng F R, Wu Q, Fan L X, et al. Street view cross-sourced point cloud matching and registration[C]//2014 IEEE International Conference on Image Processing (ICIP), October 27-30, 2014, Paris, France. New York: IEEE Press, 2015: 2026-2030.
- [3] 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.
- [4] Huang X S, Zhang J, Fan L X, et al. A systematic approach for cross-source point cloud registration by preserving macro and micro structures[J]. IEEE Transactions on Image Processing, 2017, 26(7): 3261-3276.
- [5] Huang X S, Mei G F, Zhang J. Feature-metric registration: a fast semi-supervised approach for robust point cloud registration without correspondences[C]//2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), June 13-19, 2020, Seattle, WA, USA. New York: IEEE Press, 2020: 11363-11371.
- [6] Ying S H, Peng J G, Du S Y, et al. A scale stretch method based on ICP for 3D data registration[J]. IEEE Transactions on Automation Science and Engineering, 2009, 6(3): 559-565.
- [7] Lin B W, Tamaki T, Zhao F D, et al. Scale alignment of 3D point clouds with different scales[J]. Machine Vision and Applications, 2014, 25(8): 1989-2002.
- [8] 范怡萍, 葛宝臻, 陈雷. 基于人工蜂群优化的异尺度点云配准算法[J]. 激光与光电子学进展, 2023, 60(12): 1210023.
- Fan Y P, Ge B Z, Chen L. Registration algorithm of differently scaled point clouds based on artificial bee colony optimizer[J]. Laser & Optoelectronics Progress, 2023, 60(12): 1210023.
- [9] 汪千金, 崔海华, 张益华, 等. 面向光学测量跨源点云的多尺度采样配准方法[J]. 光学学报, 2022, 42(10): 1015002.
- Wang Q J, Cui H H, Zhang Y H, et al. Multi-scale sampling registration method for optical measurement of cross-source point clouds[J]. Acta Optica Sinica, 2022, 42(10): 1015002.
- [10] 王玉文, 李珊君, 杨赞秀, 等. 基于有向包围盒的尺度点云配准算法[J]. 激光杂志, 2022, 43(1): 12-18.
- Wang Y W, Li S J, Yang Y X, et al. Scale point cloud registration algorithm based on oriented bounding[J]. Laser Journal, 2022, 43(1): 12-18.
- [11] 张琮毅, 魏子庄, 徐昊文, 等. 尺度可变的快速全局点云配准方法[J]. 计算机学报, 2019, 42(9): 1939-1952.
- Zhang C Y, Wei Z Z, Xu H W, et al. Scale variable fast global point cloud registration[J]. Chinese Journal of Computers, 2019, 42(9): 1939-1952.
- [12] 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.
- [13] 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.
- [14] Yang J Q, Huang Z Q, Quan S W, et al. SAC-COT: sample consensus by sampling compatibility triangles in graphs for 3-D point cloud registration[J]. IEEE Transactions on Geoscience and Remote Sensing, 2022, 60: 5700115.
- [15] Theiler P W, Wegner J D, Schindler K. Keypoint-based 4-points congruent sets-automated marker-less registration of laser scans[J]. ISPRS Journal of Photogrammetry and Remote Sensing, 2014, 96: 149-163.
- [16] Myronenko A, Song X B. Point set registration: coherent point drift[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2010, 32(12): 2262-2275.
- [17] 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, 2020: 124-133.
- [18] 荆路, 武斌, 李先帅. 基于 SAC-IA 和 NDT 融合的点云配准方法[J]. 大地测量与地球动力学, 2021, 41(4): 378-381.
- Jing L, Wu B, Li X S. Point cloud registration method based on SAC-IA and NDT fusion[J]. Journal of Geodesy and Geodynamics, 2021, 41(4): 378-381.
- [19] Lin B W, Tamaki T, Raytchev B, et al. Scale ratio ICP for 3D point clouds with different scales[C]//2013 IEEE International Conference on Image Processing, September 15-18, 2013, Melbourne, VIC, Australia. New York: IEEE Press, 2014: 2217-2221.