

基于主成分分析和特征图匹配的点云配准方法

郑伟斌¹, 练国富¹, 张学明¹, 郭方²

(1. 福建理工大学机械与汽车工程学院, 福建 福州 350118;

2. 福建理工大学计算机科学与数学学院, 福建 福州 350118)

摘要: 由于点云模型存在不同程度的重叠, 点云配准容易出现特征匹配错误、配准难度大等问题。因此, 提出了一种基于主成分分析和特征图匹配的点云配准方法。配准前, 首先采用带主轴校正的主成分分析方法进行点云初始位姿调整, 建立KD树进行重叠区域搜索。其次, 根据两幅点云的重叠区域计算采样点的快速点特征直方图特征, 进行点云特征图匹配以及裁剪迭代最近点精配准。在现有数据集以及实际扫描模型上进行配准实验, 实验结果表明该方法的稳定性好, 精度更高, 相较于其他算法精度能提高25%以上。

关键词: 重叠区域; KD树; 图匹配; 裁剪迭代最近点; 点云配准

中图分类号: TP391

文献标志码: A

doi: 10.11959/j.issn.2096-6652.202340

Point cloud registration method based on principal component analysis and feature map matching

ZHENG Weibin¹, LIAN Guofu¹, ZHANG Xueming¹, GUO Fang²

1. School of Mechanical and Automotive Engineering, Fujian University of Technology, Fuzhou 350118, China

2. School of Computer Science and Mathematics, Fujian University of Technology, Fuzhou 350118, China

Abstract: Due to varying degrees of overlap in point cloud models, point cloud registration is prone to problems, such as feature matching errors and high difficulty in registration. Therefore, a point cloud registration method based on principal component analysis and feature map matching is proposed. Before registration, the principal component analysis method with spindle correction was used to adjust the initial pose, then the K-dimensional tree was established to search the overlapping area. Secondly, the fast point feature histograms features of the sampling points were calculated according to the overlapping area of the two-point cloud, and the point cloud feature graph matching and trimmed iterative closest point (TrICP) fine registration were performed. Registration experiments were carried out according to the existing datasets and the actual scanning model. The experimental results show that the method has good stability and higher accuracy, and the accuracy can be improved by more than 25% compared with other algorithms.

Key words: overlapping region, K-dimension tree, graph matching, TrICP, point cloud registration

0 引言

随着激光扫描技术的普及, 各种激光扫描设备能够快速获得大量的物体表面3D点云。点云被广

泛应用于计算机视觉和工业设计, 包括自动驾驶、虚拟现实、三维重建等领域^[1-2]。然而在激光扫描过程中, 通常会产生多组不同视角捕获的点云, 需要通过点云配准技术将其转换到同一基准坐标

收稿日期: 2022-12-07; 修回日期: 2023-06-02

通信作者: 练国富, gflian@mail.ustc.edu.cn

基金项目: 福建省科技重大专项专题项目 (No.2020HZ03018)

Foundation Item: Science and Technology Major Project of Fujian Province (No.2020HZ03018)

系下。

国内外学者对点云配准技术进行了大量研究。Besl和Mckay^[3]提出的迭代最近点(iterative closest point, ICP)算法是点云配准领域的经典算法,该算法虽然精度较高,但是存在计算量大以及对点云的初始位置敏感等问题。目前,先进行粗配准再进行精配准的策略已经成为配准方法的主流。Zhong等人^[4]基于图形尺度不变特征(scale-invariant feature transform, SIFT)和点云快速点特征直方图(fast point feature histograms, FPFH)进行特征描述,选择与图像特征和几何特征相匹配的特征点来完成粗配准,再采用ICP算法实现精细配准,能有效避免ICP算法陷入局部最优解。张旭春等人^[5]基于FPFH提取多尺度特征的关键点,利用距离约束条件获取配准的初步变换矩阵,再通过ICP算法进行微调,该方法能有效适应不同规模的点云数据。Xu等人^[6]在特征匹配阶段采用了三维形状上下文(3D shape context, 3DSC)特征,较好地描述了点云的局部几何结构。Zaganidis等人^[7]采用三维正态分布变换(normal distributions transform, NDT)算法进行点云配准,按照平滑度将点云分区,在相同类型的分区上进行三维NDT算法,加快了配准速度。三维NDT算法的速度优于ICP算法,但是依然需要良好的初始位姿,否则也容易陷入局部极值。荆路等人^[8]提出一种一致性初始配准(sample consensus initial alignment, SAC-IA)方法,在NDT配准算法前先基于点云的FPFH特征进行采样以获得较好的初始变换矩阵。

虽然配准问题得到了广泛的关注,但是目前绝大多数方法依赖点云数据间的特征匹配,很少考虑到点云间重叠区域的问题。点云的重叠区域指两幅点云数据之间具有相同结构的区域。杜辉等人^[9]采用欧氏距离法对大面积点云进行分割来寻找重叠区域,使用二维正态分布模型的概率密度均值表示子点云特征,进行子点云间的特征匹配。李鑫等人^[10]对裁剪ICP(TrICP)算法进行改进,在迭代过程中根据距离曲线的斜率特性自动计算并更新重叠度,该算法的精度与抗噪声能力都显著提高。Li等人^[11]根据几何结构特点将点云分块,构建每个点云块的多维形状描述符,根据描述符的相似性搜索点云间的重叠区域,但当点云相似结构较多时容易发生错误匹配。在配准算法执行过程中,进行特征匹配的点对如果不是从两幅点云的重叠区域中寻

找,则会出现大量无意义的错误对应点对。在重叠率低于60%时,配准难度加大,此类更具挑战性的低重叠的点云配准情况在很大程度上被忽视了^[12-13]。在实际应用中,低重叠的点云配准情况并不少见,一方面,由于激光扫描过程中会存在遮挡等问题,很难保证每次扫描都具有较高的重叠率;另一方面,点云数据的获取成本较高,低重叠的点云能减少点云片段的数量,减少配准的工作量。在深度学习方面,Wang和Solomon^[14]设计了一种深度最近点(deep closest point, DCP)网络结构,通过结合注意力机制的端到端深度网络学习点云之间的位置变换关系,在ModelNet40数据集^[15]上获得了较高的配准精度,但DCP网络在重叠率不高的点云上的配准效果还有待提高。Fu等人^[16]提出基于学习的深度图匹配框架,将点云转换为图并提取深度特征,利用图匹配计算点之间的一对一关系。这种方式考虑了每个点的局部结构,找到了更准确的对应关系。Huang等人^[17]提出了一种Predator网络结构,专门用于低重叠率的点云配准,该网络模型能够比对输入点云之间的结构信息,深入关注重叠区域,可以预测出位于两幅点云重叠区域的关键点并进行匹配,在低重叠场景下配准成功率较高。但是,基于深度学习网络的方法需要大量相似点云数据的训练,对于多样性的点云配准应用场景来说,成本较高,适用范围较窄。

基于以上研究,本文提出了一种基于两幅点云之间重叠区域搜索匹配的点云配准方法,采用改进后的主成分分析方法进行点云初始位姿调整,再结合KD树进行重叠区域搜索,根据点云整体结构特点进行分割,使参与特征匹配的点云集中于重叠区域。在重叠区域基于点云的局部特征进行图匹配的方式能找到更准确的点对应关系,提高配准的成功率和精度。

1 配准流程

本文方法的流程图如图1所示。在粗配准阶段的特征匹配前确定两幅点云的重叠区域,首先利用带主轴方向判定的主成分分析(principal components analysis, PCA)方法对点云的初始位姿进行调整,再通过KD树近邻搜索算法寻找两幅点云的重叠区域。然后,采用基于重叠区域点云FPFH特征的图匹配算法进行对应关系搜索,再利用M估计样本一致性(M-estimate sample consensus, MSAC)

算法计算最优变换矩阵。上述操作可实现粗配准效果，显著减少点云之间的旋转和平移误差，防止后续的精配准陷入局部最优。最后，将上述步骤获得的重叠区域进行重叠率计算，并采用 TrICP 算法进行点云精配准。




图1 配准流程

2 确定重叠区域

2.1 点云位姿初始对齐

利用主成分分析 PCA 算法对两组点云数据进行初始位姿调整，以便寻找重叠区域。PCA 是一种鲁棒的数据降维方法，对噪声的敏感性较低，能够处理高维图像数据^[18]。基于 PCA 的初始配准方法，主要在点云数据的 3 个主轴方向进行配准。该方法计算移动点云整体协方差矩阵的特征向量，选取其中特征值最高的 3 个主成分，与基准点云的特征向量对应配准。

计算点云数据 PCA 的算法步骤如下。

步骤1 将基准点云记为 P，移动点云记为 Q。移动点云 Q 中的点 $q_i = (x_i, y_i, z_i)^T$, $i \in (1, 2, \dots, n)$ ，计算移动点云的重心坐标，如式 (1) 所示。

$$\bar{q} = \frac{1}{n} \sum_{i=1}^n q_i \quad (1)$$

步骤2 计算移动点云 Q 的协方差矩阵 C_Q 。

$$C_Q = \frac{1}{n} \sum_{i=1}^n (q_i - \bar{q})(q_i - \bar{q})^T = \frac{1}{n} \begin{bmatrix} q_1 - \bar{q} \\ \vdots \\ q_n - \bar{q} \end{bmatrix} \begin{bmatrix} q_1 - \bar{q} \\ \vdots \\ q_n - \bar{q} \end{bmatrix}^T \quad (2)$$

步骤3 利用 SVD 分解法可以将协方差矩阵 C_Q 分解成 3 个特征主分量 ($v_{q_1}, v_{q_2}, v_{q_3}$)，对应的特征值按照降序排序，即 $\lambda_{q_1} \geq \lambda_{q_2} \geq \lambda_{q_3}$ 。

以同样的步骤计算基准点云 P 的协方差矩阵 C_P 及其 3 个特征主分量 ($v_{p_1}, v_{p_2}, v_{p_3}$)。将移动点云 Q 与基准点云 P 的特征主分量矩阵分别记为 $V_Q = [v_{q_1}, v_{q_2}, v_{q_3}]^T$ 与 $V_P = [v_{p_1}, v_{p_2}, v_{p_3}]^T$ 。 V_Q 和 V_P 即代表了点云 P 和 Q 的 3 个主方向信息，通过三维转换公式求出移动点云 Q 到基准点云 P 的变换参数 R_0, T_0 ：

$$R_0 = V_P V_Q^{-1}, T_0 = \bar{q} - R_0 \bar{p} \quad (3)$$

通过 PCA 得到了初始的旋转矩阵和平移向量，然而由于 3 个特征主分量可以看作 1 个新坐标轴，当进行主方向对齐时，容易出现主轴反向的情况^[19]。如图 2 所示，以 Bunny 模型的两幅扫描点云为例，其中蓝色表示基准点云，红色表示移动点云。左图为主轴正向情况，模型初始对齐；右图为其 1 个主轴发生反向的情况。由于 3 个轴的方向都可能存在反向的问题，因此一共有 2^3 种情况。该方法通过计算转换后的均方误差自动判断主轴的正反向情况，解决主轴反向问题。转换后移动点云和基准点云的均方误差计算方法如下。




图2 主轴反向情况

$$\text{err}_{\text{RMSE}} = \frac{1}{n} \sum_{i=1}^n |q_i^{\text{new}} - p_i|^2 \quad (4)$$

式中 q_i^{new} 是转换后的移动点云，计算每种情况下的均方误差 err_{RMSE} ，取最小的均方误差对应的变换参数 R_0, T_0 作为最优的初始变换参数。

2.2 重叠区域搜索

在配准过程中，点云的重叠区域往往更受关注。对应点匹配的前提是对应点在两个点云的重叠区域内，这样找到的对应点才是真实有效的。本文采用KD树算法^[20]来进行最近点搜索，加快找到点云重叠区域的速度。

经过点云主轴初始对齐后，利用KD树来搜索移动点云与基准点云的重叠区域。KD树是一种二叉树，构造KD树的目的是为了对K维空间中的实例点进行存储以便快速检索。图3是利用KD树进行近邻搜索的原理图，对基准点云P构建KD树结构，对移动点云Q中的每个点 q_i ，通过KD树搜索基准点云中与其最接近的点 p_i 。统计移动点云中的每个点 q_i 与基准点云中的最近邻点 p_i 的欧氏距离dist，欧氏距离统计直方图如图4所示。




图3 近邻搜索




图4 欧氏距离统计

移动点云的重叠区域具体检索策略如下。

步骤1 根据距离统计图选取合适的距离阈值 t ，当 $\text{dist} < t$ 时，将点 q_i 的集合作为移动点云的重叠区域，该最近邻点 p_i 的集合作为基准点云的初始重叠区域内点。以 45° Bunny移动点云和 0° Bunny基准点云为例，图5是不同阈值下的点云初始重叠区域。其中，左边为移动点云，红色区域为移动点云中的重叠区域；右边为基准点云，绿色区域为基准




图5 不同阈值下的点云初始重叠区域

点云中的重叠区域。

步骤2 由于点云数据的不规则性和噪点的存在，步骤1中通过最近邻确定的 p_i 存在多对一的情况，因此其重叠区域是稀疏的，还有大量重叠区域的点未被检测出来。为了找到更加完整的基准点云重叠区域，需要对其中未被识别到的点进行二次检索。

对基准点云中的每个点 p_i ，根据点 p_i 最近的 k 个近邻点构建内点评价函数：

$$\tau_i = \sum_{j=1}^k (p_i - p_j)^2, j=1, 2, \dots, k \quad (5)$$

式(5)中， p_j 是步骤1中找到的重叠区域中的点，当求得的 τ_i 小于设置的阈值时，则点 p_i 周围存在较多重叠区域中的点，可以认为该点也是重叠区域中的点。通过这种方法，可以将步骤1中的重叠区域进行扩充，使找到的重叠区域更加完整。

同理，进行基准点云的重叠区域寻找。经过重

叠区域检索后,可以将点云划分为重叠区域和非重叠区域,移动点云的重叠区域记为 C_Q ,基准点云的重叠区域记为 C_P 。

3 点云特征图匹配

基于特征图匹配 (feature graph matching, FGM) 的方法通过构造图的节点和边之间的相似性函数来实现图之间的最优对应关系。本文利用重叠区域中点云的 FPFH 特征^[21],将图匹配方法应用于点云配准中,图的边长为点云重叠区域采样点数量 n 。用权重矩阵表示点云特征图,记为 M_{nn} 。图6为图匹配过程中采样点对应关系与其权重矩阵的可视化结果。




图6 点云特征图匹配

首先选取采样点。在移动点云和基准点云的重叠区域 C_Q 与 C_P 中各选取 n 个数据点,本文采用的方法为最远点采样算法:

- (1) 以区域中一个数据点 q_0 作为初始采样点,计算区域内所有点到 q_0 的距离;
- (2) 选取距离中最大值对应的点作为采样点 q_1 ,此时的采样点集合为 $L=(q_0, q_1)$;
- (3) 计算剩下的每个点到采样点集合 L 的距离,同样以最大值对应的点作为采样点 q_2 ,更新采样点集合 $L=(q_0, q_1, q_2)$;
- (4) 重复步骤(2)、(3),直至采样点集合 L 中点数为 n ,移动点云、基准点云中的采样点分别记为 $p_i, p_j, i, j \in 1, \dots, n$ 。

最远点采样算法使得各采样点之间的距离较大,保证各采样点的局部特征均不相同。然后,计算采样点的 FPFH 特征。FPFH 特征是点云的一种几何特征描述符,基于采样点与其周围的 k 个点来描述该局部区域的点云结构信息,具有较强的稳定性和辨识度。采样点 q_i 的 FPFH 特征计算式如下:

$$\text{FPFH}(q_i) = \text{SPFH}(q_i) + \frac{1}{k} \sum_{i=1}^k \left(\frac{1}{\omega_k} \cdot \text{SPFH}(q_k) \right) \quad (6)$$

FPFH 的计算过程与简单点特征直方图 (simple point feature histogram, SPFH) 相结合,SPFH 计算

邻域内相邻点之间的几何特征关系,由 $(\alpha, \varphi, \theta)$ 三元组构成,其中 α, θ 代表邻域点 q_k 的法向量与局部坐标系 x 轴、 y 轴形成的角度, φ 代表采样点 q_i 的法向量与 q_i, q_k 连线方向形成的角度。 ω_k 代表在给定区域中采样点 q_i 与其近邻点 q_k 之间的距离权值。

为了从权重矩阵中获得精确的采样点对应关系,基于 p_i 与 p_j 的 FPFH 特征定义了一个角向量 $\theta = \cos^{-1}(p_i, p_j)$,以及特征空间的欧氏距离函数 d ,权重矩阵的计算过程如下:

$$M_{ij} = \cos(p_i, p_j) - d(p_i, p_j) \quad (7)$$

$$\cos(p_i, p_j) = \frac{V_i \cdot V_j}{\|V_i\| \cdot \|V_j\|}, d(p_i, p_j) = \|V_i - V_j\|$$

其中, V_i, V_j 代表移动点云和基准点云的 FPFH 特征。在权重矩阵范围内, p_i 与 p_j 角向量 θ 的余弦相似性越高,欧氏距离函数 d 的值越小,代表其权重赋值 M_{ij} 越高,估计的点对应关系越准确。给定阈值 ε_1 ,将 $M_{ij} > \varepsilon_1$ 时的 p_i 与 p_j 点索引作为最优的点对应关系。采用 MSAC 算法从点对应关系中求解最优对应关系的变换矩阵。

4 TrICP 点云精配准

为进一步提高配准精度,本文采用 TrICP 算法进行精配准。TrICP 算法是 Chetverikov 等人^[22]提出的一种 ICP 算法的改进算法,核心思想是引入点云重叠度 φ ,在迭代过程中去除非重叠区域的点,所以经典 ICP 算法是 $\varphi=1$ 时的特殊情况。TrICP 适用于部分重叠的三维点集配准,有效解决了重叠率不高时 ICP 算法容易陷入局部最优解导致配准失败的问题,具有较高的鲁棒性和配准精度。在 TrICP 算法执行过程中,重叠度 φ 一般通过人为经验给出,而不同的 φ 对 TrICP 的计算结果影响较大。通过第3节求得的点云重叠区域来计算 φ ,能获得合理、可信度高的重叠度。为此,改进重叠度计算后的 TrICP 的算法步骤如下。

- (1) 根据先前求得的重叠区域计算点云的重叠率为:

$$\varphi = \frac{M_{C_Q} + N_{C_P}}{M + N} \quad (8)$$

其中, M 是移动点云的总点数, N 是基准点云的总点数, M_{C_Q} 是移动点云重叠区域的点个数, N_{C_P} 是基准点云重叠区域的点个数。

(2) 对移动点云中所有点 q_i 查找其在基准点云中的最近邻点 p_i , 计算各点对之间的距离平方 D_i^2 并进行排序, 即 $D_1^2 < D_2^2 < \dots < D_i^2$; 根据重叠率提取排列在前 N_o 个的对应点集, $N_o = \varphi N$, 并计算它们的距离平方和 D_{sum} :

$$D_{\text{sum}} = \sum_{i=1}^{N_o} D_i^2 \quad (9)$$

(3) 通过奇异值分解 (singular value decomposition, SVD) 法计算旋转变换矩阵 (R, T) , 使得距离平方和函数 D_{sum} 最小, 求得的变换矩阵为:

$$(R, T) = \operatorname{argmin} \sum_{i=1}^{N_o} [p_i - (Rq_i + T)]^2 \quad (10)$$

(4) 对移动点云 Q 进行三维变换 $Q' = RQ + T$, 计算配准误差 $MSE = D_{\text{sum}} / N_o$, 重复步骤 (2)、(3)、(4), 进行迭代计算, 当配准误差小于给定阈值或者达到最大迭代次数时, 精配准结束。

5 实验与分析

本文实验环境为 Inter Core i7-7700 CPU 8G RAM 计算机, 使用 Visual Studio2019 以及 Matlab 软件, 开源点云库版本为 PCL 1.12.1。为验证本文提出的算法的准确性和有效性, 在点云数据 Bunny (兔子)、Dragon (龙) 以及 7-Scenes 室内场景点云上进行仿真实验。参与实验的点云数据的重叠区域大小各不相同, 且重叠率都低于 60%。不同的重叠率有助于对本文算法进行全面的稳定性与精度测试。

表 1 为 Bunny、Dragon 以及 7-Scenes 室内场景点云的模型参数, Q 代表移动点云, P 代表基准点云。利用带主轴校正的主成分分析方法对各点云数据进行位姿初始对齐, 再确定点云重叠区域。图 7 为各点云数据的初始位姿以及进行主轴对齐后的结果。

在点云主轴对齐的基础上, 采用本文的重叠区域搜索算法寻找重叠区域。图 8 为各点云重叠区域可视化结果, 绿色区域表示基准点云的重叠区域,




图7 初始位姿对齐

红色区域表示移动点云的重叠区域。在进行重叠区域搜索时, 设置 Bunny、Dragon 模型点云的距离阈值 $t=0.02$, 7-Scenes 室内场景点云的距离阈值 $t=0.3$ 。




图8 点云重叠区域

表1 点云数据参数细节

模型	重叠率	点数/个	质心位置
Bunny	31%	Q: 40 097	0.0104, 0.0984, 0.0606
		P: 30 379	-0.0064, 0.1027, 0.0064
Dragon	44%	Q: 41 841	-0.0044, 0.1157, 0.0058
		P: 22 092	0.0045, 0.1145, 0.0114
7-Scenes 室内场景	58%	Q: 291 605	0.1772, -0.3775, 2.0563
		P: 268 376	0.5535, -0.1114, 2.0154

本文提出的算法 FGM+TrICP 根据重叠区域进行特征图匹配, 再进行点云精配准。将本文算法与传统 ICP 算法和文献[8]、文献[11]、文献[16]的算法进行对比。其中, 文献[8]采用了 SAC-IA 粗配准与三维正态分布变换精配准相结合的配准方法,

文献[11]同样采用先确定重叠区域再进行配准的策略,文献[16]采用了基于深度学习的配准算法,这些方法都获得了较好的配准结果。图9是各点云数据配准后的可视化结果。表2展示了各个配准算法的精度与时间。从配准时间可以看出,本文方法配准花费的时间较少,这得益于KD树搜索算法;基于学习的方法虽然在部分情况下配准时间优于本文算法,但是需要预先训练模型,适用范围较窄。在配准误差方面,传统ICP算法能获得较高的精度,但当两幅点云的重叠率较低以及初始位姿较差时,如Bunny点云,ICP算法会收敛到局部最优解,直接导致配准失败;本文方法的配准误差均小于其他3种方法,获得了较好的配准精度,对比ICP算法,Bunny、Dragon和7-scenes室内场景点云的配准误差分别降低了83.65%、23.25%、14.79%。由于本文方法预先进行了初始位姿对齐以及重叠区域计算,在处理不同重叠度、初始位姿差的点云时均能获得理想的配准效果。

图10是Bunny点云经过各算法配准后的距离




图9 配准结果可视化

表2 点云数据配准误差分析

点云数据	配准算法	配准误差MSE	时间/s
Bunny	ICP	11.104×10^{-4}	32.1
	文献[8]	1.922×10^{-4}	25.4
	文献[11]	2.129×10^{-4}	19.2
	文献[16]	2.562×10^{-4}	17.9
	FGM+TrICP	1.816×10^{-4}	15.2
Dragon	ICP	5.165×10^{-5}	28.7
	文献[8]	6.080×10^{-5}	22.1
	文献[11]	4.557×10^{-5}	18.9
	文献[16]	6.921×10^{-5}	13.5
	FGM+TrICP	3.964×10^{-5}	14.3
7-Scenes 室内场景	ICP	2.413×10^{-3}	42.7
	文献[8]	3.458×10^{-3}	32.7
	文献[11]	2.556×10^{-3}	25.1
	文献[16]	2.388×10^{-3}	22.0
	FGM+TrICP	2.056×10^{-3}	19.8

误差热图,颜色越浅的区域代表点云间的距离越小,误差也越小。可以看到,本文方法在两幅点云的重叠区域均获得了最小的距离误差。ICP算法陷入了局部最优解,重叠区域的距离误差较大;而其他3种算法在Bunny的耳朵、头部、尾部等均有不同程度的错位。

除此之外,在两组大场景建筑物点云集上验证本文算法对复杂数据的配准鲁棒性。这些建筑物点云来自Bremen city、Wue city数据集,是经过Riegl VZ-400激光雷达扫描得到的^[23]。这些点云数据具有千万级别的点数据以及复杂的空间结构,研究建筑物点云的配准效果对于城市三维重建具有重要意义。两组建筑物点云的重叠率分别为47%与36%,运用本文方法的配准结果如图11所示。各个配准算法在建筑物点云上的配准误差如表3所示,在建筑物点云的配准实验中,本文方法获得了很好的配准效果。

为验证所提算法在实际场景的可行性,采用三维激光扫描仪获取铸造齿轮箱的点云数据,根据本文算法进行配准。不同视角的齿轮箱体点云如图12所示。该齿轮箱体两幅视图点云的总点数超过27万,将一幅作为基准点云,另一幅作为移动点云。

采用本文方法对齿轮箱体点云进行初始位姿调整以及重叠区域搜索,设置距离阈值为 $t=0.03$,移动点云与基准点云的重叠区域如图13所示,重叠率为55%,可以看到本文方法找到的重叠区域大致




图10 Bunny点云误差热图

正确。

同样与传统ICP算法和文献[8]、文献[11]以及文献[16]的算法进行对比,配准结果如图14所示,配准误差如表4所示。传统ICP算法配准后的箱体有错位现象,配准失败;而文献[11]方法与文献[16]方法配准后存在较大误差;文献[8]方法配准误差较低,但配准时间较长。本文基于重叠区域的FGM+TrICP方法获得了最低的配准误差,且花费的配准时间也较少,能满足实际场景应用。

6 结论

针对不同重叠率的点云配准稳定性差、配准精度低等问题,提出基于主成分分析和特征图匹配的点云配准方法。提出了一种重叠区域搜索算法,在配准前采用PCA进行初始位姿调整,再构建两幅点云的KD树,同时,设置距离阈值来提高找到重叠区域的准确率。在特征匹配阶段,在重叠区域上基于FPFH特征描述符构建权重矩阵进行图匹配,能够有效提高点对应关系的搜索成功率,降低错误




图11 建筑物点云配准效果

表3 建筑物点云配准误差分析

点云数据	配准算法	配准误差MSE	时间/s
Bremen city	ICP	7.208	185.7
	文献[8]	1.055	115.6
	文献[11]	0.566	75.3
	文献[16]	1.489	68.6
	FGM+TrICP	0.102	70.2
Wue city	ICP	12.054	192.3
	文献[8]	1.244	105.7
	文献[11]	0.987	77.9
	文献[16]	1.442	69.1
	FGM+TrICP	0.635	67.5

点对的比例。通过重叠区域计算出重叠率,再将其应用于TrICP精配准,对配准结果进行微调,再次提高精度。实验结果表明,本文方法能够有效适应不同重叠率下的点云配准情况,具有较高的配准精



图12 齿轮箱体点云



图13 齿轮箱体重叠区域




图14 箱体点云配准结果

表4 齿轮箱体点云配准误差分析

点云数据	配准算法	配准误差MSE	时间/s
齿轮箱体	ICP	7.411×10^{-4}	39.8
	文献[8]	4.513×10^{-4}	32.7
	文献[11]	5.253×10^{-4}	21.4
	文献[16]	5.770×10^{-4}	16.5
	FGM+TrICP	2.593×10^{-4}	17.2

度，为三维重建领域提供了理论指导。本文方法的运行效率还需要进一步提高，后续将进行时间复杂

度的优化研究。

参考文献：

- [1] 李博洋, 刘思健, 崔明月, 等. 基于最小回环检测的多车协同SLAM框架[J]. 电子学报, 2021, 49(11): 2241-2250.
LI B Y, LIU S J, CUI M Y, et al. Multi-vehicle collaborative SLAM framework for minimum loop detection[J]. Acta Electronica Sinica, 2021, 49(11): 2241-2250.
- [2] DONG Z, LIANG F X, YANG B S, et al. Registration of large-scale terrestrial laser scanner point clouds: a review and benchmark[J]. ISPRS Journal of Photogrammetry and Remote Sensing, 2020, 163: 327-342.
- [3] BESL P J, MCKAY N D. Method for registration of 3-D shapes[C]// Proceedings of SPIE 1611, Sensor Fusion IV: Control Paradigms and Data Structures. Washington: SPIE, 1992, 1611: 586-606.
- [4] ZHONG L S, YING J, YANG H M, et al. Triple screening point cloud registration method based on image and geometric features[J]. Optik, 2021, 246: 167763.
- [5] 张旭春, 周洪军, 郑津津, 等. 基于多尺度特征及点距离约束的点云配准[J]. 激光与光电子学进展, 2021, 58(24): 325-333.
ZHANG X C, ZHOU H J, ZHENG J J, et al. Point cloud registration based on multi-scale features and point distance constraints[J]. Laser & Optoelectronics Progress, 2021, 58(24): 325-333.
- [6] XU G X, PANG Y J, BAI Z X, et al. A fast point clouds registration algorithm for laser scanners[J]. Applied Sciences, 2021, 11(8): 3426.
- [7] ZAGANIDIS A, MAGNUSSON M, DUCKETT T, et al. Semantic-assisted 3D normal distributions transform for scan registration in environments with limited structure[C]//Proceedings of 2017 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS). Piscataway: IEEE Press, 2017: 4064-4069.
- [8] 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.
- [9] 杜辉, 郑长亮, 苗春雨, 等. 一种动态特征匹配的部分重叠点云配准方法[J]. 电信科学, 2021, 37(4): 97-107.
DU H, ZHENG C L, MIAO C Y, et al. A partial overlapping point cloud registration method based on dynamic feature matching[J]. Telecommunications Science, 2021, 37(4): 97-107.
- [10] 李鑫, 莫思特, 黄华, 等. 自动计算重叠度的多源点云配准方法[J]. 红外与激光工程, 2021, 50(12): 260-268.
LI X, MO S T, HUANG H, et al. Multi-source point cloud registration method for automatically calculating overlap degree[J]. Infrared and Laser Engineering, 2021, 50(12): 260-268.
- [11] LI J, QIAN F, CHEN X F. Point cloud registration algorithm based on overlapping region extraction[J]. Journal of Physics: Conference Series, 2020, 1634(1): 012012.
- [12] 张元, 李晓燕, 韩燮. 一种低重叠率的三维点云配准方法[J]. 激光与光电子学进展, 2021, 58(8): 162-171.
ZHANG Y, LI X, HAN X. Three-dimensional point cloud registration method with low overlap rate[J]. Laser & Optoelectronics Progress, 2021, 58(8): 162-171.
- [13] POIESI F, BOSCAINI D. Learning general and distinctive 3D local deep descriptors for point cloud registration[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2023, 45(3): 3979-3985.

- [14] WANG Y, SOLOMON J. Deep closest point: learning representations for point cloud registration[C]//Proceedings of 2019 IEEE/CVF International Conference on Computer Vision (ICCV). Piscataway: IEEE Press, 2020: 3522-3531.
- [15] WU Z R, SONG S R, KHOSLA A, et al. 3D ShapeNets: a deep representation for volumetric shapes[C]//Proceedings of 2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Piscataway: IEEE Press, 2015: 1912-1920.
- [16] FU K X, LIU S L, LUO X Y, et al. Robust point cloud registration framework based on deep graph matching[C]//Proceedings of 2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Piscataway: IEEE Press, 2021: 8889-8898.
- [17] HUANG S Y, GOJCIC Z, USVYATSOV M, et al. PREDATOR: registration of 3D point clouds with low overlap[C]//Proceedings of 2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Piscataway: IEEE Press, 2021: 4265-4274.
- [18] CHENG D Y, ZHAO D J, ZHANG J C, et al. PCA-based denoising algorithm for outdoor lidar point cloud data[J]. Sensors, 2021, 21(11): 3703.
- [19] 王来强, 包静. 附加主方向判定的PCA点云数据初始配准算法[J]. 测绘地理信息, 2021, 46(6):59-62, 66.
- WANG L Q, BAO J. Initial registration algorithm for PCA point cloud data with additional main direction decision[J]. Journal of Geomatics, 2021, 46(6): 59-62, 66.
- [20] LIU J, ZHU J W, YANG J L, et al. Three-dimensional point cloud registration based on ICP algorithm employing K-D tree optimization[C]//Proceedings of Eighth International Conference on Digital Image Processing (ICDIP 2016). Washington: SPIE, 2016, 10033: 872-876.
- [21] RUSU R B, BLODOW N, BEETZ M. Fast point feature histograms (FPFH) for 3D registration[C]//Proceedings of 2009 IEEE International Conference on Robotics and Automation. Piscataway: IEEE Press, 2009: 3212-3217.
- [22] CHETVERIKOV D, SVIRKO D, STEPANOV D, et al. The trimmed iterative closest point algorithm[C]//Proceedings of 2002 International Conference on Pattern Recognition. Piscataway: IEEE Press, 2002: 545-548.
- [23] LI J Y, HU Q W, AI M Y. Point cloud registration based on one-point RANSAC and scale-annealing biweight estimation[J]. IEEE Transac-

tions on Geoscience and Remote Sensing, 2021, 59(11): 9716-9729.

[作者简介]



郑伟斌 (1998-), 男, 福建理工大学机械与汽车工程学院硕士生, 主要研究方向为计算机视觉与三维重建。



练国富 (1980-), 男, 博士, 福建理工大学机械与汽车工程学院教授, 主要研究方向为增材制造技术与机器视觉。



张学明 (1996-), 男, 福建理工大学机械与汽车工程学院硕士生, 主要研究方向为计算机视觉与深度学习。



郭方 (1977-), 男, 博士, 福建理工大学计算机科学与数学学院副教授, 主要研究方向为计算机视觉、大数据处理与分析。