

基于关键点提取与优化迭代最近点的点云配准

彭真^{1,2}, 吕远健^{1,2}, 渠超^{1,2}, 朱大虎^{1,2*}

¹武汉理工大学现代汽车零部件技术湖北省重点实验室, 湖北 武汉 430070;

²武汉理工大学汽车零部件技术湖北省协同创新中心, 湖北 武汉 430070

摘要 对强噪声且密度不均匀的点云进行高效、高精度配准是一个难题。针对此难题, 提出一种基于关键点提取与优化迭代最近点(ICP)的点云配准算法。在粗配准中, 将体素格滤波与法向距离关键点的提取相结合, 计算关键点的快速点特征直方图以进行特征匹配, 然后采用对应关系估计优化随机采样一致性(RANSAC)算法以进行误匹配剔除。在精配准中, 采用最优节点优先(BBF)算法搜索 k -d tree 最近点, 设定动态阈值消除误配对, 最后利用基于“点到三角面”模型的加速 ICP 算法计算配准向量。通过对模型点云和建筑物点云进行配准, 将所提算法与其他常用的算法进行比较分析。实验表明, 所提算法具有良好的稳健性和抗噪性, 能显著提升配准速度和配准精度。

关键词 图像处理; 点云配准; 特征点提取; 迭代最近点; 快速点特征直方图

中图分类号 TP391.7 文献标志码 A

doi: 10.3788/LOP57.061002

Accurate Registration of 3D Point Clouds Based on Keypoint Extraction and Improved Iterative Closest Point Algorithm

Peng Zhen^{1,2}, Lü Yuanjian^{1,2}, Qu Chao^{1,2}, Zhu Dahu^{1,2*}

¹Hubei Key Laboratory of Advanced Automotive Components Technology, Wuhan University of Technology, Wuhan, Hubei 430070, China;

²Hubei Collaborative Innovation Center for Automotive Components Technology, Wuhan University of Technology, Wuhan, Hubei 430070, China

Abstract Registering highly efficient and accurate point clouds with strong noise and inhomogeneous density remains a challenging task. In this paper, we propose a point cloud registration algorithm based on keypoint extraction and the improved iterative closest point (ICP). In coarse registration, we first fused the voxel grid filtering and normal distance keypoint extraction and then computed the fast point feature histogram of keypoints for feature matching. Then the random sampling consistency (RANSAC) algorithm was estimated and optimized by correspondent relation for eliminating mismatches. In fine registration, we implemented the best bin first (BBF) algorithm to search for the nearest point of k -d tree and set the dynamic threshold to eliminate wrong point pairs. Finally, we used the improved accelerated ICP algorithm based on the “point-to-triangle plane” model to obtain the registration vector. By registering the model point cloud and building point cloud, we compared the proposed algorithm with other commonly used algorithms. The results demonstrate that the proposed algorithm is robust against noise, and in particular, the running speed and registration accuracy are enhanced.

Key words image processing; point cloud registration; keypoint extraction; iterative closest point; fast point feature histogram

OCIS codes 100.2000; 100.3008; 100.6890

收稿日期: 2019-06-17; 修回日期: 2019-07-28; 录用日期: 2019-08-20

基金项目: 国家重点研发计划(2017YFB1303403)、国家自然科学基金(51675394)、数字制造装备与技术国家重点实验室(DMETKF2018018)、“111”工程(B17034)

* E-mail: dhzhu@whut.edu.cn

1 引言

点云配准是计算机视觉研究中一个活跃的领域,现广泛应用于目标识别^[1]、三维重建^[2]、即时定位地图构建(SLAM)^[3]、智能抓取^[4]等领域。配准技术是一种将多视角点云向同一坐标系转换的技术^[5],配准过程通常分为两步,即粗配准和精配准^[6]。粗配准能显著缩小点云之间的平移旋转误差,防止精配准陷入局部最优,而精配准以点云之间的欧氏距离为目标函数,通过缩小点对之间距离而实现精配准。

对于粗配准,由于局部特征具有旋转平移不变性,因此特征匹配被广泛应用于粗配准,特征匹配是点云粗配准的关键步骤^[7]。为了稀疏点云以减小计算量,需要对点云提取稳健的、可重复的关键点。李仁忠等^[8]提出基于内部形态描述子关键点(ISS)^[9]结合 k -d tree 改进的迭代最近点(ICP)的点云配准算法,该算法提高了配准速度,但配准精度与标准 ICP 相差无几;贾勇杰等^[10]提出将方向直方图签名(SHOT)描述子离散程度较大的点作为关键点的检测技术,这些关键点具有良好的再现性和可描述性,但 SHOT 描述子计算效率较低;张哲等^[11]提出法向量(NV)特征点,该特征点可以过滤平滑区域,提取特征区域,但是点云精简效果并不明显,关键点聚集使得关键点区分度下降,故计算复杂度仍然较大;He 等^[12]提出基于最大曲率变化提取特征点的方法,该算法的局限性在于关键点的可重复性和区分度受噪声影响较大;Theiler 等^[13]在高斯差分 and Harris 关键点提取上展开了研究,发现 Harris 关键点与四点一致集算法结合的方法在保证配准成功率的前提下,可以显著提高算法的配准速度;Kleppe 等^[14]对考虑形状因子和局部协方差矩阵的关键点提取展开了研究,该研究在模型点云配准上具备一定的抗噪性,但不易实现密度不均匀的点云的配准。为了使关键点具有唯一性,将关键点描述子用作描述关键点局部特征的标签,特征描述子包含点的局部特征信息,如法向量、密度、曲率等。常用的描述子有快速特征点直方图(FPFH)^[15]、归一化对齐特征(NARF)^[16]、局部特征直方图(LSFH)^[17]等。

对于精配准,应用最广的是 Besl 等^[18]提出的标准 ICP 算法,该算法具备良好的配准精度,但需要两点云有较大重叠区域和良好的初始位置,否则会导致算法陷入局部最优解或不收敛。Li 等^[19]在 ICP 算法中引入动态调整因子,在不影响收敛方向

的情况下能提高配准效率,但当调整因子增加过大时,算法会丧失稳定而无法收敛;陈旭等^[20]提出利用 Libnabo 算法加速最近点搜索的方法,该方法能显著提升 ICP 算法的运算效率;全局最优(Go-ICP)^[21]将全局优化和标准 ICP 相结合,克服了 ICP 算法陷入局部最优的限制,但算法计算复杂度增加,容易使配准效率下降;此外,稀疏 ICP (Sparse-ICP)^[22]、广义 ICP (Generalized-ICP)^[23]分别解决了 ICP 算法受点云噪声和异常值的影响,计算复杂度大等局限性。

上述关键点提取算法主要研究了关键点的特殊性而忽略了唯一性,故导致关键点分布集中、区分度低。另外,对 ICP 算法及其变种算法的研究主要集中在优化算法本身,而忽略了搜索算法和误匹配对算法精度和速度的影响。对此,本文提出高效、高精度实现点云配准的粗、精配准算法。对于粗配准,提出一种基于体素格和法向距离的关键点提取方法,在该方法中计算 FPFH 值进行特征匹配,采用对应关系优化随机采样一致性(RANSAC)算法,以消除误匹配,最后采用奇异值分解(SVD)获得初始配准矩阵。对于精配准,提出一种基于“点到三角面”模型结合最优节点优先(BBF)的算法来加速最近点搜索,以优化 ICP 算法。为了验证所提算法的效率和精度,采用斯坦福库点云、机器人库点云数据进行配准实验,并将所提算法与其他算法进行对比分析。

2 算法总述

点云配准技术一般分为粗配准和精配准两个阶段。粗配准的目的是实现两点云之间转换矩阵的初始估计,精配准用于修正初始矩阵,从而得到更精确的转换矩阵。图 1 为点云 P 和 Q 配准的流程图,其中 ω_{\max} 为最大迭代次数, τ 为设定的极小值。

在粗配准中,对于大数据量的点云,在不丧失点云特征的前提下对关键点提取可简化的点云,从而降低计算复杂度,减少消耗时间;然后计算关键点 FPFH 值,采用对应关系估计优化 RANSAC 算法,以剔除误匹配;最后采用奇异值分解(SVD)获得初始配准矩阵。在精配准中,利用基于“点到三角面”的优化 ICP 算法进行点云精确对齐。精配准算法的过程如下。

步骤 1:对于源点云 P 中的每个点,使用 BBF 优化的 k -d tree 算法搜索目标点云 Q 中的最近点序列;
步骤 2:设置动态阈值以消除错误的点对;
步骤 3:运行加速 ICP 算法,计算变换向量。

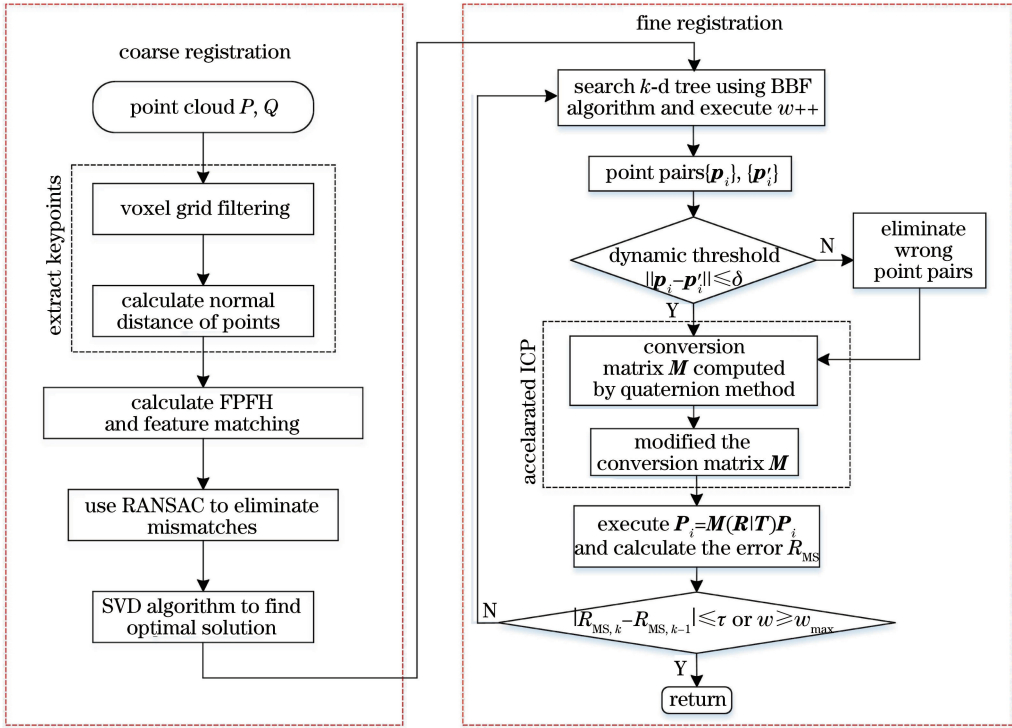

 图1 点云 P 和 Q 配准的流程图

 Fig. 1 Flowchart of registration of point clouds P and Q

3 粗配准

3.1 基于法向距离的关键点提取

图2为特征点提取的原理,对于密度不均匀和有噪声的点云,首先采用体素格滤波,降低点云的复杂度,然后计算点的法向距离来提取特征点。假设给定点云 P ,该点云被边长为 a 的体素格划分为网格,对包裹在体素格内部的点云计算重心,并将重心作为滤波点。

$$(x, y, z) = \left(\frac{1}{n_{\text{vox}}} \sum_{i=1}^{n_{\text{vox}}} x_i, \frac{1}{n_{\text{vox}}} \sum_{i=1}^{n_{\text{vox}}} y_i, \frac{1}{n_{\text{vox}}} \sum_{i=1}^{n_{\text{vox}}} z_i \right), \quad (1)$$

式中: n_{vox} 为体素格内点的数量。该滤波过程需要将点云 P 中点的数量削减至 15%~30%。对于 P 中任一点 p_i , 搜索其半径 r 以内的邻域点, 记为 $\{p_{i1}, p_{i2}, \dots, p_{im}\}$, 采用主成分分析 (PCA) 计算 p_i 点的法向量 n_i 。对于 p_i 点的近邻点 p_{im} , d_{im} 为向量 $\overrightarrow{p_i p_{im}}$ 在法向量方向的投影 ($\overrightarrow{p_i p_{im}}$ 代表点 p_i 到 p_{im} 的向量, 下同), 如图 2(b) 所示。 p_i 点的法向距离 d_i 为

$$d_i = \sum_{j=1}^m d_{ij} = \frac{1}{m} \sum_{j=1}^m n_i \cdot (p_{ij} - p_i). \quad (2)$$

设定一个阈值百分比 t_{hr} 以提取关键点, 在关键点周围的点具有相似的法向距离。为保证关键点的

唯一性, 采用近邻搜索算法对关键点进行稀疏唯一化处理, 判断关键点 p_i 是否保留的依据为

$$d_i = \min(d_i, d_{i1}, d_{i2}, \dots, d_{im}), \quad (3)$$

式中: m 为 p_i 的 m 邻域; $d_{i1}, d_{i2}, \dots, d_{im}$ 为 p_i 的 m 邻域点的法向距离。以 bunny 点云为例, 图 3 为不同参数下关键点的分布情况, 关键点主要分布在点云凸凹特征明显的地方且不聚集, 因此相互之间区分度大且不丧失特征。

3.2 对应关系估计优化 RANSAC

对于给定的源点云 P 和目标点云 Q , 首先提取关键点, 并计算关键点 FPFH 值, 寻找准确对应的点对是特征匹配的重要内容。RANSAC 算法常被用来区分正确点对和误匹配点对, 估计点云配准模型最优的转换矩阵, 具有良好的稳健性和抗噪性^[24-25]。利用对应关系估计优化 RANSAC 算法, 对误匹配剔除进行预处理, 可以提高 RANSAC 算法的剔除效率和准确度。RANSAC 算法的具体流程如下。

由于源点云与目标点云位姿的差异性, 需要建立合适的转换模型以确保点对之间的最佳拟合。点对在不同坐标之间的转换关系需要满足

$$\begin{bmatrix} R_1 & R_2 & R_3 \\ R_4 & R_5 & R_6 \\ R_7 & R_8 & R_9 \end{bmatrix} \begin{bmatrix} x \\ y \\ z \end{bmatrix} + \begin{bmatrix} T_1 \\ T_2 \\ T_3 \end{bmatrix} = \begin{bmatrix} x' \\ y' \\ z' \end{bmatrix}, \quad (4)$$




图2 关键点提取。(a)体素格滤波;(b)法向距离提取关键点

Fig. 2 Keypoint extraction. (a)Voxel grid filtering; (b) extracting keypoints using normal distance




图3 不同参数下的关键点分布。(a) $a_0=0.3\text{ mm}$, $r=1.0\text{ mm}$, $t_{hr}=10\%$, $m=5$ 时,关键点数目为 658;(b) $a_0=0.4\text{ mm}$, $r=2.0\text{ mm}$, $t_{hr}=10\%$, $m=5$ 时,关键点数目为 597;(c) $a_0=0.4\text{ mm}$, $r=2.0\text{ mm}$, $t_{hr}=10\%$, $m=10$ 时,关键点数目为 364

Fig. 3 Distribution of keypoints under different parameters. (a) $a_0=0.3\text{ mm}$, $r=1.0\text{ mm}$, $t_{hr}=10\%$, $m=5$, the number of keypoints is 658; (b) $a_0=0.4\text{ mm}$, $r=2.0\text{ mm}$, $t_{hr}=10\%$, $m=5$, the number of keypoints is 597; (c) $a_0=0.4\text{ mm}$, $r=2.0\text{ mm}$, $t_{hr}=10\%$, $m=10$, the number of keypoints is 364

式中: R_1, R_2, \dots, R_9 为旋转矩阵的参数; T_1, T_2, T_3 为平移向量的参数; (x, y, z) 和 (x', y', z') 为源点云和目标点云中的坐标。

每次迭代中,为计算(4)式中的 12 个参数,需要选择 4 组点对进行估计,为了保证点对选取的有效性,以确保 RANSAC 算法的高效性,可利用对应关系估计点对进行筛选。分别记源点云 $P\{p_1, p_2, \dots, p_{n_1}\}$ 和目标点云 $Q\{q_1, q_2, \dots, q_{n_2}\}$ 的特征为 $\{p_{1f}, p_{2f}, \dots, p_{n_1f}\}, \{q_{1f}, q_{2f}, \dots, q_{n_2f}\}$ 。对于任一源点云特征 $p_{j_1f}(j_1 < n_1) \in \{p_{1f}, p_{2f}, \dots, p_{n_1f}\}$,在目标点云特征中搜索最接近特征 $q_{j_2f}(j_2 < n_2)$,同时对点云特征 $q_{j_2f}(j_2 < n_2)$,在源点云中搜索最接近特征 $q_{j_3f}(j_3 < n_1)$,如果满足

$$\begin{cases} j_1 = j_3 \\ \sqrt{\sum_{s=1}^{s_{\max}} \|p_{j_1f}^s - q_{j_2f}^s\|^2} \leq C \end{cases}, \quad (5)$$

则 p_i 和 q_j 被视为一对正确点对 (p_i, q_j) 。其中, s_{\max} 为特征维数,一般取值为 33 或 125, C 为设定常数。利用点对可以估计转换模型参数 R 和 T 。对于剩余点对中任一点对 (p, q) , 计算距离 $d = \|Rp + T - q\|$, 如果距离 d 小于某一给定的阈值, 则称该点对 (p, q) 为内点, 如果 d 大于给定的阈值, 则点对为外点。统计每组参数 $[R|T]$ 对应的内点数

目 n_{num} , 直至达到最大迭代次数。满足最大内点数 n_{num} 的转换参数 $[R|T]$ 是该模型的最佳参数, 可利用 SVD 计算 n_{num} 对内点的转换矩阵, 进而完成粗配准。

4 精配准

4.1 基于 BBF 优化 k -d tree 搜索

BBF 优化是一种近似搜索算法, 即在高维空间内高效地搜索到最近点或近似最近点。本文采用 BBF^[26] 优化 k -d tree 搜索算法搜索最近点序列, 并计算最近点以进行精配准。为了在目标点云中搜寻源点云中任一点的最近点序列, 可采用基于优先级的回溯搜索。其具体过程为, 首先按照构建 k -d tree 的方法纵向搜索到子节点(搜索左节点或右节点, 取决于待搜索点与当前节点的分割维度值的大小), 同时在这一过程中建立优先级序列。在回溯过程中, 优先级序列会按照优先级大小依次进行搜索, 直到达到搜索时限 t_{\max} 或最大搜索点数 n_{\max} 。点优先级 M_{pri} 定义为

$$M_{\text{pri}} = |t_k - s_k|, k \in (x, y, z), \quad (6)$$

式中: t_k 为目标点的第 k 维值; s_k 为节点的第 k 维值; k 为分割维度。 M_{pri} 值越小, 节点的优先级越大。

4.2 “点到三角面”模型

“点到点”模型趋向于出现“多对一”的最近点模型, 如图4(a)所示, 该模型会对 ICP 算法的迭代收敛




图4 不同的最近点模型。(a)“点到点”模型；(b)“点到三角面”模型

Fig. 4 Different nearest point models. (a) “Point to point” model; (b) “point to triangle plane” model

性产生较大影响。本文提出一种“点到三角面”最近点模型,该模型在不增加搜索时间的情况下能有效解决以上一问题。对源点云 P 中任一点 p_i ,采用4.1节算法可以搜索到最近点序列,取优先级最高的3个最近点,依次设为 c_{i0} 、 c_{i1} 、 c_{i2} 。图4(b)为“点到三角面”最近点模型。

该三角面的法向量为 \mathbf{n} ,对任一直线通过 p_i 且垂直于平面 $c_{i0}c_{i1}c_{i2}$ 平面(由 c_{i0} 、 c_{i1} 、 c_{i2} 组成的平面)的任一直线,必须满足

$$\boldsymbol{\eta} = \frac{\overrightarrow{c_{i0}c_{i1}} \times \overrightarrow{c_{i0}c_{i2}}}{|\overrightarrow{c_{i0}c_{i1}} \times \overrightarrow{c_{i0}c_{i2}}|}, \quad (7)$$

$$\frac{\overrightarrow{p_i p'_i}}{\mathbf{n}} = \mathbf{n} \cdot \overrightarrow{p_i c_{i0}}, \quad (8)$$

$$\mathbf{p}'_i = p_i - \mathbf{n} \cdot (\mathbf{n} \cdot \overrightarrow{p_i c_{i0}}), \quad (9)$$

式中: \mathbf{p}'_i 为点 p_i 的最近点。如果 \mathbf{p}'_i 不满足

$$\begin{aligned} \overrightarrow{p'_i c_{i0}} &= k_1 \overrightarrow{c_{i0}c_{i1}} + k_2 \overrightarrow{c_{i0}c_{i2}} \\ \text{s.t. } k_1 + k_2 &\leq 1, k_1, k_2 \geq 0, \end{aligned} \quad (10)$$

则表示投影点 \mathbf{p}'_i 落在了三角面之外,此时认为 p_i 在向量 $\overrightarrow{c_{i0}c_{i1}}$ 上的投影点 \mathbf{p}''_i 为点 p_i 的最近点。

$$\mathbf{p}''_i = c_{i0} + \frac{\overrightarrow{c_{i0}p_i} \cdot \overrightarrow{c_{i0}c_{i1}}}{|\overrightarrow{c_{i0}c_{i1}}|} \cdot \frac{\overrightarrow{c_{i0}c_{i1}}}{|\overrightarrow{c_{i0}c_{i1}}|}. \quad (11)$$

4.3 动态阈值

点对点进行错误点对剔除是防止精配准算法过早陷入局部最优的关键步骤,对两点云进行配准对齐的目的是实现两点云重叠区域内最近点之间的距离最小化,其目标函数^[18]为

$$f(\mathbf{R}, \mathbf{T}) = \underset{\mathbf{R}, \mathbf{T}}{\operatorname{argmin}} \frac{1}{N} \sum_{i=1}^N \| \mathbf{p}_i - \mathbf{R} \mathbf{p}'_i - \mathbf{T} \|^2, \quad (12)$$

式中: \mathbf{R} 为旋转矩阵; \mathbf{T} 为平移向量; N 为点云中对应点数目。

为了防止迭代过程陷入局部最优,需要提取两点云的重叠区域,消除欧氏距离较大的点对。将每次迭代完成的配准误差 R_{MS} 设置为下一次迭代的距离阈值,可以对其动态调整,即在第 w 次确定配准误差。

$$R_{MS} = \sqrt{\frac{1}{n} \sum_{i=1}^n \| \mathbf{p}_i - (\mathbf{R}_w \mathbf{p}'_i + \mathbf{T}_w) \|^2}, \quad (13)$$

$$\| (\mathbf{p}_i - \mathbf{p}'_i) \| \leq \delta, \quad (14)$$

式中: \mathbf{R}_w 和 \mathbf{T}_w 分别为第 w 次迭代的旋转矩阵和平移矩阵; δ 为误差阈值。假设点云偏差服从正态分布,残差标准差的无偏估计 $\hat{\sigma}_1$ 为 $1.4826R_{MS}$, 对于 $\delta \leq 2.5 \hat{\sigma}_1$ ^[27], 可剔除异常值,本文中取 δ 为 $3R_{MS}$ 。剔除不满足(14)式的点对,以防止参与第 $w+1$ 次迭代。

4.4 加速 ICP 算法

加速 ICP 算法^[18]通过对点对进行反复迭代,使对应点对逐渐逼近,从而使目标函数值收敛。在移除错误点对之后,对源点云 P 中点集和目标点云 Q 中对应点集采用四元数法计算转换矩阵。将转换矩阵应用于源点云,进行下一次迭代。加速 ICP 算法具体流程如下。

转换向量 $\mathbf{q}_w = [\gamma_w, \beta_w, \alpha_w, x_w, y_w, x_w]$, 其中 $[\gamma_w, \beta_w, \alpha_w]$ 为欧拉角旋转分量, $[x_w, y_w, x_w]$ 为平移分量。初始化 $P_0 = P, \mathbf{q}_0 = [0, 0, 0, 0, 0, 0]$ 。

步骤 1: 当 $w < 5$ 时, 计算转换向量 \mathbf{q}_w , 执行 $\mathbf{P}_w = \mathbf{q}_w \mathbf{P}_{w-1}$, 其中 \mathbf{P}_w 为由第 w 次迭代的所有点 p 组成的矩阵。

步骤 2: 当 $w \geq 5$ 时, 利用点 $[v_w, R_{MS,w}]$, $[v_{w-1}, R_{MS,w-1}]$, $[v_{w-2}, R_{MS,w-2}]$ 分别拟合一次函数 $R_{MS,w} = kx + e$ 和抛物线 $R_{MS,w} = av^2 + bv + c$, 其中 $\Delta \mathbf{q}_w = \mathbf{q}_w - \mathbf{q}_{w-1}$, $v_w = 0$, $v_{w-1} = -\|\Delta \mathbf{q}_w\|$, $v_{w-2} = -(\|\Delta \mathbf{q}_w\| + \|\Delta \mathbf{q}_{w-1}\|)$ 。一次函数和抛物线的极值(即最小误差)分别为 $v_1 = -k/e > 0$ 和 $v_p = -b/2a$, 再执行 $\mathbf{P}_w = \mathbf{q}_w \mathbf{P}_{w-1}$, 其中转换向量 \mathbf{q}_i 修正的公式为

$$\mathbf{q}_w = \begin{cases} \mathbf{q}_w + \min(v_1, v_p, v_{\max}) \Delta \mathbf{q}_w / \|\Delta \mathbf{q}_w\|, \\ \theta_w, \theta_{w-1} \in (0, 0.3), v_p \geq 0 \\ \mathbf{q}_w + \min(v_1, v_{\max}) \Delta \mathbf{q}_w / \|\Delta \mathbf{q}_w\|, \\ \theta_w, \theta_{w-1} \in (0, 0.3), v_p < 0 \\ \mathbf{q}_w, \text{ others} \end{cases}. \quad (15)$$

在(15)式中, θ_w 的值为

$$\theta_w = \arccos\left(\frac{\Delta \mathbf{q}_w \cdot \Delta \mathbf{q}_{w-1}}{\|\Delta \mathbf{q}_w\| \cdot \|\Delta \mathbf{q}_{w-1}\|}\right), \quad (16)$$

式中: $\Delta \mathbf{q}_w$ 为两次迭代转换向量之间的误差; θ_w 为收敛方向角; v_{\max} 为最大修正量, 取 $v_{\max} = 15$ 。

步骤 3: 当 w 大于最大迭代次数 w_{\max} 或者 $|R_{\text{MS},w} - R_{\text{MS},w-1}| < \tau$ (τ 取极小值, 如 0.005) 时, 终止迭代, 否则返回步骤 1 或步骤 2。

5 实验与分析

为了验证所提算法配准速度和精度的性能, 采用斯坦福库点云^[28] (bunny, happy, dargon, armadillo) 和机器人库点云^[29] (dagstuhl, hokuyo) 进行配准实验。实验在 1.8 GHz Inter(R) Core i7-8700U CPU RAM 16G 计算机, Visual Studio2015 环境下运行, 粗配准算法利用 PCL1.8.0 库 C++ 实现, 精配准算法中 BBF 优化 k -d tree 搜索、加速 ICP 算法等利用 C# 实现。

第 1 组实验, 为了验证所提粗配准算法的配准效率和精度, 将其与 uniform + FPFH + SAC-IA、NARF + FPFH + SAC-IA^[30]、ISS + FPFH + SAC-IA^[8]、基于关键点四点一致集算法 (KFPCS)^[31]

进行比较。第 2 组实验, 将优化 ICP 算法与标准 ICP、LM-ICP^[32]、GICP、正态分布变换算法 (NDT)^[33] 进行比较。第 3 组实验, 为了验证所提法向距离关键点的抗噪性和稳健性, 需分别对源点云、目标点云添加高斯噪声^[34], 并与 NARF 兴趣点、ISS 关键点、均匀 (uniform) 采样关键点进行比较分析。

5.1 点云配准实验

利用所提算法与其他常用算法进行配准模型 (happy, dargon, armadillo) 和建筑物 (dagstuhl, hokuyo) 点云的比较来验证所提算法在配准精度和运行效率上的性能。图 5 和图 6 分别为模型和建筑物的点云粗配准。图 5(a) 和图 6(a) 为特征匹配结果, 结果中包含大量的误匹配点, 图 5(b) 和图 6(b) 为对应关系估计优化 RANSAC 算法对误匹配剔除后的对应点, 图 5(c) 和图 6(c) 为 SVD 的粗配准结果。表 1 和表 3 为所提算法在模型、建筑物点云的配准结果, 表 2 和表 4 为不同粗配准算法对模型、建筑物点云配准结果的比较。从表 2 和表 4 可以得出: 与 uniform + FPFH + SAC-IA、NARF + FPFH + SAC-IA、ISS + FPFH + SAC-IA、KFPCS 算法相比, 所提算法的配准时间消耗分别降低了




图 5 模型点云粗配准。(a) 特征匹配; (b) 优化 RANSAC 对误匹配剔除; (c) 粗配准结果

Fig. 5 Coarse registration of model point clouds. (a) Feature matching; (b) correct correspondences after improved RANSAC; (c) results of coarse registration

表 1 模型点云粗配准结果

Table 1 Coarse registration results of model point clouds

Dataset	Size of point cloud	Number of keypoints	Number of correspondences	Number of correct correspondences	R_{MS}/mm
Happy024	75582	433	102	75	0.44
Happy048	69158	381			
Dragon120	21833	382	80	53	1.04
Dragon144	23530	411			
Armadillo15	32208	405	97	64	0.96
Armadillo45	24813	371			

表 2 不同算法对模型点云粗配准结果的比较

Table 2 Comparison of coarse registration results of model point clouds by different methods

Method	Happy		Armadillo		Dragon	
	Time /s	R_{MS}/mm	Time /s	R_{MS}/mm	Time /s	R_{MS}/mm
Uniform+FPFH+SAC-IA	42.90	2.06	6.40	1.64	4.48	1.14
NARF+FPFH+SAC-IA	28.67	2.18	16.40	1.76	8.43	1.91
ISS+FPFH+SAC-IA	17.80	2.53	9.09	1.15	10.17	1.02
KFPCS	6.70	1.29	3.28	1.03	2.71	1.09
Proposed method	1.23	0.44	1.80	0.96	0.61	1.04

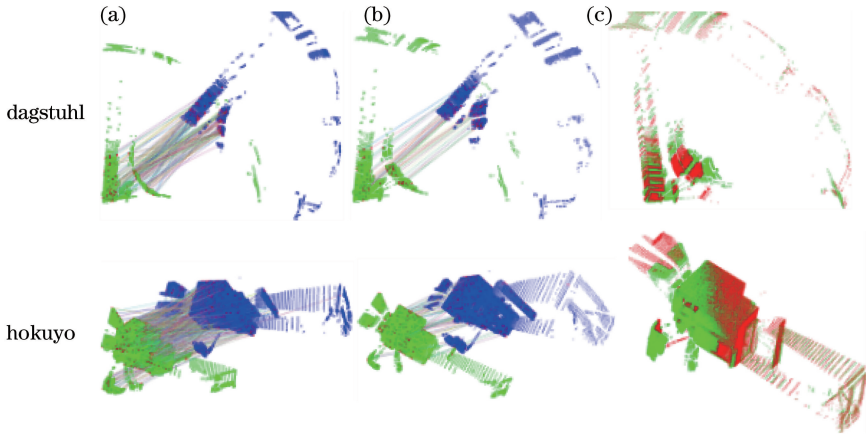


图 6 建筑物点云粗配准。(a)特征匹配;(b)优化 RANSAC 对误匹配剔除;(c)粗配准结果

Fig. 6 Coarse registration of building point clouds. (a) Feature matching; (b) correct correspondences

after improved RANSAC; (c) results of coarse registration

表 3 建筑物点云粗配准结果

Table 3 Coarse registration results of building point clouds

Dataset	Size of point cloud	Number of keypoints	Number of correspondences	Number of correct correspondences	$R_{MS}/(10^{-2} \text{ m})$
Dagstuhl000	81359	453	113	46	2.07
Dagstuhl001	81360	404			
Hokuyo_0	370261	2695	565	123	1.82
Hokuyo_1	370277	3283			

表4 不同算法对建筑物点云粗配准结果比较

Table 4 Comparison of coarse registration results of building point clouds by different methods

Method	Dagstuhl		Hokuyo	
	Time /s	R_{MS}/m	Time /s	R_{MS}/m
Uniform+FPFH+SAC-IA	27.20	0.0415	93.80	0.0267
NARF+FPFH+SAC-IA	4.33	0.0360	63.70	0.0439
ISS+FPFH+SAC-IA	12.04	0.0239	77.40	0.0206
KFPCS	5.23	0.0249	29.70	0.0279
Proposed method	0.72	0.0207	12.09	0.0182

至少71%、83%、80%、46%；同时所提算法在配准精度上，相比 uniform+FPFH+SAC-IA、KFPCS、NARF+FPFH+SAC-IA 算法分别提升了至少9%、5%、80%。为了使得关键点具有较高的区分度和稳健性，首先要对点云进行稀疏网格化处理，确保点云密度均匀的同时降低计算复杂度，然后在丧失点云特征情况下提取法向距离关键点，过滤掉平坦的区域，最后，为了防止关键点聚集，采用近邻搜索算法再次进行稀疏处理。粗配准实验结果表明，所提算法具有良好的配准效率和配准精度。

表5 不同算法模型点云精配准结果比较

Table 5 Comparison of fine registration results of model point clouds under different methods

Method	Happy		Armadillo		Dragon	
	Time /s	R_{MS}/mm	Time /s	R_{MS}/mm	Time /s	R_{MS}/mm
Standard ICP	18.90	0.082	7.60	0.170	5.80	0.230
GICP	32.23	0.055	15.10	0.091	11.50	0.167
LM-ICP	20.24	0.079	6.97	0.150	10.17	0.183
NDT	5.30	0.087	2.35	0.150	1.69	0.180
Proposed method	11.2	0.053	6.47	0.084	4.70	0.173

5.2 抗噪性实验验证

为了验证所提关键点提取算法，需要在不同视角的点云中提取到相同或相近的关键点，以确保配准点云的正确率，达到良好的初始配准精度。为了验证所提法向距离关键点的稳健性，首先将点云数据标准化至 $[-1, 1]^3$ 单位区间，再分别对 bunny, happy, armadillo 点云分别添加 $\sigma=0.005, \sigma=0.010, \sigma=0.015$ 和 $\sigma=0.020$ ，即概率密度函数为 $N(0, \sigma^2)$ 的高斯噪声，然后将点云按照原标准化的比例进行还原，得到高斯噪声点云数据，其中点云噪声越大，提取相近关键点的概率越低。因此，将所提法向距离关键点与 NARF 兴趣点、ISS 关键点、uniform 采样关键点进行比较分析。为了直观地显示配准结果，将3种算法结

精配准实验是在粗配准的结果上进行的，将所提优化 ICP 算法与标准 ICP、LM-ICP、GICP、NDT 算法进行配准效率和配准精度的比较。在 BBF 算法参数设置上， n_{max} 的范围设置为 $[1.21b N, 1.51b N]$ ，其中 N 为目标点云的数目。和粗配准类似，图7和图8分别为模型点云、建筑物点云的精配准。图7(a)和图8(a)分别为所提算法对模型、建筑物点云的精配准结果，图7(c)和图8(c)分别为不同算法配准偏差的比较。对比标准 ICP、NDT、LM-ICP，所提算法的收敛速度更快且配准精度更高，所提算法在配准精度上与 GICP 算法比较接近，但是所提算法效率更高。另外，为了更加直观地显示图7(a)和图8(a)中点云的配准情况，给出了精配准点云距离偏差的色谱对比，如图7(b)和图8(b)所示，其中纵坐标表示配准偏差，可显示两点云的接近程度。

表5和表6为不同算法的精配准结果比较。由表5和表6可知：NDT 算法在运行效率上优于其他算法，但是所提算法具有更好的配准精度；所提算法在配准精度上相比标准 ICP、LM-ICP、NDT 算法分别提升了至少32%、6%、5%，同时在配准效率上分别比标准 ICP、LM-ICP、GICP 提升了至少15%、8%、70%。

合 FPFH+SAC-IA 与所提粗配准算法对添加噪声后的点云进行配准，然后对配准误差进行比较分析。图9为不同算法的高斯噪声点云配准实验，图10为所提算法在高斯噪声 $\sigma=0.02$ 下对不同点云的配准结果。由图9可知，所提算法在不同高斯噪声下的配准偏差明显低于 NARF 兴趣点、ISS 关键点，但和 uniform 采样关键点接近。在配准时间消耗方面，所提算法耗时更短，如表2和表4所示。所提法向距离关键点提取可以将关键点数量保持在1%左右，这能极大降低 FPFH 值的计算复杂度。实验结果表明，所提算法具有良好的抗噪性和稳健性。不过需要指出的是，噪声的急剧上升可能会造成法向量和 FPFH 值的计算失败。

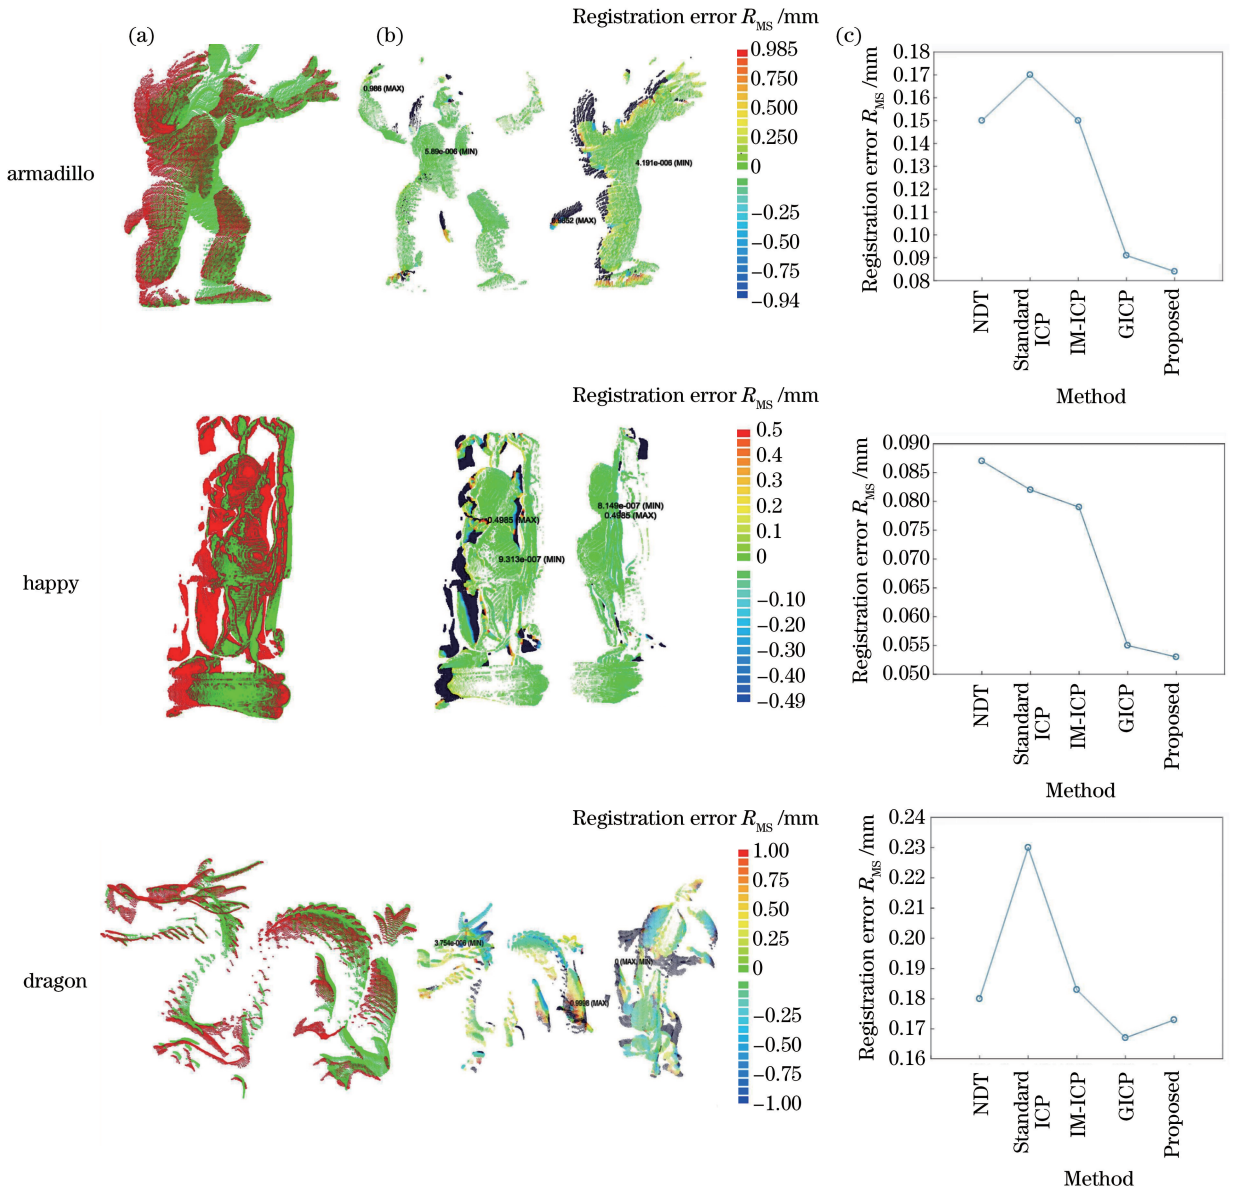


图 7 模型点云精配准。(a)所提算法的精配准结果;(b)精配准下点云距离偏差的色谱对比;(c)不同算法精配准误差的比较
 Fig. 7 Fine registration of model point clouds. (a) Results of fine registration by proposed method; (b) chromatographic comparison of point clouds distance deviation under fine registration; (c) registration error comparison of fine registration among different methods

表 6 不同算法建筑物点云精配准结果比较

Table 6 Comparison of fine registration results of building point clouds by different methods

Method	Dagstuhl		Hokuyo	
	Time /s	$R_{MS}/(10^{-3} \text{ m})$	Time /s	$R_{MS}/(10^{-3} \text{ m})$
Standard ICP	15.70	4.77	105.6	2.82
GICP	23.97	4.31	121.7	2.43
LM-ICP	60.60	4.52	203.6	4.56
NDT	10.67	5.73	49.6	2.57
Proposed method	13.60	3.58	70.9	1.61

6 结 论

对强噪声且密度不均匀的点云进行高效、高精度配准是一个难题。针对这一难题,提出一种基于关键点提取与优化 ICP 的点云配准算法。利用开源数据点云对比多种算法,验证了所提算法在配准效率和配准精度上的性能。实验表明,所提法向距离关键点提取在不丧失点云特征情况下,能将关键点数目削减到 1% 左右,极大降低了特征描述计算复杂度和时间消耗,具有更好的稳健性和抗噪性,

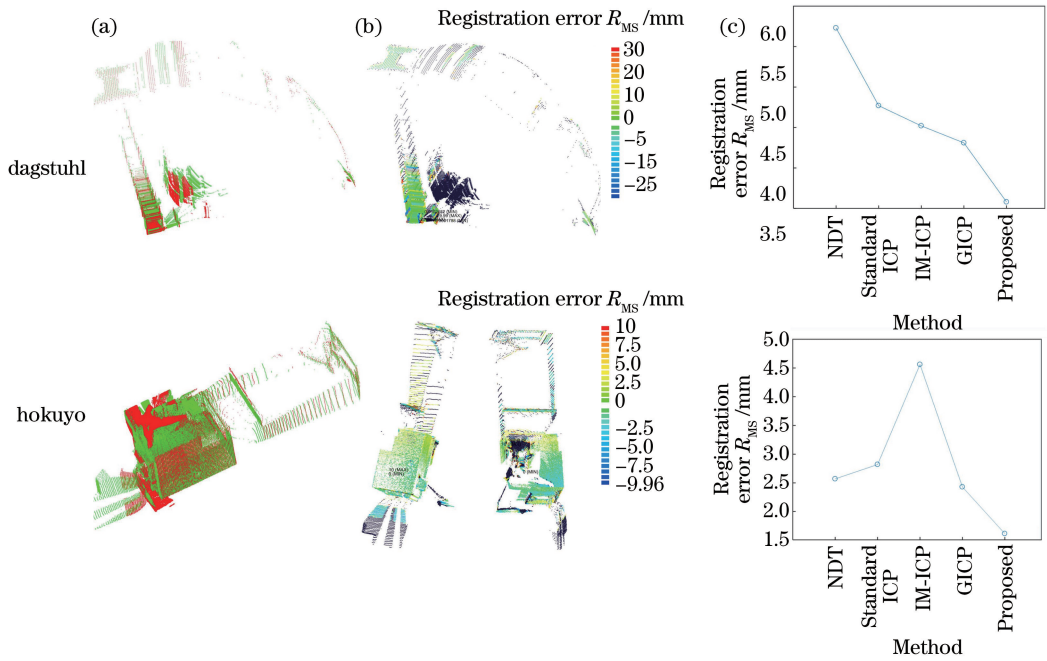


图 8 建筑物点云精配准。(a)所提算法的精配准结果；(b)精配准下点云距离偏差的色谱对比；(c)不同算法配准精度误差的比较

Fig. 8 Fine registration of building point clouds. (a) Results of fine registration by proposed method; (b) chromatographic comparison of point clouds distance deviation under fine registration; (c) registration error comparison of fine registration among different methods

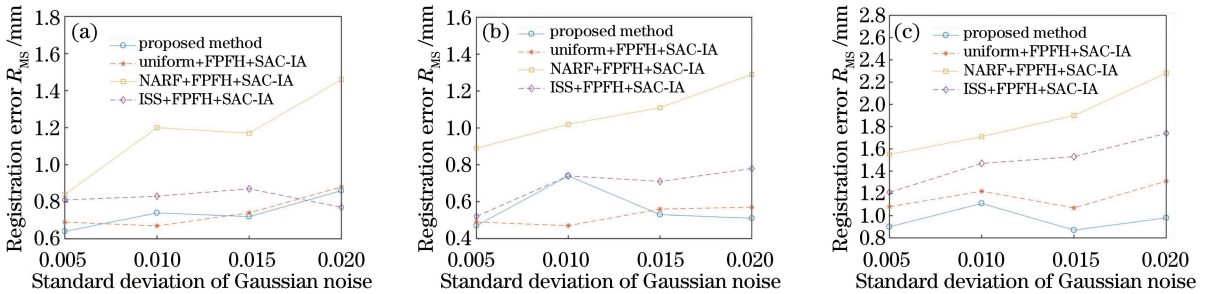


图 9 不同算法的高斯噪声点云配准实验比较。(a) Bunny;(b) happy;(c) armadillo

Fig. 9 Registration experiment comparison of Gaussian noise point clouds under different methods.

(a) Bunny; (b) happy; (c) armadillo




图 10 所提算法在高斯噪声 $\sigma=0.02$ 下对

不同点云的配准结果。(a) Bunny;(b) happy;(c) armadillo

Fig. 10 Registration results of different point clouds with Gaussian noise $\sigma = 0.02$ in proposed method.

(a) Bunny; (b) happy; (c) armadillo

使得粗配准算法具有更好的配准效率和配准精度。

另外,提出的优化 ICP 算法结合“点到三角面”模型和动态阈值加速 ICP 的算法,可以有效剔除错误点对,防止算法陷入局部最优。同时,基于 BBF 优化的 k -d tree 搜索能极大提高搜索最近点的速度,通过加速 ICP 算法同时削减迭代次数,可极大提升算法的配准效率。

参 考 文 献

[1] Wang J H, Lindenbergh R, Menenti M. SigVox: a 3D feature matching algorithm for automatic street object recognition in mobile laser scanning point clouds[J]. ISPRS Journal of Photogrammetry and Remote Sensing, 2017, 128: 111-129.

- [2] Yang P, Zhou Y H, Yao J, et al. Three-dimensional shape reconstruction via an objective function optimization-based point cloud registration method [J]. *Optical Engineering*, 2017, 56(11): 113108.
- [3] Yue H S, Chen W H, Wu X M, et al. Extension of an iterative closest point algorithm for simultaneous localization and mapping in corridor environments [J]. *Journal of Electronic Imaging*, 2016, 25(2): 023015.
- [4] Chen C S, Chen P C, Hsu C M. Three-dimensional object recognition and registration for robotic grasping systems using a modified viewpoint feature histogram [J]. *Sensors*, 2016, 16(11): 1969.
- [5] Jiang Y, Huang H G, Shu Q, et al. Scale point cloud registration algorithm in high-dimensional orthogonal subspace mapping [J]. *Acta Optica Sinica*, 2019, 39(3): 0315007.
蒋悦, 黄宏光, 舒勤, 等. 高维正交子空间映射的尺度点云配准算法 [J]. *光学学报*, 2019, 39(3): 0315007.
- [6] Ji S J, Ren Y C, Ji Z, et al. An improved method for registration of point cloud [J]. *Optik*, 2017, 140: 451-458.
- [7] Liu J, Bai D. 3D point cloud registration algorithm based on feature matching [J]. *Acta Optica Sinica*, 2018, 38(12): 1215005.
刘剑, 白迪. 基于特征匹配的三维点云配准算法 [J]. *光学学报*, 2018, 38(12): 1215005.
- [8] Li R Z, Yang M, Tian Y, et al. Point cloud registration algorithm based on the ISS feature points combined with improved ICP algorithm [J]. *Laser & Optoelectronics Progress*, 2017, 54(11): 111503.
李仁忠, 杨曼, 田瑜, 等. 基于 ISS 特征点结合改进 ICP 的点云配准算法 [J]. *激光与光电子学进展*, 2017, 54(11): 111503.
- [9] Zhong Y. Intrinsic shape signatures: a shape descriptor for 3D object recognition [C] // 2009 IEEE 12th International Conference on Computer Vision Workshops, ICCV Workshops, September 27-October 4, 2009, Kyoto, Japan. New York: IEEE, 2009: 689-696.
- [10] Jia Y J, Xiong F G, Han X, et al. Multi-scale keypoint detection based on SHOT [J]. *Laser & Optoelectronics Progress*, 2018, 55(7): 071013.
贾勇杰, 熊风光, 韩燮, 等. 基于 SHOT 的多尺度关键点检测技术研究 [J]. *激光与光电子学进展*, 2018, 55(7): 071013.
- [11] Zhang Z, Xu H L, Yin H. A fast point cloud registration algorithm based on key point selection [J]. *Laser & Optoelectronics Progress*, 2017, 54(12): 121002.
张哲, 许宏丽, 尹辉. 一种基于关键点选择的快速点云配准算法 [J]. *激光与光电子学进展*, 2017, 54(12): 121002.
- [12] He B W, Lin Z M, Li Y F. An automatic registration algorithm for the scattered point clouds based on the curvature feature [J]. *Optics & Laser Technology*, 2013, 46: 53-60.
- [13] 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.
- [14] Kleppe A L, Tingelstad L, Egeland O. Coarse alignment for model fitting of point clouds using a curvature-based descriptor [J]. *IEEE Transactions on Automation Science and Engineering*, 2019, 16(2): 811-824.
- [15] 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, 2009: 3212-3217.
- [16] Steder B, Rusu R B, Konolige K, et al. Point feature extraction on 3D range scans taking into account object boundaries [C] // 2011 IEEE International Conference on Robotics and Automation, May 9-13, 2011, Shanghai, China. New York: IEEE, 2011: 2601-2608.
- [17] Yang J Q, Cao Z G, Zhang Q. A fast and robust local descriptor for 3D point cloud registration [J]. *Information Sciences*, 2016, 346/347: 163-179.
- [18] 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.
- [19] Li W M, Song P F. A modified ICP algorithm based on dynamic adjustment factor for registration of point cloud and CAD model [J]. *Pattern Recognition Letters*, 2015, 65: 88-94.
- [20] Chen X, He B W. A fast global registration algorithm based on correcting point cloud principal component coordinate system [J]. *Laser & Optoelectronics Progress*, 2018, 55(6): 061003.
陈旭, 何炳蔚. 一种基于校正点云主成分坐标系的快速全局配准算法 [J]. *激光与光电子学进展*, 2018,

55(6): 061003.

- [21] 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.
- [22] Mavridis P, Andreadis A, Papaioannou G. Efficient sparse ICP[J]. Computer Aided Geometric Design, 2015, 35/36: 16-26.
- [23] Segal A, Haehnel D, Thrun S. Generalized-ICP[C]//Robotics: Science and Systems V, June 28-July 1, 2009, Seattle, USA. USA: MIT Press, 2009.
- [24] Wu M Q, Li Z W, Zhong K, et al. Adaptive point cloud registration method based on geometric features and photometric features [J]. Acta Optica Sinica, 2015, 35(2): 0215002.
伍梦琦, 李中伟, 钟凯, 等. 基于几何特征和图像特征的点云自适应拼接方法[J]. 光学学报, 2015, 35(2): 0215002.
- [25] Zhao Y, Hong R C, Jiang J G. Visual summarization of image collections by fast RANSAC [J]. Neurocomputing, 2016, 172: 48-52.
- [26] Lowe D G. Distinctive image features from scale-invariant keypoints [J]. International Journal of Computer Vision, 2004, 60(2): 91-110.
- [27] Guo Y, Zhang H L, Wang J W, et al. An improved distance threshold constrained ICP algorithm for 3D registration [J]. Journal of China Academy of Electronics and Information Technology, 2011, 6(6): 643-647.
郭琰, 张会林, 王金伟, 等. 基于改进距离阈值约束的 ICP 三维配准方法[J]. 中国电子科学研究院学报, 2011, 6(6): 643-647.
- [28] Stanford 3D scanning repository[EB/OL]. (2014-08-09) [2019-06-16]. <http://graphics.stanford.edu/data/3Dscanrep/>.
- [29] Robotic 3D scan repository[EB/OL]. (2016-10-15) [2019-06-16]. <http://kos.informatik.uni-osnabrueck.de/3Dscans/>.
- [30] Hu X X, Zhang L. Improved 3D-NDT multi-viewpoint cloud registration combined with NARF features[J]. Signal Processing, 2015, 31(12): 1675-1679.
胡修祥, 张良. 结合 NARF 特征的改进 3D-NDT 多视角点云配准[J]. 信号处理, 2015, 31(12): 1675-1679.
- [31] Theiler P W, Wegner J D, Schindler K. Markerless point cloud registration with keypoint-based 4-points congruent sets [J]. ISPRS Annals of Photogrammetry, Remote Sensing and Spatial Information Sciences, 2013, II-5/W2: 283-288.
- [32] Fitzgibbon A W. Robust registration of 2D and 3D point sets[J]. Image and Vision Computing, 2003, 21(13/14): 1145-1153.
- [33] Magnusson M. The three-dimensional normal-distributions transform: an efficient representation for registration, surface analysis, and loop detection[D]. Örebro: Örebro Universitet, 2009:1-5.
- [34] Lei H, Jiang G, Quan L. Fast descriptors and correspondence propagation for robust global point cloud registration[J]. IEEE Transactions on Image Processing, 2017, 26(8): 3614-3623.