

基于弧长密度的自动邻域半径鉴别 FPFH 提取算法

朱琛琛, 齐 林, 帖 云

(郑州大学 信息工程学院, 郑州 450001)

摘 要: 在快速点特征直方图(FPFH)的特征计算过程中,需要人工多次选择邻域半径,计算过程复杂且效率较低。针对该问题,提出基于弧长密度的自动邻域半径鉴别 FPFH 特征提取算法。给出点云弧长密度的计算方法,依据弧长密度估算多对点云的邻域半径,以提取 FPFH 特征并完成采样一致性初始配准,确定配准性能最优的半径与弧长密度值。在此基础上,使用最小二乘法拟合邻域半径与弧长密度之间的函数表达式,并与 FPFH 特征提取算法结合得到自动邻域半径鉴别 FPFH 特征提取算法。实验结果表明,该算法可根据点云弧长密度自动鉴别出合适的邻域半径,运算速度较快。

关键词: 点云密度;邻域半径;快速点特征直方图;采样一致性初始配准;最小二乘法

开放科学(资源服务)标志码(OSID):



中文引用格式:朱琛琛,齐林,帖云.基于弧长密度的自动邻域半径鉴别 FPFH 提取算法[J].计算机工程,2019,45(10):253-259.

英文引用格式:ZHU Chenchen, QI Lin, TIE Yun. Automatic neighborhood radius identification FPFH extraction algorithm based on arc length density[J]. Computer Engineering, 2019, 45(10): 253-259.

Automatic Neighborhood Radius Identification FPFH Extraction Algorithm Based on Arc Length Density

ZHU Chenchen, QI Lin, TIE Yun

(College of Information Engineering, Zhengzhou University, Zhengzhou 450001, China)

【Abstract】 The computation of Fast Point Feature Histogram (FPFH) features requires human intervention to choose the neighborhood radius, which adds to the complexity and decreases the efficiency of computation. To address the problem, an automatic neighborhood radius identification algorithm for FPFH feature extraction based on arc length density is proposed. The calculation method of point cloud arc length density is given. The neighborhood radius of multiple pairs of point clouds is estimated according to the arc length density to extract FPFH features and complete Sample Consensus Initial Alignment (SAC-IA). The optimal values of the radius and arc length density are determined. On this basis, the least square method is used to fit the function expression between the neighborhood radius and the arc length density, and combined with the FPFH feature extraction algorithm to form an automatic neighborhood radius identification FPFH feature extraction algorithm. The experimental results show that the algorithm can automatically identify the appropriate neighborhood radius according to the point cloud arc length density, and the computation speed is fast.

【Key words】 point cloud density; neighborhood radius; Fast Point Feature Histograms (FPFH); Sample Consensus Initial Alignment (SAC-IA); least square method

DOI: 10.19678/j.issn.1000-3428.0052880

0 概述

基于点云数据对现实生活场景进行感知是计算机视觉领域研究的热点。点云特征包括全局特征与局部特征,前者多应用于三维物体识别,而后者在位

姿配准中应用较多。文献[1-3]提出点特征直方图(Point Feature Histograms, PFH)特征提取算法,该算法具有较好的特征提取能力,但运算速度较慢。为提升 PFH 运算速度,文献[4]提出快速点特征直方图(Fast Point Feature Histograms, FPFH)特征提取算

基金项目:国家自然科学基金(61071211,61331021)。

作者简介:朱琛琛(1992—),男,硕士研究生,主研方向为三维重建、图像处理;齐林、帖云,教授、博士。

收稿日期:2018-10-16 修回日期:2018-12-02 E-mail: zuzcczhu@163.com

法,该算法可提升特征提取的运算速度,节省运算空间,减少数据处理的迭代步数,因此广泛应用于三维物体的识别及配准。文献[5]提出基于ICP的配准算法,该算法使用FPFH点云特征对钢质零件的位姿信息进行求解。文献[6]基于FPFH特征设计了点云配准系统,以对由多个深度相机同时拍摄所得的点云或由单个相机从不同角度拍摄所得的多幅点云进行配准。文献[7]使用FPFH特征进行粗配准,在求出初始位姿的基础上进行ICP配准。文献[8]使用FPFH特征对人体各部位点云进行提取并完成识别匹配。

上述基于点FPFH特征的提取算法在计算点云FPFH特征时未考虑邻域半径的选取标准,未能根据点云的特点自动鉴别出合适的邻域半径。另外,通过手动多次调试以取得邻域半径的方法效率较低。为此,本文提出一种基于点云弧长密度的FPFH特征提取算法,根据点云弧长密度自动鉴别出合适的邻域半径,以用于FPFH的特征计算。

1 基于点云弧长密度的FPFH特征提取算法

1.1 特征提取算法

基于点云弧长密度的自动邻域半径鉴别FPFH特征提取算法包括2个部分,分别为求解半径函数与计算FPFH特征,如图1所示。

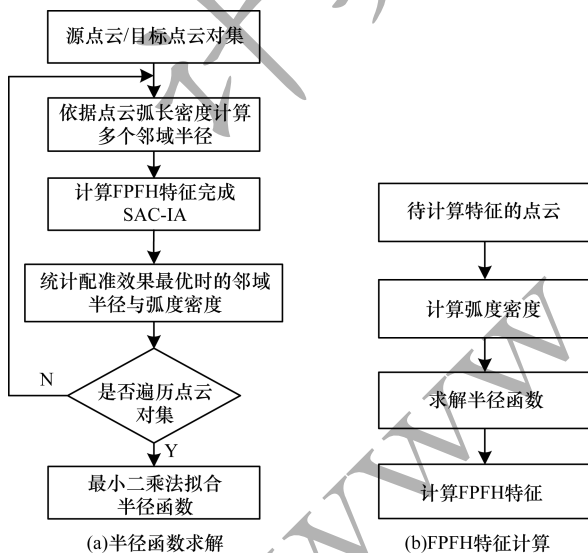


图1 基于点云弧长密度的FPFH特征提取算法流程

在求解半径函数过程中,首先计算多对点云的弧长密度,根据弧长密度以手动选择的方法找出多个邻域半径,计算点云FPFH特征并完成采样一致性初始配准(Sample Consensus Initial Alignment, SAC-IA),提取配准效果最好的邻域半径和弧长密度,使用最小二乘法拟合邻域半径与弧长密度的函数关系,称为半径函数。将半径函数与FPFH特征提取算法相结合,求

出点云弧长密度并输入给半径函数,进而自动鉴别得到合适的邻域半径以计算FPFH特征。本文算法在计算FPFH特征时不再使用人工手动选择邻域半径的方法,根据点云本身的弧长密度特点自动鉴别出合适的邻域半径,从而达到全自动的目的。

1.2 点云弧长密度

1.2.1 点云密度估算

目前对点云密度的估算方法有2种:基于距离的方法与基于分块的方法^[9]。基于距离的点云密度求解方法是以点云内各点间的欧氏距离为度量标准衡量点云中点的分布情况。而基于分块的方法是将点云均匀分成若干块,计算出分布在各块点的点云数目并进行取舍组合,进而得到点云的密度估算值。但是以上2种方法均是对点云分布粗略的估算,不能较好地体现点云中点的分布特性,因此本文提出点云弧长密度提取方法,以点云分布表面的曲面特性为基础估算点云分布情况,能较好地体现点云分布的本质特征。

1.2.2 点云法线估算

计算点云的弧长密度要先计算点云各点的法线。目前,估算点云法线的方法有曲面重建和直接估算法。曲面重建通过重建点云模型,得到待求点所在物体表面的拟合曲面,然后计算得到法线。直接估算法则直接根据点的邻域估计点的法线。本文使用的方法属于直接估算法,通过在点云中某点的k-邻域内使用PCA算法进行求解^[10]。对于点云P中的一点 $p_i = (x_i, y_i, z_i)$, $i = 1, 2, \dots, n$,在其k-邻域内构建协方差矩阵有:

$$A_{3 \times 3} = \frac{1}{n} \sum_{i=1}^n (p_i - \bar{p})(p_i - \bar{p})^T \quad (1)$$

其中, $\bar{p} = \frac{1}{n} \sum_{i=1}^n (p_{x_i}, p_{y_i}, p_{z_i})$ 为k-邻域内所有点的质心, n 为点云中点的个数。式(1)中协方差矩阵能够较好地描述点云局部几何信息。通过对A进行奇异值分解(Singular Value Decomposition, SVD)^[11]求解出特征值 $\lambda_i (i = 0, 1, 2)$,并按照由大到小的顺序进行排列,即 $\lambda_2 \geq \lambda_1 \geq \lambda_0 \geq 0$,各个特征值对应的特征向量为 v_2, v_1, v_0 。PCA算法的作用是将数据集映射到低维空间,数据集的特征值(在SVD中用奇异值表征)按照重要性排列,降维的过程就是舍弃不重要的特征向量的过程,而剩下的特征向量组成的空间即为降维后的空间。因此,前2个特征值所对应的特征向量可以描述一个点云局部表面的变化特性。对于给定的三维点云中的点,可以描述一个平面,如式(2)所示。

$$ax + by + cz + d = 0 \quad (2)$$

其中, (a, b, c) 为该平面的法向量, d 为平面到坐标原点的距离, 从而可知与最小的特征值 λ_0 对应的特征向量 v_0 为对应于点 p_i 的平面的法向量 n_i 。

为确定法向量的方向, 取点云采集设备的位置为视点 $v_p = (x_{vp}, y_{vp}, z_{vp})$, 当视点满足式(3)时, n_i 的取向正确。


$$n_i \cdot (v_p - p_i) > 0 \quad (3)$$

当视点满足式(4)时, n_i 取向为原法向量的反向

$$n_i = -n_i。$$


$$n_i \cdot (v_p - p_i) < 0 \quad (4)$$

图 2 所示为点云表面法线示意图。可以看出, 由现实生活中的物体采样生成的点云并不光滑, 点与点之间具有一定的弧度特性, 即使所采样的物体对象表面为平面, 所生成的点云并不严格平滑, 具有丰富的凹凸几何性质。现实生活的物体一般表现为空间曲面特性, 如图 3 所示。因此, 与基于距离的方法与基于分块的方法相比, 使用点云中点与点之间的弧长来描述点云中点的分布疏密情况更能保持物体的几何性质。




(a)点云 (b)法线

图 2 点云表面法线示意图



(a)公鸡 (b)兔子




(c)碗 (d)水杯

图 3 点云曲面特性示意图


1.2.3 弧长密度求解

点云的弧长密度可以近似地体现出物体表面的空间关系特征、形状特征及疏密特性, 计算点云的弧

长密度, 需要先计算每组点对的弧长。将点云中的 2 点 p_i 和 p_j 近似看成空间球体表面上的 2 点, 以图 3(a) 中公鸡的点云为例, 局部放大公鸡的点云, 将球体表面上 2 点 p_i, p_j 与球心相连, 得到的空间几何位置关系如图 4 所示。



(a)公鸡 (b)局部点云



(c)空间几何位置关系

图 4 公鸡局部点云空间两点的位置关系

对于点云中一点 p_i , 求解所得单位法向量为 n_i , 在点云邻域半径为 r 的范围内距离点 p_i 最近的点为 p_j , 对应的单位法向量为 n_j , 2 点的欧氏距离为 d 。

由图 4 可得:

$$n_i \cdot n_j = \cos \varphi \quad (5)$$

则有:

$$\varphi = \arccos(n_i \cdot n_j) \quad (6)$$

同时, 由三角形的边角关系可得:

$$r = \frac{d}{\sqrt{2(1 - \cos \varphi)}} \quad (7)$$

综合上述各式, 可得到弧长 l_i :

$$l_i = \varphi r \quad (8)$$

从而可得到平均弧长 \bar{l} :

$$\bar{l} = \frac{1}{n} \sum_{i=1}^n l_i \quad (9)$$

弧长密度是将弧长 \bar{l} 作为点云分布疏密的衡量标准。对于相对光滑的平面, 某些点之间所计算的单位法向量可能相互平行, 角度 φ 的值为 0, 不能使用弧长密度来表示点云的密度, 此时可使用 2 点的欧氏距离 d 代替平均弧长 \bar{l} 。然后将 φ 的值为 0 和不为 0 这 2 种情况进行综合求解得到点云整体弧长密度, 描述点云分布的同时, 可保持点云表面的曲面性质。

1.3 点云 FPFH 特征与 SAC-IA

点云 FPFH 是对点特征直方图 PFH 的加速。PFH 通过统计点云内各点的 k-邻域内点对的法线相对角度关系来形成直方图,计算原理如图 5 所示。其中, p_q 是查询点,该查询点位于半径为 r 的球心, p_q 的 k-邻域点均位于球内,邻域内所有点两两相连接成点对。




图 5 PFH 计算原理示意图

要计算点云中任一个点 p 的 PFH 特征,首先要建立局部坐标系和求解点云的法线,步骤如下:

- 1) 搜索该点位于半径为 r 的球内的 k-邻域点;
- 2) 对于 k-邻域内的任意点对 p_i 与 p_j (i 与 j 不相等),对应的法线分别为 n_i 与 n_j ,在 p_i 上定义局部坐标系 uvw ,如图 6 所示,坐标系的方向与法向量和点之间的关系如式(10)所示。

$$\begin{cases} u = n_i \\ v = \frac{p_j - p_i}{\|p_j - p_i\|} \times u \\ w = u \times v \end{cases} \quad (10)$$




图 6 局部坐标系

- 3) 基于 uvw 坐标系,根据式(10)计算 p_i 与 p_j 法线 n_i 与 n_j 之间的 3 个变量值:

$$\begin{cases} \alpha = v \cdot n_j \\ \phi = u \cdot \frac{p_j - p_i}{\|p_j - p_i\|} \\ \theta = \arctan(w \times n_j, u \times n_j) \end{cases} \quad (11)$$

将 3 个量值联合构成 (α, ϕ, θ) 的形式,每个值使用 5 个区间来统计,因此会生成 125 维的 PFH 特征。

由图 5 可以看出,PFH 的计算复杂度为 $O(nk^2)$ (n 为点云的总点数),运算速度较慢。为提升特征

提取的运算速度,文献[4]提出 FPFH 特征提取算法,该算法将计算复杂度降低为 $O(nk)$ 。FPFH 特征的计算原理如图 7 所示。




图 7 FPFH 特征计算原理示意图

FPFH 特征计算步骤为:

- 1) 计算查询点 p_q 与 p_q 的 k-邻域内的点的 PFH,称为 SPFH。
- 2) 对于 p_q 邻域内的每一点,计算相应 k-邻域内的点的 SPFH。
- 3) 使用式(12)计算 p_q 的 FPFH:

$$FPFH(p_q) = SPFH(p_q) + \frac{1}{k} \sum_{i=1}^k \frac{1}{w_i} SPFH(p_i) \quad (12)$$

其中, w_i 是点 p_q 与其邻域点 p_i 的欧氏距离,并将其作为计算的权值。点云中的一点生成 FPFH 特征,如图 8 所示。




图 8 FPFH 特征图形

由上述分析可知:在 FPFH 特征计算过程中,邻域半径的选择比较重要,较大的半径会导致邻域内的点过多,计算速度会降低;较小的半径虽能加速运算过程,但计算所得特征性能较差。因此,在计算 FPFH 时,根据点云特性自动鉴别出合适的邻域半径,使得特征的运算速度得到大幅提升,并改善特征性能。

根据以上计算所得的弧长密度 \bar{l} , 以手动选取的方式选择多个邻域半径, 计算每对点云的 FPFH 并完成 SAC-IA^[12], 具体步骤为:

1) 对源点云 P 进行抽样, 为保证所采样的点具有不同的 FPFH 特征, 采样点两两之间的距离应大于预先给定的最小距离阈值 d_{\min} 。

2) 搜索目标点云 Q 中与步骤 1 的 N 个采样点 FPFH 特征一样或接近的一个点或多个点, 选其中一个作为 P 对于 Q 的对应点。

3) 计算对应点的刚体变换矩阵, 通过求解对应点变换后的距离误差和函数来判断配准的性能。误差越小, 配准效果越好。

配准误差得分用 Huber 惩罚函数^[13] $L_h(e_i)$ 表示, 有:

$$L_h(e_i) = \begin{cases} \frac{1}{2}e_i^2, & \|e_i\| \leq t_e \\ \frac{1}{2}t_e(2\|e_i\| - t_e), & \|e_i\| > t_e \end{cases} \quad (13)$$

其中, t_e 为预设的阈值, e_i 为第 i 组对应点的距离误差。迭代以上 3 个步骤, 手动选择多个邻域半径对点云集中的每对点云完成 SAC-IA, 求解误差得分最小时的变换矩阵, 并确定误差得分最小时所选择的邻域半径, 其中, 最优邻域半径采用穷举的方法得到。将多对点云集统计出误差得分小且配准效果好的邻域半径与配准的点云弧长密度一一对应, 所得的多组数值代表配准性能最优时的邻域半径与弧长密度, 并用于半径函数的拟合。

1.4 拟合函数曲线

基于 1.3 节所统计出的邻域半径与弧长密度数值组, 使用最小二乘法^[14-15] 完成曲线的拟合, 找出邻域半径与弧长密度的函数关系。最小二乘法是广泛使用的数据分析方法, 通过一组实验数据, 根据残差平方和最小准则, 确定解析函数以描述变量间的关系, 进而求取数据之间的客观规律。

对于给定的实验数据 $(x_i, y_i) (i=0, 1, \dots, m)$, 求出自变量 x 与因变量 y 的函数关系 $y = s(x; a_0, a_1, \dots, a_n)$ ($n < m$), 实质是在函数类 $s(x) \in \text{span}\{\varphi_0, \varphi_1, \dots, \varphi_n\}$ 上确定唯一的函数 $s(x) = a_0\varphi_0(x) + a_1\varphi_1(x) + \dots + a_n\varphi_n(x)$, 使在给定点 x_i 上的误差 $\delta_i = s(x_i) - y_i (i=0, 1, \dots, m)$ 的平方和最小。当 $\varphi_k(x) = x^k (k=0, 1, 2, \dots, n)$ 时, 函数 $s(x) = a_0 + a_1x + \dots + a_nx^n$ 。

通过选择合适的 n 值, 使用最小二乘法拟合出邻域半径 r 与弧长密度 \bar{l} 的函数曲线, 称为半径函数, 记作 $r(\bar{l})$, 其图形曲线如图 9 所示(图中的弧长密度与邻域半径分别放大 1 000 倍且弧长密度为平均弧长)。




图 9 邻域半径与弧长密度的函数曲线

半径函数的计算公式如式(14)所示。

$$r(\bar{l}) = b_0 + b_1(\bar{l})^2 + \dots + b_n(\bar{l})^n \quad (14)$$

其中, b_0, b_1, \dots, b_n 为系数。

半径函数 $r(\bar{l})$ 客观上反映了邻域半径与弧长密度之间的规律。对于一对待配准的点云数据, 先计算该点云的弧长密度 \bar{l} , 将计算出的点云弧长密度 \bar{l} 代入半径函数 $r(\bar{l})$, 所求得的邻域半径即为自动鉴别出的邻域半径 r , 用于计算点云的 FPFH 特征及 SAC-IA。

1.5 自动邻域半径鉴别 FPFH 特征提取算法

将半径函数 $r(\bar{l})$ 与原始 FPFH 特征提取算法相结合构建自动邻域半径鉴别 FPFH 特征提取算法, 计算 FPFH 特征前需估算点云弧长密度 \bar{l} , 输入到函数 $r(\bar{l})$ 中得到邻域半径 r , 用于计算 FPFH 特征, 如图 1(b) 所示, 得到这些特征之间的对应关系, 从而完成初始配准, 使 2 个点云集获得一个较好的初始位置^[16], 以减少迭代次数和配准时间。该算法根据点云中点的分布疏密鉴别出与点云自身分布特性相匹配的邻域半径, 自动完成特征提取, 不需要人工参与设置邻域半径, 保证提取出的特征具有较高匹配质量的同时具有较快的计算速度。

2 实验结果与分析

为验证算法的有效性, 本文在 CPU 为 Intel(R) Core(TM) i5-3230@2.60 GHz、内存 4 GB 的 PC 上, 使用 VS 2015 基于 PCL V1.72 点云库开发实验程序, 测试数据为斯坦福大学的 Armadillo 点云数据。该点云使用激光扫描设备每间隔一定角度扫描模型制作, 部分点云数据展示如图 10 所示。为加速运算过程, 对点云进行下采样之后分别使用手动人工选择邻域半径与本文算法计算 FPFH 特征并完成 SAC-IA。




图10 点云数据展示

表1所示为人工选择邻域半径实验部分配准误差得分,其中,邻域半径每间隔0.005 m人工选取。表2所示为人工选择半径与本文算法的最小邻域半径、最大邻域半径、配准误差得分最小的2个半径所计算得到的FPFH特征对比结果,其中,“—”表示自动鉴别出的半径。图11所示为该组dragon点云配准视觉效果。

表1 人工选取半径的配准参数1

半径/m	配准误差得分	半径/m	配准误差得分
0.005	2.401 00e-04	0.055	2.368 88e-05
0.010	7.327 99e-05	0.060	2.293 99e-05
0.015	2.408 43e-05	0.065	2.221 04e-05
0.020	2.329 87e-05	0.070	2.198 02e-05
0.025	2.216 45e-05	0.075	2.561 98e-05
0.030	2.206 86e-05	0.080	2.503 19e-05
0.035	2.235 33e-05	0.085	2.685 14e-05
0.040	2.914 10e-05	0.090	2.289 67e-05
0.045	2.706 65e-05	0.095	2.469 72e-05
0.050	2.753 10e-05	0.100	2.665 54e-05

表2 人工选择半径与本文算法的性能对比1

算法	半径/m	配准误差得分	$T_{FPFH} + T_{SAC-IA}/s$
人工选择	0.005	2.401 00e-04	0.011 + 0.428
	0.030	2.206 86e-05	0.063 + 0.420
	0.070	2.198 02e-05	0.278 + 0.387
	0.100	2.665 54e-05	0.501 + 0.389
本文算法	—	2.102 15e-05	0.069 + 0.394




图11 dragon点云配准视觉效果1

从表1与表2可以看出,较小的邻域半径虽然能减少FPFH特征的提取时间,但是特征的性能较差;较大的邻域半径在一定程度上能增强特征的性能,但运算速度较慢。通过人工多次选择邻域半径的方法计算FPFH特征,虽然能找出较为合适的半径值,但是过程较复杂且效率较低。本文算法根据点云本身的弧长密度选择合适的半径计算FPFH特征,不仅增强了特征的性能(配准误差得分达到 $2.102 15e-05$),同时减少了特征计算的时间,仅为0.463 s。从图11可以看出,使用邻域半径计算的FPFH特征的配准效果较差,而在人工选择的邻域半径中, $r=0.030$ m与 $r=0.070$ m配准误差得分与本文算法的得分相当接近。此外,本文算法在耳朵与前爪部分配准效果较好。

为验证本文算法针对不同点云同样有效,选择另外一组dragon点云来进行实验,结果如表3和表4所示,其中,“—”表示自动鉴别出的半径。图12所示为此组dragon点云配准视觉效果。

表3 人工选取半径的配准参数2

半径/m	配准误差得分	半径/m	配准误差得分
0.005	1.387 47e-04	0.055	1.958 81e-05
0.010	4.285 99e-05	0.060	1.775 09e-05
0.015	1.994 85e-05	0.065	1.961 63e-05
0.020	1.645 21e-05	0.070	1.768 02e-05
0.025	1.751 05e-05	0.075	1.604 90e-05
0.030	1.723 95e-05	0.080	2.366 49e-05
0.035	1.907 37e-05	0.085	1.729 16e-05
0.040	1.668 03e-05	0.090	2.030 07e-05
0.045	1.623 25e-05	0.095	2.654 14e-05
0.050	1.727 39e-05	0.100	2.275 40e-05

表4 人工选择半径与本文算法的性能对比2

方法	半径 r/m	配准误差得分	$T_{FPFH} + T_{SAC-IA}/s$
人工选择	0.010	4.285 99e-05	0.050 + 0.506
	0.025	1.751 05e-05	0.285 + 0.471
	0.075	1.604 90e-05	1.420 + 0.497
	0.095	2.654 14e-05	2.026 + 0.484
本文算法	—	1.568 71e-05	0.266 + 0.480

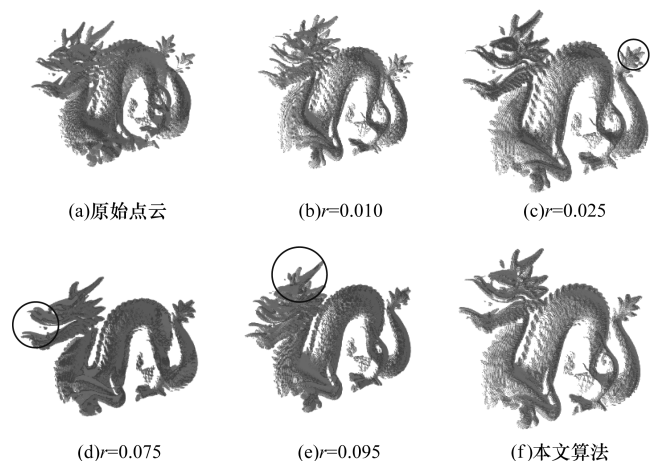


图12 dragon点云配准视觉效果2

从表3、表4和图12可以看出,本文提出的算法针对不同的点云同样有效,在人工选择的邻域半径中 $r=0.075\text{ m}$ 的配准误差与本文算法较为接近,且在嘴部效果更为突出,因此本文算法具有较好的实用性和有效性。

3 结束语

本文提出一种基于弧长密度的 FPFH 提取算法,根据点云的弧长密度,自动鉴别合适的邻域半径,以计算 FPFH 特征。实验结果表明,该算法的计算过程简单且效率较高。但是,本文算法在提取特征时速度较慢,解决该问题是下一步的研究方向。

参考文献

- [1] RUSU R B, MARTON Z C, BLODOW N, et al. Persistent point feature histograms for 3D point clouds [C]//Proceedings of IEEE/RSJ International Conference on Intelligent Robots and Systems. Washington D. C., USA: IEEE Press, 2008: 119-128.
- [2] RUSU R B, BLODOW N, MARTON Z C, et al. Aligning point cloud views using persistent feature histograms [C]//Proceedings of IEEE/RSJ International Conference on Intelligent Robots and Systems. Washington D. C., USA: IEEE Press, 2008: 3384-3391.
- [3] RUSU R B, MARTON Z C, BLODOW N, et al. Learning informative point classes for the acquisition of object model maps [C]//Proceedings of International Conference on Control, Automation, Robotics and Vision. Washington D. C., USA: IEEE Press, 2008: 643-650.
- [4] RUSU R B, BLODOW N, BEETZ M. Fast point feature histograms for 3D registration [C]//Proceedings of IEEE International Conference on Robotics and Automation. Washington D. C., USA: IEEE Press, 2009: 3212-3217.
- [5] ALI H, FIGUEROA N. Segmentation and pose estimation of planar metallic objects [C]//Proceedings of Conference on Computer and Robot Vision. Washington D. C., USA: IEEE Computer Society, 2012: 376-382.
- [6] WEBER T, HÄNSCH R, HELWICH O. Automatic registration of unordered point clouds acquired by Kinect sensors using an overlap heuristic [J]. ISPRS Journal of Photogrammetry and Remote Sensing, 2015, 102: 96-109.
- [7] SHEN Bowei, YIN Fang, CHOU Wusheng. A 3D modeling method of indoor objects using Kinect sensor [C]//Proceedings of International Symposium on Computational Intelligence and Design. Washington D. C., USA: IEEE Press, 2017: 64-68.
- [8] NASAB S E, KASAEI S, SANAEI E, et al. Multiview 3D reconstruction and human point cloud classification [C]//Proceedings of Conference on Electrical Engineering. Washington D. C., USA: IEEE Press, 2014: 1119-1124.
- [9] 朱俊锋, 胡翔云, 张祖勋, 等. 多尺度点云噪声检测的密度分析法 [J]. 测绘学报, 2015, 44(3): 282-291.
- [10] NURUNNABI A, WEST G, BELTON D. Outlier detection and robust normal-curvature estimation in mobile laser scanning 3D point cloud data [J]. Pattern Recognition, 2015, 48(4): 1404-1419.
- [11] ARUN K S, HUANG T S, BLOSTEIN S D. Least-squares fitting of two 3-D point sets [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 1987, 9(5): 698-700.
- [12] 陈学伟, 朱耀麟, 武桐, 等. 基于 SAC-IA 和改进 ICP 算法的点云配准技术 [J]. 西安工程大学学报, 2017, 31(3): 395-401.
- [13] 吕晓春, 顾汉明, 成景旺. 基于 Huber 函数的频率域全波形反演 [J]. 石油物探, 2013, 52(5): 544-552.
- [14] WAN Xiangkui, LI Yan, XIA Chong, et al. A T-wave alternans assessment method based on least squares curve fitting technique [J]. Measurement, 2016, 86: 93-100.
- [15] 张永涛, 贾延明. 最小二乘法中代数多项式曲线拟合的分析及实现 [J]. 计算机与数字工程, 2017, 45(4): 637-639, 654.
- [16] 姚晓山, 刘健鑫, 柯维. 多视点云拼接中的 ICP 算法优化 [J]. 微电子学与计算机, 2012, 29(8): 94-97.

编辑 赵辉