

## 基于人工蜂群优化的异尺度点云配准算法

范怡萍<sup>1,2</sup>, 葛宝臻<sup>1,2</sup>, 陈雷<sup>3\*</sup><sup>1</sup>天津大学精密仪器与光电子工程学院, 天津 300072;<sup>2</sup>光电信息技术教育部重点实验室, 天津 300072;<sup>3</sup>天津商业大学信息工程学院, 天津 300134

**摘要** 针对不同尺度点云配准的精度和效率问题,提出一种基于人工蜂群优化的异尺度点云配准算法。引入尺度缩放因子,与三维旋转、平移参数共同作为配准过程中的待求变量,使用人工蜂群优化方法进行优化求解。同时,基于归一化尺度参数改进了欧氏距离目标函数,以消除优化求解中尺度缩放因子引起的误差,从而有效提高配准算法的稳定性。与当前几组典型方法进行对比,所提算法对不同模型配准的精度和效率均有提高。实验结果表明,所提算法充分利用了人工蜂群优化方法优异的全局优化能力,可以有效实现对异尺度点云的高精度、快速配准。

**关键词** 点云配准; 异尺度; 人工蜂群优化; 改进欧氏距离; 跨源点云

中图分类号 TP751.1

文献标志码 A

DOI: 10.3788/LOP221735

## Registration Algorithm for Differently Scaled Point Clouds Based on Artificial Bee Colony Optimization

Fan Yiping<sup>1,2</sup>, Ge Baozhen<sup>1,2</sup>, Chen Lei<sup>3\*</sup><sup>1</sup>School of Precision Instrument and Opto-Electronics Engineering, Tianjin University, Tianjin 300072, China;<sup>2</sup>Key Laboratory of Opto-Electronic Information and Technology, Ministry of Education, Tianjin 300072, China;<sup>3</sup>School of Information Engineering, Tianjin University of Commerce, Tianjin 300134, China

**Abstract** This study proposed a differently scaled point cloud registration algorithm based on artificial bee colony optimization that can improve the accuracy and efficiency of differently scaled point cloud registration. The scale scaling factor, together with the three-dimensional rotation and translation parameters, was introduced as the variables to be solved in the registration process, and the artificial bee colony optimization method was used to optimize the solution. Furthermore, the proposed algorithm improved the Euclidean distance objective function based on the normalized scale factor, which eliminated the errors caused by optimizing the scale scaling factor to effectively improve the stability of the registration algorithm. Compared to currently employed methods, the proposed algorithm improves the accuracy and efficiency in different model registrations. The experimental results demonstrate that the proposed algorithm utilizes the excellent global optimization ability of the artificial bee colony optimization method and can therefore effectively realize the high-precision and fast registration for differently scaled point clouds.

**Key words** point cloud registration; different scales; artificial bee colony optimization; improved Euclidean distance; cross-source point cloud

## 1 引言

点云配准是三维重建过程中的关键步骤。三维点云配准主要分为同尺度点云配准和异尺度点云配准两大类。同尺度点云配准对同一三维数据采集设备得到的多片点云进行配准,需正确求解点云空间位置变换的旋转参数、平移参数。而异尺度点云配准是针对不

同三维数据采集设备得到的多片点云的,其配准过程还需考虑不同点云之间的尺度差异。但因广泛灵活的适应性,异尺度点云配准逐渐在大场景三维重建、遥感及考古等领域<sup>[1-2]</sup>受到了越来越多的重视。

异尺度点云配准算法一般可分三大类:基于优化求解的方法<sup>[3-4]</sup>、基于高斯混合模型(GMM)的方法<sup>[5]</sup>、基于特征的方法<sup>[6-8]</sup>。基于优化求解的方法将配准问题转换

收稿日期: 2022-05-30; 修回日期: 2022-07-01; 录用日期: 2022-07-14; 网络首发日期: 2022-07-24

基金项目: 国家自然科学基金(61535008)

通信作者: \*chenlei@tjcu.edu.cn

为非线性最优化问题,并根据目标函数进行迭代收敛求解,但在尺度差异较大的情况下配准效果不佳。基于高斯混合模型的方法的核心是将配准问题转换为求解高斯混合模型参数的问题,但随着点云数量的增加,计算时间会快速增加。基于特征的方法分为特征提取和特征选择两种:前者通过奇异值分解(SVD)得到新的点云特征空间后分步求解配准参数;后者则根据点或线等特征选出特征子集,使用随机抽样一致性(RANSAC)方法或者特征直线的螺旋缩放运动求解配准参数,此类方法配准结果受特征分解或选择效果影响较大,稳定性有待提升。近几年,随着对异尺度点云配准算法研究的不断深入,基于特征学习的方法<sup>[9]</sup>、基于改进概率模型的方法<sup>[10]</sup>及基于RANSAC的方法<sup>[11]</sup>等被提出。ScaleLK方法以深度学习的方式提取尺度特征并进行异尺度点云配准,相比于传统特征提取方法,效率更高,但并未解决特征提取带来的不稳定性问题。MMC算法使用多维混合柯西分布代替高斯分布,解决了配准过程易受噪声影响的问题。基于RANSAC的尺度估计方法具备优异的全局性能,但配准过程耗时较长。

人工蜂群优化算法<sup>[12]</sup>是一类模拟蜂群觅食行为的最优化算法,具有优化能力强、鲁棒性强和控制参数少等优点,适用于求解多参数优化问题。近年来已有学者采用该算法进行同尺度点云配准<sup>[13]</sup>,可进一步将人工蜂群优化方法引入到异尺度点云配准问题中,从而获得更好的配准效果。本文首先引入尺度缩放因子,其与三维旋转、平移参数共同作为配准过程中的待求变量,解决了异尺度点云配准的尺度缩放问题;提出基于改进欧氏距离的目标函数,消除尺度缩放因子带来的误差;最后使用人工蜂群优化方法对目标函数进行优化求解,得到有效实现异尺度点云配准的7个配准参数。与其他异尺度点云配准算法相比,所提算法充分利用了仿生智能优化算法的全局优化能力,有效提升了点云配准的精度。

## 2 算法原理

### 2.1 异尺度点云配准

点云配准对不同视角下的点云进行空间位置变换,实现对物体形貌的完整重建。源点云  $\mathbf{P} = \{\mathbf{p}_1, \mathbf{p}_2, \dots, \mathbf{p}_N\}$  通过变换矩阵  $\mathbf{T}$  与目标点云  $\mathbf{Q} = \{\mathbf{q}_1, \mathbf{q}_2, \dots, \mathbf{q}_M\}$  合并到同一坐标系下。同尺度点云配准包括旋转和平移两种形式变换,异尺度点云配准中还需确定缩放变换。因此,异尺度配准变换矩阵  $\mathbf{T}$  可表示为

$$\mathbf{T} = [s_0 \mathbf{R} \ \mathbf{t}], \quad (1)$$

式中:  $s_0$  为尺度缩放因子;  $\mathbf{R} \in \mathbb{R}^{3 \times 3}$  为空间旋转矩阵;  $\mathbf{t} \in \mathbb{R}^3$  为空间平移向量。旋转阵  $\mathbf{R}$  和绕 Z、Y、X 三个坐标轴的欧拉角  $\{\alpha, \beta, \gamma\}$  之间的关系为

$$\mathbf{R} = \mathbf{R}_z(\alpha) \mathbf{R}_y(\beta) \mathbf{R}_x(\gamma), \quad (2)$$

其中,

$$\mathbf{R}_z(\alpha) = \begin{bmatrix} \cos \alpha & -\sin \alpha & 0 \\ \sin \alpha & \cos \alpha & 0 \\ 0 & 0 & 1 \end{bmatrix}, \quad (3)$$

$$\mathbf{R}_y(\beta) = \begin{bmatrix} \cos \beta & 0 & \sin \beta \\ 0 & 1 & 0 \\ -\sin \beta & 0 & \cos \beta \end{bmatrix}, \quad (4)$$

$$\mathbf{R}_x(\gamma) = \begin{bmatrix} 1 & 0 & 0 \\ 0 & \cos \gamma & -\sin \gamma \\ 0 & \sin \gamma & \cos \gamma \end{bmatrix}. \quad (5)$$

平移向量  $\mathbf{t}$  和沿三个坐标轴的平移量  $\{t_x, t_y, t_z\}$  之间的关系为

$$\mathbf{t} = \begin{bmatrix} t_x \\ t_y \\ t_z \end{bmatrix}, \quad (6)$$

因此,异尺度配准变换矩阵  $\mathbf{T}$  由 7 个参数  $\{s_0, \alpha, \beta, \gamma, t_x, t_y, t_z\}$  共同决定。

在完全配准的情况下,  $\mathbf{P}$  变换后的点云  $T(\mathbf{P})$  与  $\mathbf{Q}$  对应点之间的距离为 0,实际配准中因测量误差、噪声等,无法达到理想值 0。因此,将异尺度点云配准问题转换为一个最优化问题,寻求一个最优变换矩阵  $\mathbf{T}$ ,使得  $T(\mathbf{P})$  与  $\mathbf{Q}$  之间的欧氏距离最小:

$$E = \sum_{i=1}^n \|T(\mathbf{p}_i) - \mathbf{q}_j\|^2, \quad (7)$$

式中:  $\{\mathbf{p}_i, \mathbf{q}_j\}$  是一对对应点,通过 K 最邻近(KNN)方法搜索确定。

### 2.2 人工蜂群优化

人工蜂群优化方法是一种应用广泛的性能优异的仿生智能优化方法,其优化原理源于蜜蜂觅食行为。算法中的蜜蜂被分为 3 类:雇佣蜂,发现食物源的蜜蜂,评估食物的价值,将食物信息以一定概率分享给其他蜜蜂;跟随蜂,接收到雇佣蜂的信息,在食物邻域搜索并评估食物价值,保留价值更高的食物;侦察蜂,雇佣蜂的食物被抛弃后,随机进行邻域搜索,寻找新的食物源。

人工蜂群优化方法在每一次迭代中都会进行全局和局部最优的搜索,相较于其他仿生智能优化方法,有全局优化能力强、鲁棒性强、控制参数少的优点,其易用性已经体现在生物医学信号处理、光通信<sup>[14]</sup>、图像处理<sup>[15]</sup>等多个领域。其原理简要介绍如下。

首先,随机初始化  $N_s$  个食物源  $S$ ,表达式为

$$S_{ij} = S_{\min_j} + \text{rand}[0, 1](S_{\max_j} - S_{\min_j}), \quad (8)$$

式中:  $i \in \{1, 2, \dots, N_s\}$ ,  $j \in \{1, 2, \dots, d\}$ ;  $S_{\max_j}$  和  $S_{\min_j}$  分别代表可行解在  $j$  维的上下边界;  $\text{rand}$  为取  $[0, 1]$  之间的随机数函数。

雇佣蜂需要对初始化后的可行解进行邻域搜索,以判断是否需要放弃当前食物,表达式为

$$v_{ij} = S_{ij} + \varphi_{ij}(S_{ij} - S_{kj}), \quad (9)$$

式中:  $k \in \{1, 2, \dots, N_s\}$ ,  $k \neq i$ ,  $k$  和  $j$  随机选取;  $\varphi_{ij}$  取  $[-1, 1]$  之间的随机数。邻域搜索的目标函数值小于原来的

值,则用邻域搜索得来的可行解代替原解,否则保持不变。然后雇佣蜂分享信息给跟随蜂。

$$p_i = F_{\text{obj}}(S_i) / \sum_{j=1}^d F_{\text{obj}}(S_j) \quad (10)$$

进入跟随蜂阶段,蜂群根据概率  $p_i$  选择食物源进行采蜜,选择的概率和食物的收益  $F_{\text{obj}}(S_i)$  有关。选择好食物之后根据式(9)进行邻域搜索,保留更好的解。最后进入侦察蜂阶段,食物被搜索一定次数后仍未更新,则放弃该食物,由侦察蜂根据式(9)产生新食物。异尺度点云配准问题本质上属于多维非线性参数优化问题,因此可使用人工蜂群优化方法进行变换矩阵  $T$  参数的求解。

使用人工蜂群优化方法配准同尺度点云时,重点关注蜂群搜索策略的改进和目标函数的构造。Chen 等<sup>[13]</sup>使用差分进化算法改进蜂群搜索策略,进一步提升了配准的精度和效率。马卫<sup>[16]</sup>在蜂群的个体位置和群体位置中引入振荡环节,可以扩大蜂群搜索点云配准参数的范围。Yi 等<sup>[17]</sup>在欧氏距离目标函数中加入平滑项作为蜂群搜索的目标函数,算法表现出了优异的抗噪性。

### 3 算法框架

所提算法通过人工蜂群优化方法进行异尺度点云配准,重点解决了三个方面的问题:引入尺度缩放因子  $s_o$ ;构造合适的目标函数;利用优化算法对目标函数进行优化求解,得到 7 个配准参数。

人工蜂群优化方法解决最优化问题时能够同步求解多个参数,这一特点使得在 6 维配准参数之外引入尺度参数并求解具有便捷性。考虑到标量性质的尺度参数引入会给基于欧氏距离的目标函数带来误差,本文将使用误差构造归一化尺度参数的改进欧氏距离作为目标函数。最后,将 7 维配准参数共同作为待优化

变量进行求解。由于人工蜂群优化求解过程不涉及梯度求导运算和复杂公式推导,使用其求解配准参数的过程中各参数的物理意义更加明确,同时也能充分利用其优异的全局优化能力实现高精度配准。

#### 3.1 尺度缩放因子引入及目标函数构造

在基于仿生智能优化的点云配准问题中,一般使用欧氏距离均值作为目标函数,在异尺度点云配准问题中,提出一种带尺度因子的改进欧氏距离作为目标函数,它们的表达式分别为

$$F_{\text{average}} = \frac{1}{n} \sum_{i=1}^n \|T(\mathbf{p}_i) - \mathbf{q}_j\|^2, \quad (11)$$

$$F_{\text{obj}} = \frac{1}{n \times s_o^2} \sum_{i=1}^n \|T(\mathbf{p}_i) - \mathbf{q}_j\|^2. \quad (12)$$

尺度点云配准的参数分为尺度因子  $s_o$ 、平移参数  $t$ 、旋转参数  $R$  三类,其中尺度因子为标量值。在人工蜂群优化求解的雇佣蜂阶段,蜂群会在可行域内初始化  $N_s$  组解,随机初始化得到的尺度因子为  $\{s_o^1, s_o^2, \dots, s_o^{N_s}\}$ 。在未优化至最佳参数前,每次迭代将标量尺度因子代入欧氏距离目标函数式(11)中,较大的尺度因子会造成目标函数值大。目标函数值越大,尺度因子越会往靠近较小值的方向收敛。为了消除这种误差,对标量参数带来的误差使用式(12)进行归一化。

#### 3.2 待配准参数求解

异尺度点云配准是一个针对式(12)的最优化问题,待优化量是点云变换矩阵  $T$  中的 7 个参数  $\{s_o, \alpha, \beta, \gamma, t_x, t_y, t_z\}$ 。使用人工蜂群求解该优化问题,可行解  $\{s_o, \alpha, \beta, \gamma, t_x, t_y, t_z\}$  为食物源,可行解代入目标函数式(12),所得的值描述了该食物的收益率。目标函数值越小,食物源的收益率越大,点云配准精度越高。使用人工蜂群优化方法进行异尺度点云配准的流程如图 1 所示,优化过程由优化算法本身决定,不涉及梯度运算。

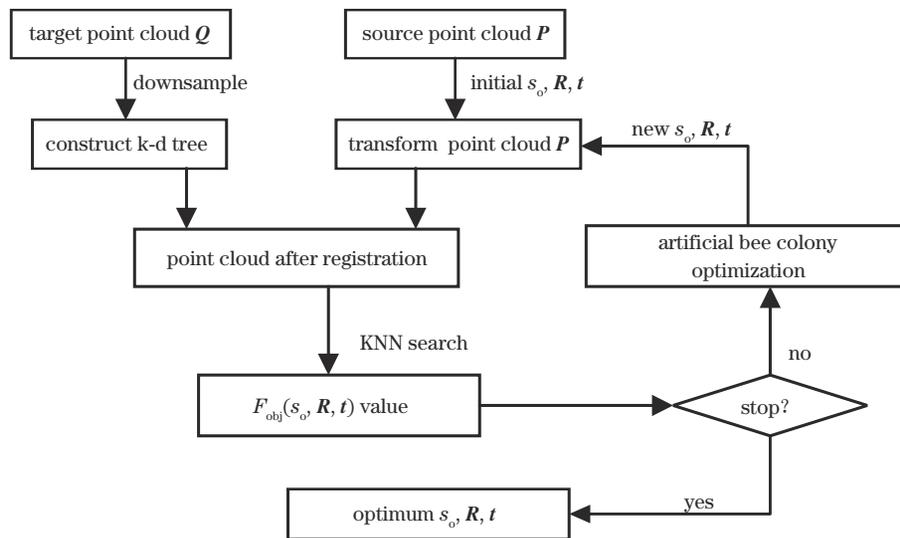


图 1 所提算法流程

Fig. 1 Flowchart of proposed algorithm

## 4 实验及分析

设计三组实验来说明所提算法相比其他算法的优势及解决跨源点云配准问题的可行性。第一组实验使用不同算法对同源点云进行异尺度配准并比较,定性和定量分析所提算法在解决部分重叠点云配准问题上的优势。第二组实验使用所提算法对有噪声干扰的同源点云进行异尺度配准,分析算法的抗噪性。第三组实验使用所提算法对跨源点云进行异尺度配准,直观分析配准结果并对比尺度因子求解值和真实值。

表 1 点云数据信息

Table 1 Point cloud data information

Point cloud	Image to be registered	Target /source point cloud	Number of points	Angle of view
Bunny	Bun000	Target	40256	45°
	Bun045	Source	40097	
Armadillo	ArmadilloBack_0	Target	19283	30°
	ArmadilloBack_30	Source	12150	
Bag	Bag_Kinect	Target	11595	Unknown
	Bag_SFMM	Source	21495	
Tsinghua gate	Tsinghua gate_Lidar	Target	33721	Unknown
	Tsinghua gate_SFMM	Source	971436	
Life science building	Life science building_Lidar	Target	761729	Unknown
	Life science building_SFMM	Source	1813056	

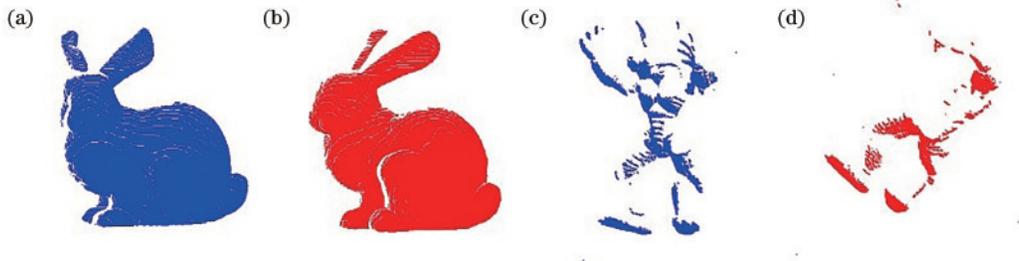


图 2 同源点云数据。(a)Bun000;(b)Bun045;(c)ArmadilloBack\_0;(d)ArmadilloBack\_30

Fig. 2 Homologous point cloud data. (a) Bun000; (b) Bun045; (c) ArmadilloBack\_0; (d) ArmadilloBack\_30

第二类数据采用悉尼理工大学提供的跨源点云数据背包<sup>[19]</sup>和中国科学院自动化研究所模式识别国家重点实验室提供的点云数据清华门和生科楼<sup>[20]</sup>。该类点云数据由不同传感器获取,点云在点数、结构上存在较大的差异,不同传感器获取到的同一物体细节信息有差异,如图 3(a)和图 3(b)所示,两处细节存在互补的情况。

### 2) 参数设置

根据蜂群算法在解决各类优化问题上的经验,食物源和雇佣蜂数目  $N = 10$ , 搜索 30 次仍未更新则放弃该食物,最大迭代次数为 1000; 根据待求解参数的个数,待求解问题的维度  $d = 7$ ; 目标点云下采样率为 0.01。根据待求解参数的极限边界,旋转参数  $\alpha, \beta, \gamma \in [0, 2\pi]$ , 平移参数  $t_x, t_y, t_z \in (-\infty, \infty)$ , 尺度缩放因子的估计边界为  $s_0 \in [1, 50]$ 。KNN 搜索点云对

### 4.1 实验说明

配准实验是在 Intel(R) Core™ i5-7600 CPU、8 GB 内存的计算机硬件环境下进行的。

#### 1) 数据介绍

点云数据信息如表 1 所示,各片点云形态如图 2 和图 3 所示。第一类数据是斯坦福大学计算机图形学实验室提供的同源点云数据 Bunny 和 Armadillo<sup>[18]</sup>,由同一种传感器(Cyberware 3030 MS)采集获取,Bunny 点云的重叠率约为 80%,Armadillo 点云的重叠率约为 60%。

时,  $K = 5$ 。

#### 3) 评价指标

为评价不同算法的性能,采用均方根误差 (RMSE) 作为配准效果的定量评价指标。其定义为

$$R_{MSE} = \frac{1}{n} \sum_{i=1}^n \|T_{result}(p_i) - q_j\|^2, \quad (13)$$

式中:  $T_{result}$  为最优转换矩阵;  $n$  为匹配成功的点的对数。

### 4.2 实验结果及分析

#### 4.2.1 同源点云配准

使用所提算法对 Bunny 和 Armadillo 两组同源点云数据进行异尺度配准,并与 EBABC-RS-IR<sup>[13]</sup>、ICP<sup>[21]</sup>、Scale-ICP<sup>[22]</sup> 和 CPD<sup>[5]</sup> 的配准结果进行对比。EBABC-RS-IR 和 ICP 是两种同尺度点云配准方法,Scale-ICP 是基于 SVD 的异尺度点云配准方法,CPD

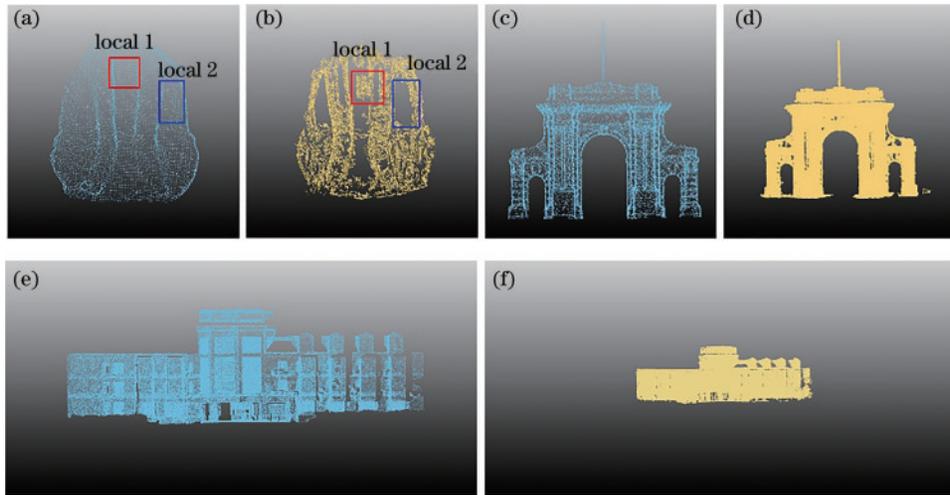


图 3 跨源点云数据。(a)背包\_Kinect;(b)背包\_SFMM;(c)清华门\_Lidar;(d)清华门\_SFMM;(e)生科楼\_Lidar;(f)生科楼\_SFMM  
Fig. 3 Cross-source point cloud data. (a) Bag\_Kinect; (b) Bag\_SFMM; (c) Tsinghua gate\_Lidar; (d) Tsinghua gate\_SFMM; (e) Life science building\_Lidar; (f) Life science building\_SFMM

是一种经典的基于GMM的点云配准算法。首先对源点云 Bun045 和 ArmadilloBack\_30 进行不同程度的缩小,使得源点云到目标点云配准的尺度因子值分别为

$s_0 = 20, 10, 1.25$ 。点云的相对初始状态如图 4 所示,各待配准的点云呈现出了明显的尺度差异。

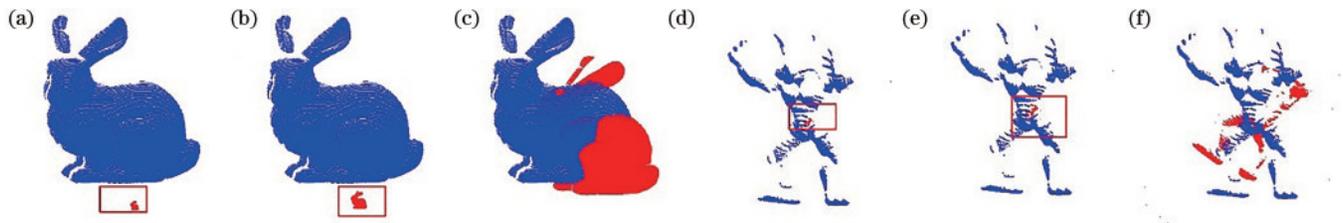


图 4 不同尺度参数下的待配准点云。(a)Bunny,  $s_0=20$ ;(b)Bunny,  $s_0=10$ ;(c)Bunny,  $s_0=1.25$ ;(d)Armadillo,  $s_0=20$ ;(e)Armadillo,  $s_0=10$ ;(f)Armadillo,  $s_0=1.25$

Fig. 4 Point clouds to be registered with different scaling factors. (a) Bunny,  $s_0=20$ ; (b) Bunny,  $s_0=10$ ; (c) Bunny,  $s_0=1.25$ ; (d) Armadillo,  $s_0=20$ ; (e) Armadillo,  $s_0=10$ ; (f) Armadillo,  $s_0=1.25$

使用不同算法配准的结果如图 5 和图 6 所示。从图 5 和图 6 的直观配准结果来看,由于 EBABC-RS-IR 和 ICP 算法对点云配准参数只进行 6 个维度的求解,缺少尺度参数的情况下配准完全失败。Scale-ICP 和 CPD 算法在两组数据上的配准效果表现出了不一致: Scale-ICP 配准点云时在旋转因子的求解上误差较大,对 Armadillo 点云数据实现了近似配准,对 Bunny 点云数据则完全没有配准;CPD 算法对高重叠率的 Bunny 数据实现了比较好的配准,但是对于低重叠率的 Armadillo 源点云产生了非刚性形变,配准效果不佳。

由于 EBABC-RS-IR 和 ICP 算法已直观地说明了在异尺度点云配准中的无效性,因此仅从均方根误差值和算法使用时间两个方面来定量分析 Scale-ICP、CPD 和所提算法的异尺度点云配准性能。从表 2 的均方根误差值来看:所提算法的精度比 Scale-ICP 算法高出 1 个数量级;相比 CPD 算法,在低重叠率 Armadillo 点云数据的 3 个不同尺度上,精度分别高 48.40%、53.32% 和 52.38%;相比 CPD 算法,在较高重叠率

Bunny 点云数据的 3 个不同尺度上,精度分别高 7.38%、2.43% 和 7.76%。

表 3 是各种算法进行异尺度点云配准时所耗费的时间。Scale-ICP 在 Armadillo 点云配准上的速度略有优势,相比于所提算法,所用时间在 3 个尺度下平均少 3.23 s;CPD 算法在时间上没有明显优势,针对重叠率较高的 Bunny 点云耗费时间较长,相比于所提算法,所用时间在 3 个尺度下平均长 73.02 s;针对重叠率较低的 Armadillo 点云,相比于所提算法,CPD 算法所用时间在 3 个尺度下平均长 3.31 s。

综合图 5 和图 6、表 2 和表 3:所提算法能够配准不同尺度差异、不同重叠率的点云,相比于 Scale-ICP 算法,在时间上略长,但精度高 1 个数量级;相比于 CPD 算法,所提算法稳定性更高,对低重叠率和高重叠率的点云配准的精度均较高,而 CPD 算法在低重叠率的点云配准中精度较低;除此之外,所提算法还有时间上的优势。

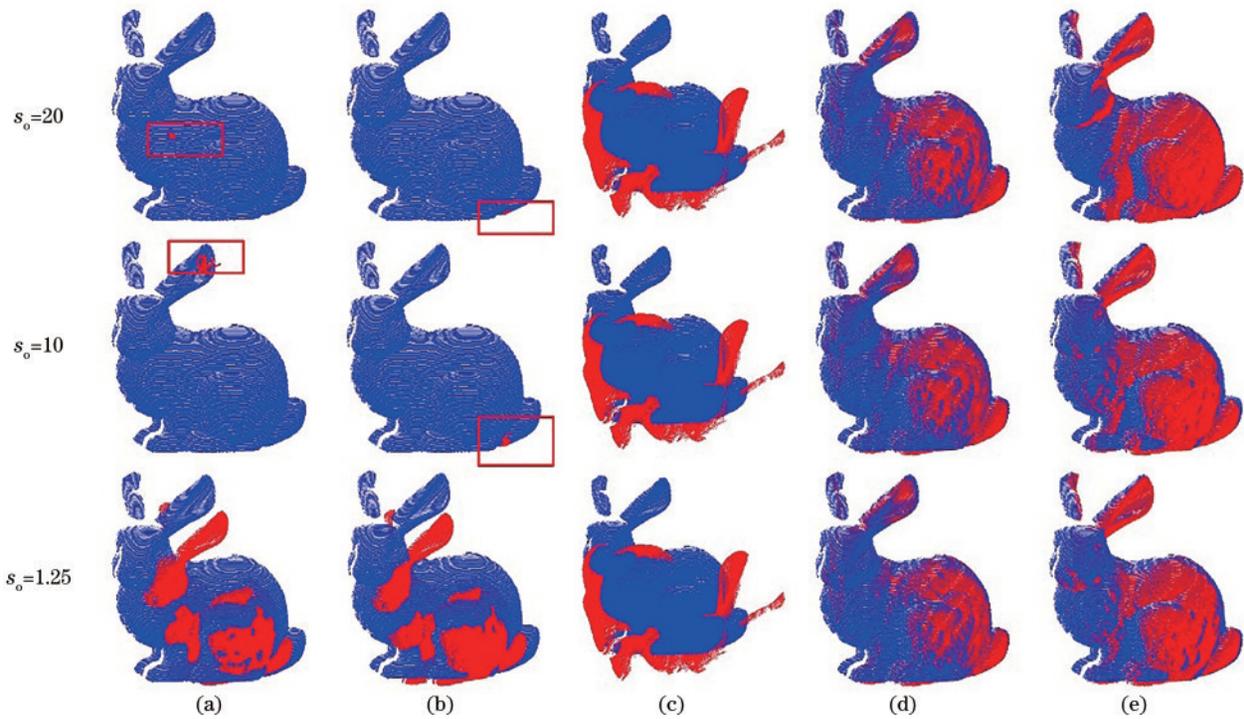


图 5 不同尺度因子下各算法对 Bunny 点云的配准结果。(a)EBABC-RS-IR;(b)ICP;(c)Scale-ICP;(d)CPD;(e)所提算法  
 Fig. 5 Registration results of various algorithms for Bunny point cloud under different scale factors. (a) EBABC-RS-IR; (b) ICP; (c) Scale-ICP; (d) CPD; (e) proposed algorithm

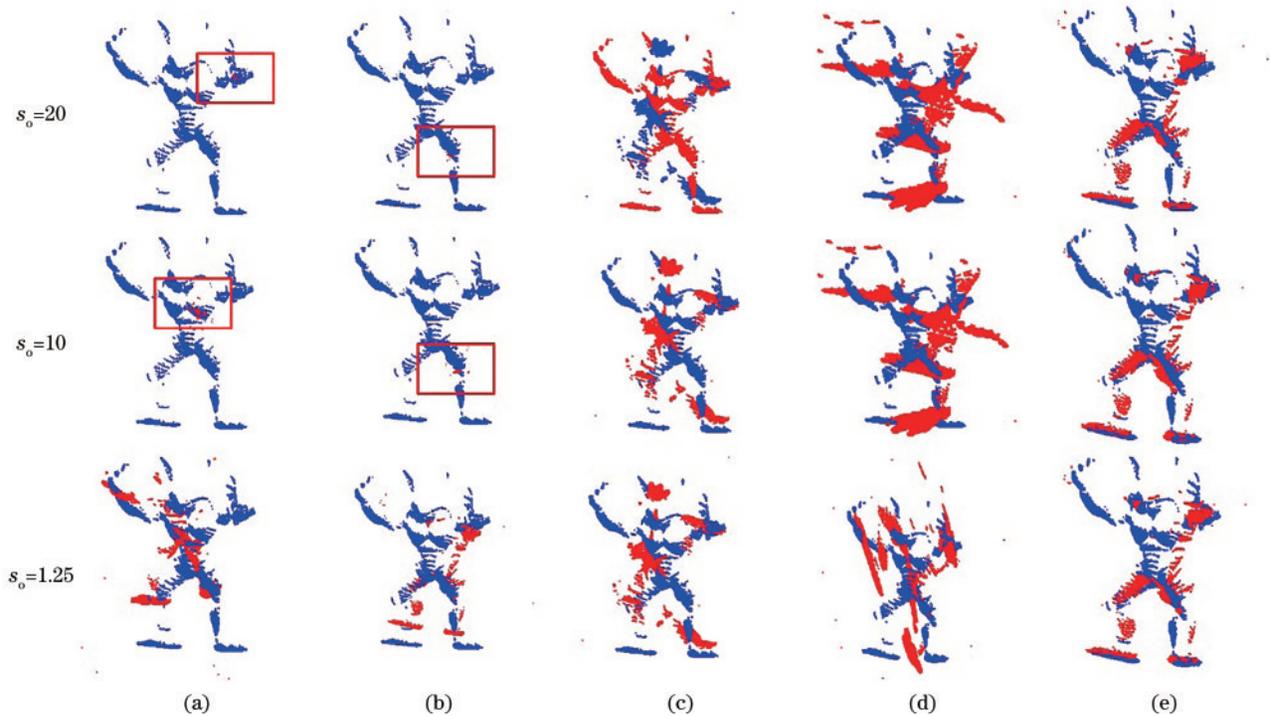


图 6 不同尺度因子下各算法对 Armadillo 点云的配准结果。(a)EBABC-RS-IR;(b)ICP;(c)Scale-ICP;(d)CPD;(e)所提算法  
 Fig. 6 Registration results of various algorithms for Armadillo point cloud under different scale factors. (a) EBABC-RS-IR; (b) ICP; (c) Scale-ICP; (d) CPD; (e) proposed algorithm

#### 4.2.2 白噪声环境下的配准

受设备、采集环境及目标物体的影响,采集到的点云数据中会存在一定的噪声。漂移点和孤立点这两种噪声由于数目少且离目标物体较远,对配准过程

的影响可忽略。对于超过预定扫描区域的噪声,可通过裁剪点云来降低对配准过程的影响。混杂在目标物体中的噪声点云难以去除,从而造成点云配准精度较低。为点云添加白噪声可较大程度地模拟混杂点

表 2 不同尺度缩放因子下各配准算法所求均方根误差值  
Table 2 RMSE for each registration algorithm with different scaling factors unit: mm

Point cloud	$s_0$	Scale-ICP	CPD	Proposed algorithm
Bunny	20	$1.425 \times 10^{-2}$	$2.127 \times 10^{-3}$	$1.970 \times 10^{-3}$
	10	$1.425 \times 10^{-2}$	$2.138 \times 10^{-3}$	$2.086 \times 10^{-3}$
	1.25	$1.425 \times 10^{-2}$	$2.152 \times 10^{-3}$	$1.985 \times 10^{-3}$
Armadillo	20	$1.503 \times 10^{-2}$	$1.652 \times 10^{-2}$	$8.525 \times 10^{-3}$
	10	$1.503 \times 10^{-2}$	$1.663 \times 10^{-2}$	$7.763 \times 10^{-3}$
	1.25	$1.503 \times 10^{-2}$	$1.629 \times 10^{-2}$	$7.758 \times 10^{-3}$

表 3 不同尺度缩放因子下各配准算法的使用时间  
Table 3 Time for each registration algorithm with different scaling factors unit: s

Point cloud	$s_0$	Scale-ICP	CPD	Proposed algorithm
Bunny	20	44.280	91.110	17.120
	10	43.449	91.470	17.670
	1.25	43.452	88.928	16.852
Armadillo	20	9.629	12.577	12.335
	10	9.306	15.457	11.416
	1.25	9.598	13.499	14.477

类型的点云噪声,从而有效验证所提算法的抗噪能力。

在图 4 所示的各组待配准点云数据的源点云中分别加入 20 dB、25 dB、30 dB 的白噪声,所提算法配准

后的结果如图 7 所示,噪声由大到小,配准后的点云边缘由模糊变清晰。在低噪声即 30 dB 的情况下,图 7(c)和图 7(f)所示的两组数据在各尺度差异下均能得到较好的配准效果。

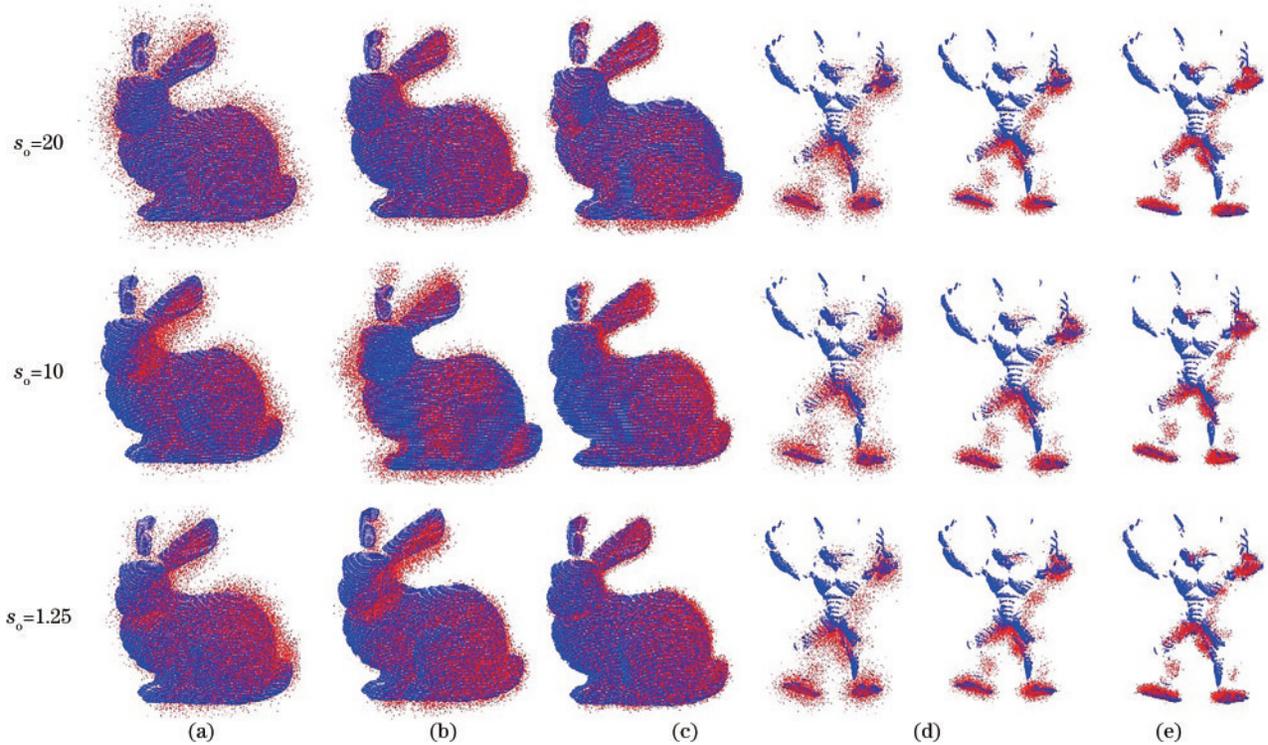


图 7 不同噪声下点云配准结果。(a)Bunny, 20 dB;(b)Bunny, 25 dB;(c)Bunny, 30 dB;(d)Armadillo, 20 dB;(e)Armadillo, 25 dB;(f)Armadillo, 30 dB

Fig. 7 Point cloud registration results under different noise. (a) Bunny, 20 dB; (b) Bunny, 25 dB; (c) Bunny, 30 dB; (d) Armadillo, 20 dB; (e) Armadillo, 25 dB; (f) Armadillo, 30 dB

不同白噪声干扰下,点云配准的均方根误差值和使用时间如表 4 和表 5 所示。对比表 2 和表 3 中无噪声情况下所提算法配准后求得的均方根误差值和所使用的时间,加噪声后整体的均方根误差值较大,使用时间变化不大。以 Bunny 点云在  $s_0 = 10$  的尺度差异下为例,三个不同分贝下的均方根误差值  $7.949 \times 10^{-3}$  mm、 $7.176 \times 10^{-3}$  mm、 $3.223 \times 10^{-3}$  mm 均大于不加噪声的均方根误差值  $2.086 \times 10^{-3}$  mm,使用时间相比于不加噪声时的 17.670 s 变化不大。

点云噪声越大,配准后的精度越低,而算法使用时间变化不大,直观配准结果图 7 中的每组点云,均实现了比较好的配准效果,因此精度的降低在可允许的范围内。综上,所提算法针对部分重叠的点云表现出一定的抗噪性。

#### 4.2.3 跨源点云配准

为验证所提算法在解决跨源点云配准问题中的有效性,采用背包、清华门和生科楼三组跨源点云进行配准,各组数据的点云相对状态如图 8 所示。其中背包

表 4 不同噪声干扰下所提算法所求均方根误差值

Table 4 RMSE of the proposed algorithm under different noise

unit: mm

Point cloud	$s_0$	20 dB	25 dB	30 dB	No noise
Bunny	20	$8.229 \times 10^{-3}$	$4.594 \times 10^{-3}$	$3.799 \times 10^{-3}$	$1.970 \times 10^{-3}$
	10	$7.949 \times 10^{-3}$	$7.176 \times 10^{-3}$	$3.223 \times 10^{-3}$	$2.086 \times 10^{-3}$
	1.25	$8.358 \times 10^{-3}$	$4.704 \times 10^{-3}$	$3.073 \times 10^{-3}$	$1.985 \times 10^{-3}$
Armadillo	20	$1.010 \times 10^{-2}$	$8.815 \times 10^{-3}$	$8.034 \times 10^{-3}$	$8.525 \times 10^{-3}$
	10	$1.032 \times 10^{-2}$	$1.129 \times 10^{-2}$	$8.155 \times 10^{-3}$	$7.763 \times 10^{-3}$
	1.25	$1.184 \times 10^{-2}$	$8.804 \times 10^{-3}$	$8.312 \times 10^{-3}$	$7.758 \times 10^{-3}$

表 5 不同噪声干扰下所提算法使用时间

Table 5 Time of the proposed algorithm under different noise

unit: s

Point cloud	$s_0$	20 dB	25 dB	30 dB	No noise
Bunny	20	20.279	20.879	19.432	17.120
	10	20.289	20.099	20.604	17.670
	1.25	20.617	19.997	17.419	16.852
Armadillo	20	14.045	14.774	14.308	12.335
	10	14.931	14.570	13.654	11.416
	1.25	14.098	14.826	13.956	14.477



图 8 待配准跨源点云的相对初始状态。(a)背包;(b)清华门;(c)生科楼

Fig. 8 Relative initial state of cross-source point clouds to be registered. (a) Bag; (b) Tsinghua gate; (c) Life science building

源点云和目标点云数据之间的尺度因子真实值是已知值 5,清华门、生科楼两组数据中源点云和目标点云数据之间的尺度因子值未知,以估计区间作为尺度因子可行域边界,设置为 $[0.1, 10]$ 。

配准结果如图 9~11 所示。针对背包点云数据,图 9 直观地表现出跨源点云数据在细节互补上的作用。在初始的点云图 3(a)和图 3(b)中,两处细节由不同的传感器获取到,配准后的三维模型更加完整。配准的均方根误差值为 0.016 mm,该值较小说明算法配准的精度较高,配准耗费时间为 8.490 s,所求尺度因

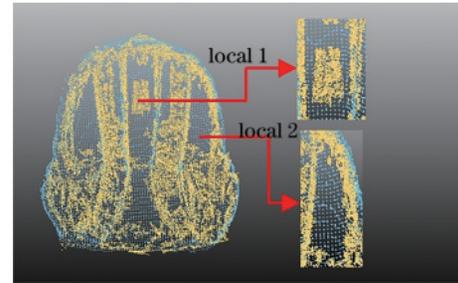


图 9 背包点云配准结果放大图

Fig. 9 Local amplification effect of Bag registration

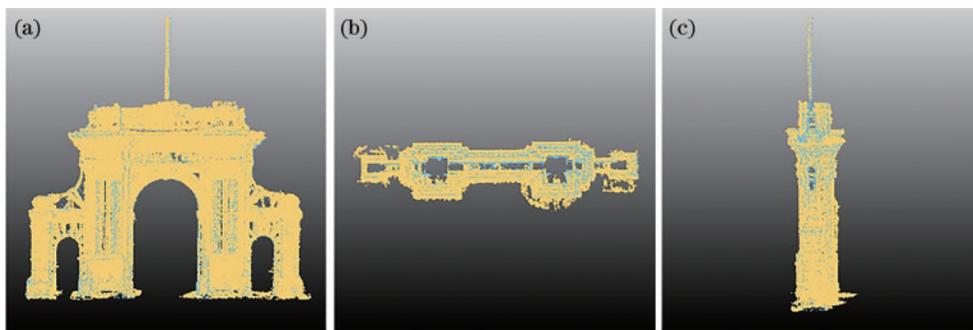


图 10 清华门点云配准结果。(a)主视角;(b)俯视角;(c)侧视角

Fig. 10 Tsinghua gate point cloud registration results. (a) Main perspective; (b) prone perspective; (c) side perspective

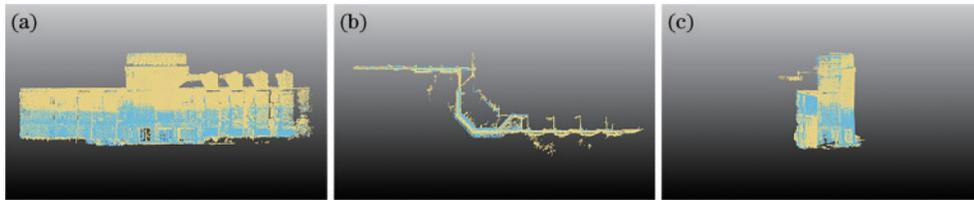


图 11 生科楼点云配准结果。(a)主视角;(b)俯视角;(c)侧视角

Fig. 11 Life science building point cloud registration results. (a) Main perspective; (b) prone perspective; (c) side perspective

子的值 4.998 与尺度因子的真实值 5 的相对误差为 0.04%。

清华门和生科楼均为建筑物点云数据,各片点云数据较大且待配准点云的数目也相差较大,图 10 和图 11 分别为从主、俯、侧三个不同视角观察的配准结果,边缘部分均未出现重影,建筑内部的镂空结构在配准后依然保留。所提算法对清华门点云配准所求得的均方根误差值为 0.191 mm,耗费时间为 72.799 s,所求尺度参数为 1.262。生科楼点云数目较大,造成配准结果的均方根误差值较大且耗费时间相对较长,其中均方根误差值为 0.574 mm,算法耗费时间为 263.731 s,所求尺度参数为 2.163,但在点云数目差异有 20 倍的情况下所提算法仍能成功配准。

综上,所提算法对有结构差异、点云数目相差较悬殊的跨源点云配准同样适用,同时也可以较高精度求出两片不同源点云配准之间的尺度因子值。

## 5 结 论

提出一种基于人工蜂群优化的异尺度点云配准方法,通过将点云配准的 7 个参数作为待求解量,用人工蜂群优化方法进行求解。采用带尺度的改进目标函数,相比于将欧氏距离作为目标函数,改进后的目标函数求解精度更高且求解结果更加稳定。相比于基于梯度、基于混合高斯模型、基于特征的异尺度点云配准方法,基于人工蜂群优化的方法在时间、精度上都具有优势。针对跨源点云配准,所提方法求解出尺度因子后实现了细节信息的互补,可进一步使用重建出来的完整模型进行纹理映射。

## 参 考 文 献

- [1] Li J Y, Hu Q W, Ai M Y. Point cloud registration based on one-point RANSAC and scale-annealing biweight estimation[J]. IEEE Transactions on Geoscience and Remote Sensing, 2021, 59(11): 9716-9729.
- [2] 张子健,程效军,曹宇杰,等.结合激光与视觉点云的古遗迹三维重建应用[J].中国激光,2020,47(11):1110001.  
Zhang Z J, Cheng X J, Cao Y J, et al. Application of 3D reconstruction of relic sites combined with laser and vision point cloud[J]. Chinese Journal of Lasers, 2020, 47(11): 1110001.
- [3] 林宝尉,王法胜,孙怡.基于SGICP的点云尺度估计及配准算法[J].计算机应用与软件,2018,35(5):202-207.  
Lin B W, Wang F S, Sun Y. Sgicp-based point cloud scale estimation and alignment algorithm[J]. Computer Applications and Software, 2018, 35(5): 202-207.
- [4] Wu Z Z, Chen H C, Du S Y, et al. Correntropy based scale ICP algorithm for robust point set registration[J]. Pattern Recognition, 2019, 93: 14-24.
- [5] 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.
- [6] Du S Y, Cui W T, Wu L Y, et al. Precise iterative closest point algorithm with corner point constraint for isotropic scaling registration[J]. Multimedia Systems, 2019, 25(2): 119-126.
- [7] 盛庆红,张斌,肖晖,等.直线簇约束下的地面LiDAR点云配准方法[J].武汉大学学报·信息科学版,2018,43(3):406-412.  
Sheng Q H, Zhang B, Xiao H, et al. A registration method based on line cluster for terrestrial LiDAR point clouds[J]. Geomatics and Information Science of Wuhan University, 2018, 43(3): 406-412.
- [8] 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.
- [9] Xu S, Shang Y L. ScaleLK: registration of point clouds with different scales using deep learning methods[J]. IOP Conference Series Materials Science and Engineering, 2020, 768(7): 072089.
- [10] 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.  
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.
- [11] 李绕波,袁希平,甘淑,等.一种基于对偶四元素描述的线面特征约束的点云配准方法[J].光学学报,2022,42(2):0214003.  
Li R B, Yuan X P, Gan S, et al. Point cloud registration method based on dual quaternion description of line-planar feature constraints[J]. Acta Optica Sinica, 2022, 42(2): 0214003.
- [12] Karaboga D, Basturk B. On the performance of artificial bee colony (ABC) algorithm[J]. Applied Soft Computing, 2008, 8(1): 687-697.
- [13] Chen L, Kuang W Y, Fu K. A resample strategy and artificial bee colony optimization-based 3d range imaging

- registration[J]. *Computer Vision and Image Understanding*, 2018, 175: 44-51.
- [14] 巩稼民, 刘芳, 吴艺杰, 等. 基于神经网络和人工蜂群算法的拉曼光纤放大器设计方案[J]. *光学学报*, 2021, 41(20): 2006002.
- Gong J M, Liu F, Wu Y J, et al. Design of Raman fiber amplifier based on neural network and artificial bee colony algorithm[J]. *Acta Optica Sinica*, 2021, 41(20): 2006002.
- [15] Rostami O, Kaveh M. Optimal feature selection for SAR image classification using biogeography-based optimization (BBO), artificial bee colony (ABC) and support vector machine (SVM): a combined approach of optimization and machine learning[J]. *Computational Geosciences*, 2021, 25(3): 911-930.
- [16] 马卫. 仿生群智能优化算法及在点云配准中的应用研究[D]. 南京: 南京大学, 2020: 82-114.
- Ma W. Bionic swarm intelligence optimization algorithm and its application in point clouds registration[D]. Nanjing: Nanjing University, 2020: 82-114.
- [17] Yi Z L, Li Y, Gong M L. An efficient algorithm for feature-based 3D point cloud correspondence search[M]// *Bebis advances in visual computing. Lecture notes in computer science*. Cham: Springer, 2016, 10072: 485-496.
- [18] Stanford Computer Graphics Laboratory. The Stanford 3D scanning repository[EB/OL]. [2022-05-26]. <http://graphics.stanford.edu/data/3Dscanrep/>.
- [19] University of Technology Sydney. Cross source registration benchmark[EB/OL]. [2022-05-26]. [http://multimediauts.org/3D\\_data\\_for\\_registration/](http://multimediauts.org/3D_data_for_registration/).
- [20] 机器视觉课题组. 三维重建数据集[EB/OL]. (2011)[2022-05-26]. <http://vision.ia.ac.cn/zh/data>.
- Machine vision research group. 3D reconstruction dataset [EB/OL]. (2011)[2022-05-26]. <http://vision.ia.ac.cn/zh/data>.
- [21] 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.
- [22] 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.