

基于二进制特征描述符的点云数据配准

蔡炜¹, 岳东杰^{1*}, 陈强²

¹河海大学地球科学与工程学院, 江苏 南京 211100;

²上海市测绘院三分院, 上海 200063

摘要 传统点云数据特征描述符存在表达能力不足、计算效率低和鲁棒性不强等问题, 针对二进制形状上下文 (BSC) 特征描述符不能有效检测到曲率分布较大的区域以及局部坐标系存在二义性的问题, 提出了一种基于二进制特征描述符的点云数据配准算法。首先, 采用内在形状签名关键点检测法和三维曲面片估计方法改进语义问题。然后, 利用汉明距离与改进的几何一致性方法进行特征匹配。最后, 用随机抽样一致性算法剔除误匹配。实验结果表明, 相比快速点特征直方图、融合点签名的直方图和 BSC 算法, 本算法与迭代最近邻点算法的结合能在大幅度提升配准效率的同时减小配准误差。

关键词 机器视觉; 二进制形状上下文算法; 汉明距离; 点云配准; 特征匹配; 迭代最近邻点算法

中图分类号 P237

文献标志码 A

DOI: 10.3788/LOP202259.1015010

Point Cloud Data Registration Based on Binary Feature Descriptors

Cai Wei¹, Yue Dongjie^{1*}, Chen Qiang²

¹School of Earth Science and Engineering, Hohai University, Nanjing 211100, Jiangsu, China;

²Shanghai Institute of Surveying and Mapping, Third Branch, Shanghai 200063, China

Abstract Traditional feature descriptors of point cloud data show disadvantages such as insufficient expressiveness, low computational efficiency, and poor robustness. Aiming at the problem that the binary shape context (BSC) feature descriptors, regions with a large curvature distribution cannot be effectively detected and the ambiguity of the local coordinate system suffers. This study proposes a point cloud data registration algorithm based on binary feature descriptors. First, the intrinsic shape signature keypoint detection method and three-dimensional surface patch estimation method are used to address the problem of semantics. Then, the Hamming distance and improved geometric consistency method are used for feature matching. Finally, the random sampling consensus is used to eliminate false matches. Experimental results show that compared with the fast point feature histogram, signature of histogram of orientations, and BSC algorithms, combining the algorithm with the iterative closest point algorithm can considerably improve the registration efficiency and reduce the registration error.

Key words machine vision; binary shape context algorithm; Hamming distance; point cloud registration; feature matching; iterative closest point algorithm

1 引言

点云数据特征提取与局部描述是人工智能领域中非常活跃的研究主题, 在点云数据配准与分类

中也发挥着重要作用^[1]。目前, 大多数三维特征描述符都是浮点数形式且通过在高维向量空间中计算欧氏距离完成匹配, 计算复杂度较高, 从而影响了特征描述符的鲁棒性和表达能力, 如自旋影像

收稿日期: 2021-06-16; 修回日期: 2021-08-03; 录用日期: 2021-08-25

通信作者: *yuedongjie@163.com

(SI)^[2]、三维形状上下文(3DSC)描述符^[3]、内在形状签名(ISS)^[4]分别为 225 维、1980 维、595 维。因此,构建高效、描述能力强以及鲁棒的特征描述符是目前点云数据处理领域中一个重要的研究方向。

基于二值化的方法可以有效提高点云局部特征描述符的时间和内存使用效率^[5],但相较于二维图像处理,二进制点云特征描述符的研究较少,且现有的二进制点云特征描述符存在算法复杂、编码过程中信息损失较大、描述性不足以及对噪声和遮挡等干扰比较敏感等问题。Salti 等^[6-7]将融合点签名的直方图(SHOT)描述符量化成一个二进制向量并提出了二进制方位直方图(B-SHOT)描述符,但 B-SHOT 描述符二值化的过程中会损失部分重要信息,在多数情况下的性能不如 SHOT 描述符。Srivastava 等^[8]提出了基于点签名的三维二进制特征(3DBS)描述符,用于刻画局部表面,但 3DBS 描述符的计算时间长,且对噪声、点密度变化等比较敏感。Dong 等^[9]提出了二进制形状上下文(BSC)描述符,能很好地描述点云的局部特征,且鲁棒性较强、计算效率较高。

本文结合 BSC 特征描述符提取点云特征的优点,针对 BSC 算法在关键点检测和局部坐标系建立中存在的问题进行改进。用本算法依次完成点云数据的粗配准与精配准,并将其与现有的特征描述符进行对比实验。

2 基于 BSC 描述符的二进制特征提取算法

基于 BSC 描述符的二进制特征提取算法可以归纳为关键点检测、局部坐标系的建立、坐标转换和格

网化、加权投影特征计算以及特征二值化五个步骤。

2.1 关键点检测

点云具有数据量大、点密度不均匀、场景复杂等特性,因此,需要提取点云数据的关键点以便进行后续处理工作^[10]。BSC 描述符采用固定比例检测关键点,检测到的关键点数目较少且不能在三维对象曲率分布不均匀的地方检测到模型的固有比例^[11]。本算法用 ISS 描述符的关键点提取流程进行检测,这是一种自适应尺度的关键点提取算法,具体步骤如下。

1) 对点云中的每个点 p_i 建立局部坐标系并设定搜索半径 r ,通常将搜索半径 r 设置为 10 倍的点云平均点间距。

2) 确定以 p_i 为中心、 r 为半径区域内的所有点,并计算这些点的权值,可表示为

$$w_{ij} = 1 / |p_i - p_j|, |p_i - p_j| < r, \quad (1)$$

式中, p_j 为 p_i 在半径 r 内的邻域点。

3) 根据权值计算每个点 p_i 的协方差矩阵,可表示为

$$\text{cov}(p_i) = \frac{\sum_{|p_i - p_j| < r} w_{ij} (p_i - p_j)(p_i - p_j)^T}{\sum_{|p_i - p_j| < r} w_{ij}} \quad (2)$$

4) 计算每个点 p_i 协方差矩阵的特征值 $\{\lambda_i^1, \lambda_i^2, \lambda_i^3\}$ 。

5) 将阈值 ϵ_1 和 ϵ_2 均设定为点云库(PCL)官方文档的参数 0.975,则关键点需满足的条件可表示为

$$\lambda_i^2 / \lambda_i^1 \leq \epsilon_1, \lambda_i^3 / \lambda_i^2 \leq \epsilon_2. \quad (3)$$

图 1 为 BSC 特征描述符中的关键点提取算法与本算法提取的关键点。可以发现,本算法提取的关键点集中分布在曲率较大的地方。




图 1 不同算法提取的关键点。(a) BSC 算法;(b) 本算法

Fig. 1 Keypoints extracted by different algorithms. (a) BSC algorithm; (b) our algorithm

2.2 局部坐标系的建立

对上述点云数据的每个关键点 p_i 都需要建立一个局部坐标系 $R^{3 \times 3}$,若 p_i 在邻域范围 r 内有 m_i 个

点,首先,要找到关键点与邻域点构成的三维曲面片的质心。然后,用该三维曲面片上所有点的坐标减去质心的坐标,得到一个新的三维平均曲面片

$q_m (m = 1, \dots, m_i)$, 用关键点 p_i 的坐标值减去质心的坐标, 得到关键点坐标的均值 $q^{3 \times 1}$ 。最后, 根据新的三维曲面片估计局部坐标参考系 $R^{3 \times 3}$, 则经过坐标转换后关键点的局部坐标可表示为

$$p'_{m_i} = Rq_o \quad (4)$$

根据修正协方差矩阵 C 的特征向量估计局部坐标系 $R^{3 \times 3}$, 可将协方差矩阵表示为

$$C = \frac{1}{\sum_{m: d_m \leq r} (r - d_m)} \sum_{m: d_m \leq r} (r - d_m) (q_m - q)(q_m - q)^T, \quad (5)$$

式中, $d_m = \|q_m - q\|_2$, m 为邻域点编号。通过特征值分解得到 C 的特征值 $\lambda_1, \lambda_2, \lambda_3 (\lambda_1 \geq \lambda_2 \geq \lambda_3)$ 及其对应的特征向量 e_1, e_2, e_3 , 然后以关键点 p_i 为原点, e_1 为 x 轴, e_2 为 y 轴, $e_1 \times e_2$ 作为 z 轴建立局部坐标系。

基于 BSC 特征描述符建立局部坐标系的方法计算步骤繁琐且局部坐标系存在二义性的问题, 而本算法中构建局部坐标系的方法能近似捕获点云的局部三维表面图案, 同时极大减小了搜索空间。图 2 为上述点云数据中某一关键点及其邻域点的局




图 2 关键点及其邻域的局部坐标系

Fig. 2 Local coordinate system of keypoints and their neighborhoods

部坐标三维图。

2.3 坐标转换与格网化

为了增强特征描述符对于平移、旋转、视角变化等因素的鲁棒性, 需要将每个关键点及其邻域点集 $\{p_o, \dots, p_{m_i}\}$ 转换到局部坐标系下, 得到转换后的点集 $\{p'_o, \dots, p'_{m_i}\}$, 然后将转换后的点集投影到三个平面中并进行格网化。图 3 为上述点云数据中某一关键点邻域局部坐标的投影和格网化结果。




图 3 点云投影和格网化。(a) xoy 平面; (b) xoz 平面; (c) $yozy$ 平面

Fig. 3 Point cloud projection and gridding. (a) xoy plane; (b) xoz plane; (c) $yozy$ plane

2.4 计算加权投影特征

为了提高特征的鲁棒性, 采用高斯距离加权方式累积每个格网的投影特征。以 xoy 平面为例, 每

个格网的归一化加权投影密度特征和加权投影距离特征可表示为

$$\begin{cases} f_{xy}^D(b) = \frac{1}{m_b} \sum_{n=1}^{m_b} \frac{1}{\sqrt{2\pi} h} \exp\left(-\frac{\|q_n^{xy} - c_b^{xy}\|^2}{2h^2}\right), \text{ s.t. } \|q_n^{xy} - c_b^{xy}\| < 3h \\ f_{xy}^d(b) = \frac{1}{m_b} \sum_{n=1}^{m_b} d_{xy}(q'_n) \frac{1}{\sqrt{2\pi} h} \exp\left(-\frac{\|q_n^{xy} - c_b^{xy}\|^2}{2h^2}\right), \text{ s.t. } \|q_n^{xy} - c_b^{xy}\| < 3h \end{cases}, \quad (6)$$

式中, b 为对应格网, $f_{xy}^D(b)$ 为加权投影密度特征, $f_{xy}^d(b)$ 为加权投影距离特征, q_n^{xy} 为邻域点 q'_n 在 xoy 平面的投影, c_b^{xy} 为格网 b 在 xoy 投影面上的中心点, m_b 为满足条件的邻域点个数, h 为高斯核半径,

$d_{xy}(q'_n)$ 为点 q'_n 到 xoy 投影面的距离。图 4 和图 5 为上述点云数据中某一关键点在 xoy 投影面的加权投影密度特征和加权投影距离特征。




图 4 加权投影密度特征

Fig. 4 Weighted projection density characteristics




图 5 加权投影距离特征

Fig. 5 Weighted projection distance characteristics

2.5 特征二值化

特征二值化通过差异测试将局部表面信息编码为二进制字符串,一次差异测试选择 1 对 (2 个) 特征并计算其差异^[12]。若所选的特征对之间存在明显差异,则将差异测试值设置为 1; 否则, 设置为 0。这种方法可以编码关于局部点分布更详细的信息, 但对网格中每个特征对进行差异化测试的效率较低, 因此, 选择合适的差异化测试数目可以大大提高计算效率和匹配速度。图 6 为将 xoy 投影面的投影距离特征归一化的结果, 对应的数字表示格子的序号。

对于每个投影面上的 N 个格子, 首先从 C_N^2 种差异性测试中随机选择一定数量的子集 Ω , 即所有关键点的差异化测试都要使用相同的子集 Ω , 可表示为

$$\Omega = \{(b_1, b'_1), \dots, (b_i, b'_i), \dots, (b_g, b'_g)\} \quad (7)$$

s. t. $b_i \neq b'_i \in \{1, \dots, N\}$,

$$\{(11, 18) = 0, (19, 5) = 0, (9, 12) = 0, (23, 25) = 0, \dots, (7, 9) = 1\}, \quad (8)$$

式中, g 为位置对的数量, 位置对 (b_i, b'_i) 为两个所选库的索引, 对应的特征将用于差异化测试。由于位




图 6 投影距离特征二值化的示意图

Fig. 6 Schematic diagram of binarization of projection distance feature

置对集合 Ω 是固定的, 所有关键点投影特征差异测试使用相同的位置对, 以保证相似的点分布产生相似的特征描述符。式 (8) 是用于差异性测试的格子序号以及对应的差异测试结果。每个采样位置对的加权投影密度差异化计算结果 τ^D 可表示为

$$\tau^D(b_i, b'_i) = \begin{cases} 1, & \text{if } |f^D(b_i) - f^D(b'_i)| > \sigma^D \\ 0, & \text{else} \end{cases}$$

$$\sigma^D = \sqrt{\frac{1}{g-1} \sum_{i=1}^g [|f^D(b_i) - f^D(b'_i)| - \mu^D]^2}, \quad (9)$$

$$\mu^D = \frac{1}{g} \sum_{i=1}^g |f^D(b_i) - f^D(b'_i)|$$

式中, $f^D(b_i)$ 和 $f^D(b'_i)$ 分别为投影面上格子 b_i 和 b'_i 的投影密度特征, $| \cdot |$ 为绝对值符号, μ^D 和 σ^D 分别为投影面上 g 个投影密度差值的均值和方差。加权投影距离差异化测试的计算方法与上述方法的原理相同, 投影面的投影密度和距离特征可表示为

$$\begin{cases} t^D = \sum_{i=1}^g 2^{i-1} \tau^D(b_i, b'_i) \\ t^d = \sum_{i=1}^g 2^{i-1} \tau^d(b_i, b'_i) \end{cases}, \quad (10)$$

式中, t^D 为投影面的投影密度特征, t^d 为投影面的投影距离特征。

最后, 融合局部坐标系和三个投影面的 6 个十进制对应位置组合成一个特征向量, 得到关键点 p_i 的特征描述符, 可表示为

$$X_{\text{BSC}}(p_i) = \{t_{xoy}^D, t_{xoy}^d, t_{xoz}^D, t_{xoz}^d, t_{yoz}^D, t_{yoz}^d\}. \quad (11)$$

3 实验结果与分析

3.1 特征描述符的性能评价指标

精确率-召回率 (PR) 曲线是常用来描述特征

描述符性能的方法,因此,用 PR 曲线评价特征描述符的性能^[13]。给定一个源点云和目标点云及其之间的转换矩阵 T ,首先找出源点云和目标点云的关键点,然后找出每个源点云中关键点在目标点云中距离最近的关键点。如果两个关键点之间的欧氏距离小于设定阈值(通常选取源点云的平均点间距),则认为这两个关键点是同名关键点。对源点云中的每个关键点,在目标点云中找到与其特征最相似的关键点,如果这两个关键点特征描述符的距离小于阈值 ϵ ,则认为这两个关键点的特征匹配;若特征匹配点的索引值和同名关键点的索引值相同,则认为这两个关键点是正确的特征匹配。PR 曲线中的精确率($X_{\text{precision}}$)和召回率 X_{recall} 可表示为

$$X_{\text{precision}} = \frac{N_{\text{cfm}}}{N_{\text{fm}}}, X_{\text{recall}} = \frac{N_{\text{cfm}}}{N_{\text{ck}}}, \quad (12)$$

式中, N_{cfm} 、 N_{fm} 、 N_{ck} 分别为正确的特征匹配个数、总特征匹配个数、同名关键点个数。通过改变阈值 ϵ ,生成源点云和目标点云的 PR 曲线,PR 曲线越靠近图的左上角,表明特征描述符的精确率和召回率越高,特征描述符的鉴别能力就越好。

本算法有三个重要参数:高斯核半径 h 、格网数量 S 以及差异性测试数量 g 。文献[11]给出了最佳的参数配置 $\{h = 4\Delta, S = 5, g = 128\}$,其中, Δ 为源点云和目标点云的平均点间距。利用 PR 曲线定量评价本算法的描述性,并与 SHOT、快速点特征直方图(FPFH)^[14]、基于点分布的三维直方图(3DHoPD)^[15]和 BSC 描述符进行对比实验。

3.2 实验数据及性能评价

为全面评价本算法的计算效率,在配置为 AMD Ryzen7 4800U、内存为 16 GB、Windows 10 操作系统的计算机上进行实验;BSC、3DHoPD、FPFH、SHOT 算法和本算法在 Visual Studio 2013、PCL1.8.0、Pycharm、Open 3D 中实现,点云数据为实测的某地水上水下一体化点云数据,点云总数量为 815 万,如图 7 所示。

通过对原始点云进行曲率压缩,得到点云数量为 76938 的源点云;通过 ISS 算法检测出 2307 个关键点,得到目标点云的数量为 86070 个,通过 ISS 算法检测出 2757 个关键点,然后分别采用 FPFH、SHOT、BSC 算法和本算法对点云数据进行特征提取,不同算法在不同邻域点数量下的计算时间如表 1 所示。可以发现,相比其他算法,本算法的计算速度较快,在邻域点数量为 10 的情况下,本算法分别




图 7 原始点云数据。(a)源点云;(b)目标点云

Fig. 7 Original point cloud data. (a) Source point cloud; (b) target point cloud

比 FPFH、SHOT、3DHoPD、BSC 算法的计算时间约快 142、104、49、8 s;在邻域点数量为 100 的情况下,本算法分别比 FPFH、SHOT、3DHoPD、BSC 算法的计算时间约快 204、170、58、7 s;在邻域点数量为 1000 的情况下,本算法分别比 FPFH、SHOT、3DHoPD、BSC 算法的计算时间约快 280、214、78、7 s。

表 1 不同算法的计算时间

Table 1 Computation time of different algorithms unit: s

Algorithm	Number of neighbor points		
	10	100	1000
FPFH	152.917	217.471	295.652
SHOT	114.543	183.762	228.776
3DHoPD	59.631	71.767	93.185
BSC	18.163	20.132	22.173
Ours	10.312	13.537	15.273

为了全面评价本算法中特征描述符的性能,通过改变匹配点对之间的距离阈值,绘制出不同算法的 PR 曲线,结果如图 8 所示。可以发现,相比其他算法,本算法可以通过编码投影密度和距离信息获取更丰富的激光点云局部表面信息,具有更好的描述性。

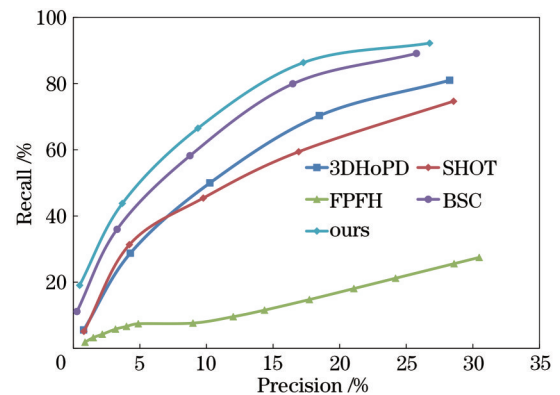


图 8 不同描述符的 PR 曲线

Fig. 8 PR curves of different descriptors

3.3 配准实验与分析

针对基于欧氏距离、马氏距离和信息熵等相似性算法进行特征匹配中误匹配较多的情况^[16],从降低误匹配率、提高计算效率的角度出发,基于融合汉明距离和改进几何一致性的策略进行特征匹配。汉明距离是对两个二进制特征描述符进行异或运算,并统计结果为1的数量,数量越少,表明这两个二进制特征描述符越相似。

首先,对源点云和目标点云进行关键点检测并计算特征描述符,然后根据汉明距离匹配目标点云 S 和源点云 F 的特征描述符。假设 $Q_S\{n_1^S, \dots, n_k^S, \dots, n_{N_S}^S\}$, $Q_F\{n_1^F, \dots, n_l^F, \dots, n_{N_F}^F\}$ 分别为源点云和目标点云的特征描述符集合,其中, N_S 和 N_F 分别为源点云和目标点云的关键点个数, $n_k^S (k=1, \dots, N_S)$ 和 $n_l^F (l=1, \dots, N_F)$ 为源点云和目标点云中每个关键点的特征描述符,则初始匹配的点对计算步骤:1)在目标点云中, n_l^F 与 n_k^S 之间的汉明距离最小且唯一;2)在源点云中, n_k^S 与 n_l^F 之间的汉明距离最小且唯一。

遍历源点云和目标点云中所有特征描述符后,得到初始的匹配点对集合 $C\{c_1, \dots, c_m, \dots, c_M\}$,其中, $c_m\{p_m^S, p_m^F\}$ 为第 m 个匹配点对, p_m^S 和 $p_m^F (m=1, \dots, M)$ 分别为源点云和目标点云中的关键点, M 为匹配点对的数量。初始匹配点对集合 $C\{c_1, \dots, c_m, \dots, c_M\}$ 仍存在一些错误匹配,因此,用改进的几何一致性方法剔除“良好”的错误匹配。对于两个正确的匹配 $c_m\{p_m^S, p_m^F\}$ 和 $c_n\{p_n^S, p_n^F\} (n \neq m, n=1, \dots, M)$, 关键点 p_m^S 和 p_n^S 在局部坐标系 F_m^S (关键点 p_m^S 对应的局部坐标系) 和 F_n^S (关键点 p_n^S 对应的局部坐标系) 具有相同的局部坐标 (x^S, y^S, z^S) 和 (x^F, y^F, z^F) , 且满足

$$\begin{cases} |x^S - x^F| < \epsilon \\ |y^S - y^F| < \epsilon, \\ |z^S - z^F| < \epsilon \end{cases} \quad (13)$$

式中, ϵ 为两坐标差值的阈值,通常设置为邻域半径的一半。

改进几何一致性剔除误匹配的步骤:1)将一个匹配点对作为初始匹配点对,然后遍历匹配点对集合 C 中的所有匹配点对,如果该匹配点对与初始匹配点对满足式(13),则将其加入同名特征集合中;2)对于 C 中每个匹配点对,重复步骤1);3)选取匹配点对最多的集合作为最终的同名匹配点对集合 $C_1\{c_1, \dots, c_q, \dots, c_H\}$, H 为最终的同名匹配点对个

数。图9为经过改进几何一致性方法筛选的匹配点对,用随机抽样一致(RANSAC)算法^[17]消除误匹配后得到的匹配点对如图10所示。




图9 基于改进几何一致性方法得到的匹配点对
Fig. 9 Matching point pairs obtained based on improved geometric consistency method




图10 基于RANSAC算法处理后的匹配点对
Fig. 10 Matching point pair processed based on RANSAC algorithm

由于RANSAC算法的迭代次数多且计算量大,因此在误匹配较多的情况下耗时较长。从图9和图10可以发现,本算法能大大减少RANSAC算法的计算量,由最终的匹配点对计算源点云和目标点云的点云转换参数。图11为FPFH、SHOT、BSC算法以及本算法的粗配准结果。计算得到,FPFH、SHOT、BSC算法以及本算法粗配准结果的均方根误差(RMSE)分别为 ± 19.73 mm、 ± 22.97 mm、 ± 10.63 mm 以及 ± 8.19 mm,这表明本算法有着较高描述性的同时又能达到很好的配准精度。

最后,采用点对平面的迭代最近邻(ICP)算法^[18]进一步细化对齐点云,计算得到FPFH、SHOT、BSC算法以及本算法精配准结果的RMSE分别为 ± 7.13 mm、 ± 7.27 mm、 ± 6.31 mm 以及 ± 5.37 mm。虽然其他算法的精配准效果在视觉上无明显差异,但本算法的计算效率较高,相比其他算法的RMSE也至少减小了14.9%,图12为本算法的精配准结果。

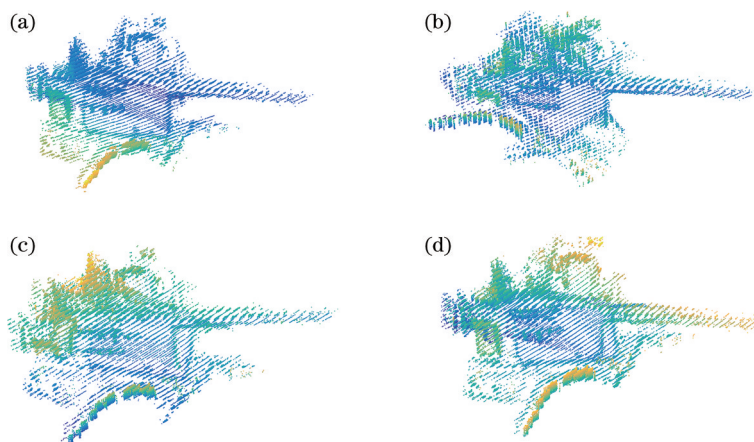


图 11 不同算法的粗配准结果。(a) FPFH;(b) SHOT;(c) BSC;(d)本算法

Fig. 11 Coarse registration results for different algorithms. (a) FPFH; (b) SHOT; (c) BSC; (d) our algorithm




图 12 本算法的精配准结果

Fig. 12 Fine registration result of our algorithm

4 结 论

对点云数据特征提取展开了深入研究,针对现有点云特征描述符局部表达能力不足、鲁棒性差、计算效率低以及误匹配较多的问题,提出了一种描述性强、计算效率高的二进制特征描述符,并结合汉明距离进行特征匹配。实验结果表明,在大规模点云数据的特征提取中,相比 FPFH、SHOT、3DHoPD、BSC 算法,本算法具有更好的描述性,且在不同邻域点数量条件下,本算法的计算速度更快。最后,将本算法应用到点云数据配准中,采用汉明距离与改进几何一致性相结合的方法进行特征匹配,大大降低了误匹配率。但该算法在特征提取过程中需要手动选取参数,对于不同点云数据选取的参数可能会不同,因此下一步还需对算法的自适应性进行改进。

参 考 文 献

[1] 唐志荣,刘明哲,蒋悦,等. 基于典型相关分析的点云配准算法[J]. 中国激光, 2019, 46(4): 0404006.
Tang Z R, Liu M Z, Jiang Y, et al. Point cloud registration algorithm based on canonical correlation analysis[J]. Chinese Journal of Lasers, 2019, 46(4):

0404006.

- [2] Brusco M, Andreetto M, Giorgi A, et al. 3D registration by textured spin-images[C]//Fifth International Conference on 3-D Digital Imaging and Modeling (3DIM'05), June 13-16, 2005, Ottawa, ON, Canada. New York: IEEE Press, 2005: 262-269.
- [3] Mori G, Malik J. Estimating human body configurations using shape context matching[M]//Heyden A, Sparr G, Nielsen M, et al. Computer vision-ECCV 2002. Lecture notes in computer science. Heidelberg: Springer, 2002, 2352: 666-680.
- [4] 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 Press, 2009: 689-696.
- [5] 杨必胜,董震. 点云智能处理[M]. 北京: 科学出版社, 2020.
Yang B S, Dong Z. Point cloud intelligent processing [M]. Beijing: Science Press, 2020.
- [6] Salti S, Tombari F, di Stefano L. SHOT: unique signatures of histograms for surface and texture description[J]. Computer Vision and Image Understanding, 2014, 125: 251-264.
- [7] Prakhya S M, Liu B B, Lin W S, et al. B-SHOT: a binary 3D feature descriptor for fast keypoint matching on 3D point clouds[J]. Autonomous Robots, 2017, 41(7): 1501-1520.
- [8] Srivastava S, Lall B. 3D binary signatures[C]//Proceedings of the Tenth Indian Conference on Computer Vision, Graphics and Image Processing-ICVGIP '16, December 18-22, 2016, Guwahati, Assam, India. New York: ACM Press, 2016: 1-8.

- [9] Dong Z, Yang B S, Liu Y, et al. A novel binary shape context for 3D local surface description[J]. *ISPRS Journal of Photogrammetry and Remote Sensing*, 2017, 130: 431-452.
- [10] 马国庆, 刘丽, 于正林, 等. 基于 iGPS 的复杂曲面三维点云拼接技术[J]. *中国激光*, 2019, 46(2): 0204003.
Ma G Q, Liu L, Yu Z L, et al. Three-dimensional point cloud splicing technology of complex surfaces based on iGPS[J]. *Chinese Journal of Lasers*, 2019, 46(2): 0204003.
- [11] 王永波, 郑南山, 卞正富. 平面特征约束下基于四元数描述的 LiDAR 点云配准算法[J]. *光学学报*, 2020, 40(23): 2310001.
Wang Y B, Zheng N S, Bian Z F. Planar feature-constrained, quaternion-based registration algorithm for LiDAR point clouds[J]. *Acta Optica Sinica*, 2020, 40(23): 2310001.
- [12] 唐敏杰, 赵欢, 丁汉. 二进制点云局部特征描述子研究[J]. *机械工程学报*, 2021, 57(2): 219-229.
Tang M J, Zhao H, Ding H. Research on binarized local feature descriptors of point clouds[J]. *Journal of Mechanical Engineering*, 2021, 57(2): 219-229.
- [13] Zhou Q M, Lu Z, Brooke R J, et al. Evaluating the incremental value of a new model: area under the ROC curve or under the PR curve[EB/OL]. (2020-10-19)[2021-04-02]. <https://arxiv.org/abs/2010.09822>.
- [14] 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.
- [15] Prakhya S M, Lin J, Chandrasekhar V, et al. 3DHoPD: a fast low-dimensional 3-D descriptor[J]. *IEEE Robotics and Automation Letters*, 2017, 2(3): 1472-1479.
- [16] 雷玉珍, 李中伟, 钟凯, 等. 基于随机抽样一致算法的误匹配标志点校正方法[J]. *光学学报*, 2013, 33(3): 0315002.
Lei Y Z, Li Z W, Zhong K, et al. Mismatching marked points correction method based on random sample consensus algorithm[J]. *Acta Optica Sinica*, 2013, 33(3): 0315002.
- [17] Schnabel R, Wahl R, Klein R. Efficient RANSAC for point-cloud shape detection[J]. *Computer Graphics Forum*, 2007, 26(2): 214-226.
- [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.