

基于 SHOT 的多尺度关键点检测技术研究

贾勇杰, 熊风光*, 韩燮, 况立群

中北大学计算机科学与技术学院, 山西 太原 030051

摘要 针对目前三维点云关键点检测方法检测的关键点的可描述性和再现性不强,且检测的关键点数量较少的问题,提出了一种新颖的关键点检测算法。首先为提高算法的效率,利用均匀采样方法减少三维点云中点的数量,降低三维点云的复杂度。然后利用具有良好描述性的方向直方图签名(SHOT)描述子对均匀采样的点进行多尺度描述,分析每个点多尺度 SHOT 描述子的独特性,选取 SHOT 描述子离散程度较大的点作为关键点。本文方法利用描述性较强的 SHOT 描述子对关键点的邻域进行描述,增强了关键点的可描述性。实验结果表明,本文方法的均匀采样时间效率高,满足关键点检测的时间要求,且本文检测关键点的方法比 Harris3D、尺度不变特征变换(SIFT)、内部形状签名(ISS)关键点检测算法具有更好的再现性。因此,本文方法可以有效、快速地在三维点云模型和场景中检测出高质量的关键点。

关键词 图像处理; 关键点; 多尺度; 描述子; 三维点云

中图分类号 TP242 **文献标识码** A

doi: 10.3788/LOP55.071013

Multi-Scale Keypoint Detection Based on SHOT

Jia Yongjie, Xiong Fengguang, Han Xie, Kuang Liqun

School of Data Science and Technology, North University of China, Taiyuan, Shanxi 030051, China

Abstract Aiming at the key point description and repeatability in the method of key point detection of three-dimensional (3D) point cloud is not strong, and the number of detected key points is small, we propose a novel algorithm of key point detection. Firstly, in order to improve the efficiency of the algorithm, the uniform sampling method is used to reduce the number of points in the 3D point cloud that can reduce the complexity of the 3D point cloud. Then, we use Signature of Histograms of Orientations (SHOT) descriptor to describe the points uniformly sampled in multi-scale, and analyze the uniqueness of the multi-scale SHOT descriptors at each point, and select the SHOT descriptor with larger discreteness of points as the key points. The proposed method uses the descriptive SHOT descriptor to describe the neighborhood of the key points, and enhances the descriptivity of the key points. The experimental results show that the uniform sampling is highly efficient in time and meets the time requirements of the keypoint detection. The proposed method has better reproducibility than Harris 3D, scale invariant feature transform (SIFT) and internal shape signature (ISS) key point detection algorithms in the key point detection. Therefore, the proposed method can detect high quality key points in the 3D point cloud model and scene effectively and quickly.

Key words image processing; key point; multi-scale; descriptor; three-dimensional point cloud

OCIS codes 100.6890; 110.2970

收稿日期: 2018-01-06; **收到修改稿日期:** 2018-02-05

基金项目: 国家自然科学基金(61672473, 61379080)、山西省回国留学人员科研项目(2015-079)

作者简介: 贾勇杰(1993—),男,硕士研究生,主要从事计算机视觉方面的研究。E-mail: 673121964@qq.com

导师简介: 韩燮(1964—),女,博士,教授,主要从事仿真与可视化、智能信息处理等方面的研究。

E-mail: haixie@nuc.edu.cn

* 通信联系人。E-mail: xfgncit98@sina.com

1 引言

视觉是人类观察世界和感知世界的重要手段, 如何使计算机获得与人类相近的视觉感知和认知能力是目前该领域的研究热点之一。物体的识别对许多计算机视觉研究来讲是一个具有挑战性的任务, 如机器人、无人车、自动化装配, 以及智能监控等。相较于二维(2D)图像, 三维(3D)点云在物体识别领域展现出一些优势: 提供了更多的几何(深度)信息; 从点云中提取的特征不受尺度、旋转和光照的影响; 在三维点云中估计物体的姿态比从 2D 图像中估计的姿态更加准确。针对现实生活中杂乱且遮挡严重的场景, 基于局部特征的 3D 对象识别系统通常由三个主要阶段组成^[1]: 关键点检测、局部表面特征描述和表面特征匹配。关键点检测是基于局部特征的 3D 对象识别^[2]系统的关键阶段, 提取关键点的好坏直接影响后续的局部表面特征描述和特征匹配^[3], 进而影响最终的物体识别效果。另外关键点检测也是当前计算机视觉应用的关键阶段, 例如表面配准^[4]、表面匹配、即时定位与地图构建(SLAM)和 3D 相机姿态估计等。本文针对关键点检测算法展开研究, 提出一种基于方向直方图签名(SHOT)的多尺度关键点检测算法。

2 相关工作

关键点要求具有可再现性和描述性的点。最简单的关键点检测方法是均匀采样和网格抽取^[5-6]。但是这些方法检测的关键点在可描述性方面是不合格的, 因为这些方法没有或很少考虑这些被提取的关键点邻域内的可描述性^[7]。因此有必要根据点邻域内的可描述性信息来检测关键点。

Yamany 等^[8]提出使用单一的角度检测关键点, 单一角度 ψ 与平均曲率 $\bar{\kappa}$ 有关。在单角满足约束条件 $|\sin \psi| \geq \tau$ 处检测关键点。阈值 τ 对于其关键点检测至关重要, 选择合适的阈值仍然是个未解决的问题。Matei 等^[9]提出使用相邻点的协方差矩阵的最小特征值 λ_1 来检测点 p 周围的表面变化, 根据其表面变化对点进行分类。Sipiran 等^[10]提出采用两个连续特征值的比例来修剪点。基于最小特征值 λ_1 , 保留满足约束条件 $\lambda_2/\lambda_1 < \tau_{21}$ 和 $\lambda_3/\lambda_2 < \tau_{32}$ 的点。Mian 等^[7]提出 Harris 3D 检测器, 给定点 p , 首先将相邻点转换为质心, 然后将点 p 处的法线旋转与 z 轴对齐。将这些变换点拟合成二次曲面, 用数学公式描述为: $f(u, v) = \mathbf{a}^T (u^2, uv, v^2, u, v,$

$1)$ 。使用该公式的导数定义对称矩阵 \mathbf{E} , 在点 p 处 Harris 3D 检测器计算值 $V(p) = \det(\mathbf{E}) - \alpha \times [\text{tr}(\mathbf{E})]^2$, 其中 $\det(\mathbf{E})$ 和 $\text{tr}(\mathbf{E})$ 分别表示矩阵 \mathbf{E} 的行列式和轨迹, α 是需要通过实验调整的参数。最后选择具有最大值 $V(P)$ 的固定百分比作为关键点。Flint 等^[11]将尺度不变特征变换(SIFT)算法应用在 3D 点云数据上, 使用 Hessian 矩阵的行列式在尺度空间上检测关键点。

上述方法需要预先确定一个检测关键点的尺度, 然后定义一个在预定的邻域内具有独特性的点作为关键点, 其有几个主要缺陷^[7]: 1) 可能检测到较少的关键点, 特别是在对象的相对平滑部分, 这将会影响物体的识别; 2) 预先确定的尺度需要根据经验确定, 未充分利用对象局部几何结构的编码尺度信息检测关键点的内在尺度。

综上所述, 本文提出了一种基于 SHOT 描述子的多尺度检测关键点方法。通过改变邻域大小建立多尺度空间, 获得特征点 p 在不同尺度空间下的 SHOT 描述子, 分析特征点 p 的 SHOT 描述子在每个尺度下的独特性, 定义在每个尺度下独特的点为关键点。本文方法降低了对尺度的要求, 充分利用特征点邻域内的几何信息, 且检测的关键点数量合理。实验表明, 本文方法检测的关键点对噪声稳健性具有良好的再现性, 对于物体识别局部表面的特征描述和特征匹配具有重要意义。

3 关键点的检测过程

关键点的检测过程主要分为三部分: 均匀采样、多尺度计算 SHOT 描述子和分析多尺度 SHOT 描述子检测关键点。均匀采样是设置点云模型的最小空间, 并对点云模型进行均匀划分, 在每个最小空间中选取一个点代表该空间, 得到一组点代表整个点云模型, 从而降低点云模型的复杂度, 减少点云模型中点的数量; 多尺度计算 SHOT 描述子是设置多个尺度的邻域, 对均匀采样获得的每个点计算其在多尺度下的 SHOT 描述子; 分析每个点的多尺度 SHOT 描述子与全部的 SHOT 描述子标准差之间的关系, 选取离散程度较大的特点作为关键点。

3.1 均匀采样

关键点检测算法需要计算点云模型中每个点, 在多尺度下采用 SHOT 描述子进行分析, 选取具有独特性的点作为关键点。通常点云中点的数量庞大, Kinect 或 Xtion 等传感器产生 307200 (640×480) 点云, 所以需要降低点云的复杂性, 减少点云中

点的数量。本文采用均匀采样的方式降低点云的复杂性。

对点云模型均匀采样的算法步骤如下。

1) 根据实验对不同的点云模型设置最小三维空间, 记为 $S = \{r, r, r\}$ 。

2) 通过搜索点云中的所有点, 获取点云中坐标最大点 $p_{\max} = \{x_{\max}, y_{\max}, z_{\max}\}$ 和坐标最小点 $p_{\min} = \{x_{\min}, y_{\min}, z_{\min}\}$ 。

3) 利用下式计算点云模型沿坐标系每个轴的空间分割数, 沿 x, y, z 分割的空间数分别记为 N_1, N_2, N_3 。

$$D = \left\{ \left\lfloor \frac{x_{\max}}{r} \right\rfloor - \left\lfloor \frac{x_{\min}}{r} + 1 \right\rfloor, \left\lfloor \frac{y_{\max}}{r} \right\rfloor - \left\lfloor \frac{y_{\min}}{r} + 1 \right\rfloor, \left\lfloor \frac{z_{\max}}{r} \right\rfloor - \left\lfloor \frac{z_{\min}}{r} + 1 \right\rfloor \right\} = \{N_1, N_2, N_3\}。 \quad (1)$$

4) 遍历点云模型中的每个点, 其坐标记为 $p = \{x, y, z\}$, 利用下式计算每个点所属的空间索引, 记为 $\{n_i, n_j, n_k\}$ 。

$$I = \left\{ \left\lfloor \frac{x}{r} \right\rfloor, \left\lfloor \frac{y}{r} \right\rfloor, \left\lfloor \frac{z}{r} \right\rfloor \right\} = \{n_i, n_j, n_k\}。 \quad (2)$$

5) 计算点云模型的每个空间中各个点与空间中心的距离 l , 保留 l 为最小值的点, 即保留离空间的中心最近的点来代表该空间, 且保留该点在点云模型中的索引。最终完成对点云模型的均匀采样, 得到一组点记为 $P = \{p_1, p_2, \dots, p_n\}$ 代表点云模型, n 表示均匀采样后剩余的点的数量。

对于不同的点云模型, 其点云密度不尽相同, 通过改变点云模型的最小空间 S , 即改变参数 r , 从而获得理想点云数量。

3.2 多尺度计算 SHOT 描述子

Tombari 等^[12]提出了一种对基于一阶微分实体的直方图进行编码的 3D 描述符(即邻域内点的法线), 与平面 3D 坐标相比, 其更能代表表面的局部结构, 且直方图的使用实现了噪声稳健性所需要的滤波效果。同时 Tombari 等^[12]提出了一个强大的、稳健的 3D 局部坐标系(LRF), 可以通过引入关键点邻域内位置的几何信息, 从而模仿一个点签名来增强描述符的辨别能力。描述符的计算是在关键点处建立一个 LRF, 在其邻域内计算一组邻域点法向量的局部直方图, 将计算出的直方图累加在一起以形成最终的描述符。这种将直方图和点签名两种方法相结合的方法, 称为 SHOT。

多尺度计算 SHOT 描述子, 需要根据实验条件改变尺度参数 r , 建立不同尺度的邻域半径 $R =$

$\{r_1, r_2, \dots, r_l\}$, 其中 l 表示多尺度邻域的尺度数量。对于每一个尺度半径 r_i , 其 SHOT 描述子的计算过程如下。

1) 建立局部坐标系。通过特征点 p 和用于计算特征点 p 描述符的球面内(计算描述子的尺度半径 r)的所有点 p_i 建立协方差矩阵 M , 为提高效率用特征点 p 代替质心, 将 M 计算为加权线性组合:

$$M = \frac{1}{\sum_{i: d_i \leq R} (R - d_i)} \cdot \sum_{i: d_i \leq R} (R - d_i) (p_i - p) (p_i - p)^T, \quad (3)$$

式中 p_i 为特征点 p 邻域内的点, $d_i = \|p_i - p\|_2$ 。对 M 进行特征值分解, 得出三个特征向量 v_0, v_1, v_2 。为了产生可重复的 LRF, 需要消除符号歧义。每个特征向量应该指向散布向量的主要方向(即从特征点开始指向位于邻域内点的方向)。因此通过特征向量和散布向量内积的符号来确定每个特征向量的符号, 按特征值降低的顺序分别表示为 x, y, z , 通过下式确定 \tilde{x} 的符号, 表示 x 轴。

$$\tilde{x} = x \cdot \text{sign}(h), \quad (4)$$

$$h = \sum_{i: d_i \leq R} (p_i - p) \cdot x, \quad (5)$$

式中符号 \cdot 为数乘, 函数 $\text{sign}(h)$ 为符号提取函数, 提取 h 的符号。同理 z 轴可以通过下式确定 \tilde{z} 的符号, 最后通过 $\tilde{y} = \tilde{x} \times \tilde{z}$ 得到 y 轴, 其中 \times 表示向量叉乘。

$$\tilde{z} = z \cdot \text{sign} \left[\sum_{i: d_i \leq R} (p_i - p) \cdot z \right]。 \quad (6)$$

2) 特征点邻域的空间划分。对于点签名结构对特征点 p 的邻域空间进行划分, 沿方位划分为 8 份, 沿高度划分为 2 份, 沿半径划分为 2 份, 邻域空间总共划分为 32 份。

3) 计算局部直方图。计算特征点邻域划分后的每个子空间局部直方图。对于子空间中的每个点 p_i , 根据计算其法线 n_{vi} 与特征点处的法线 n_u (即局部坐标系 LRF 的 z 轴) 的角度 θ_i 的函数值, 将其累计到直方图不同的盒子中。定义角度 θ_i 的函数为 $\cos \theta_i = n_u \cdot n_{vi}$ 。对于每个子空间将 $\cos \theta_i$ 的值划分为 11 份, SHOT 描述子的维度为 $32 \times 11 = 352$ 。

4) 四线性插值。由于 SHOT 描述子是基于局部直方图, 所以需要避免边界效应。此外 SHOT 描述子对邻域空间进行细分, 且存在局部坐标系的干扰也可能出现边界效应。对于每个点被累计到特定的直方图盒子, 需要对其相邻的盒子执行四线性插值, 分别为余弦差值、方位角差值、高度差值, 以及距离差值。每个计数乘以每个维度的权重 $1-d$ 。

计算点云模型均匀采样获得的点集 $P = \{p_1, p_2, \dots, p_n\}$ 中的每个点 p_i 在多尺度邻域半径 $R = \{r_1, r_2, \dots, r_l\}$ 下的 SHOT 描述子, 得到点 p_i 一组 SHOT 描述子集合 $D_{p_i} = \{d_{p_i,1}, d_{p_i,2}, \dots, d_{p_i,l}\}$, l 为多尺度邻域的尺度数量, 每个点 p_i 获得 l 个 SHOT 描述子集合, 总共获得 $n \times l$ 个 SHOT 描述子。多尺度计算 SHOT 描述子的时间复杂度由两部分组成: 建立局部坐标系的时间复杂度和多尺度计算 SHOT 描述子的时间复杂度, 两者时间复杂度分别为: $O(k \times n)$ 和 $O(l \times k \times n)$, 其中 k 为邻域内点的数量, l 为多尺度的尺度数, n 为均匀采样后点的数量。

3.3 多尺度检测关键点

SHOT 描述子引入了一个强大的、稳健的 LRF, 且直方图的使用实现了噪声稳健性所需要的滤波效果, SHOT 描述子对噪声具有非常好的稳健性^[12]。本文方法利用具有良好描述性的 SHOT 描述子对均匀采样后的点集 P 进行多尺度描述, 增强了关键点的描述性, 通过每个点 p_i 的 SHOT 描述子与 SHOT 描述子集合 D_{p_i} 质心的欧氏距离与标准差之间的关系, 分析点 p_i 在多尺度下的离散程度。定义 SHOT 描述子在多尺度下离散程度较大的点为独特的点, 即定义 SHOT 描述子离散程度较大的点为关键点。因为 SHOT 描述子对噪声具有良好的稳健性, 且选取独特的点为关键点, 从而提高了关键点的再现性。关键点的离散程度的阈值 ϵ 影响关键点的独特性和数量, 通过实验获得最佳的阈值 ϵ , 从而达到在提高关键点再现性的同时得到较多的关键点。

对均匀采样和多尺度计算 SHOT 描述子获得的点集 $P = \{p_1, p_2, \dots, p_n\}$ 和每个点 p_i 的一组多尺度 SHOT 描述子集合 $D_{p_i} = \{d_{p_i,1}, d_{p_i,2}, \dots, d_{p_i,l}\}$ 进行分析检测关键点, 具体的算法步骤如下。

1) 计算点集 p 的所有 SHOT 描述子的平均值, 记为 μ 。

$$\mu = \left[\sum_{i=1}^n \left(\sum_{k=1}^l d_{p_i,k} \right) \right] / (n \times l). \quad (7)$$

2) 对于每个点 p_i , 利用欧氏距离比较其在每个尺度的邻域半径 r_k 下的 SHOT 描述子 $d_{p_i,k}$ 与 SHOT 描述子的平均值 μ 的差值, 记为 $\sigma_{ik} = (d_{p_i,k} - \mu)$ 。

3) 计算 SHOT 描述子集合的标准差, 记为 σ 。

$$\sigma = \sqrt{\left[\sum_{i=1}^n \sum_{k=1}^l (\sigma_{ik})^2 \right] / (n \times l)}. \quad (8)$$

4) 标准差 σ 反映了 SHOT 描述子集合的离散程度。因此满足下式的点为邻域 r_k 内独特的点, 记为 $f(p_{ik}) = 1$, 否则 $f(p_{ik}) = 0$ 。

$$\sigma_{ik} > \epsilon \cdot \sigma, \quad (9)$$

式中 ϵ 为设定离散程度的阈值。

5) 对于每个点 p_i 都进行第 4) 步的计算, 选择多尺度邻域集合 $R = \{r_1, r_2, \dots, r_l\}$ 下满足 $F(p_i) = 1$ 的独特的点。

$$F(p_i) = f(p_{i1}) \cap f(p_{i2}) \cap \dots \cap f(p_{il}), \quad (10)$$

(10) 式为选择在每个邻域 r_k 下满足 (9) 式的点为关键点。从而得到一组关键点 $P = \{p_1, p_2, \dots, p_m\}$, m 为关键点的数量。

多尺度检测关键点的时间复杂度为 $O(l \times n)$, 其中 l 为多尺度的尺度数, n 为均匀采样后点的数量, 本文 l 的值为 3。

4 实验结果及分析

本文共设计两个实验: 实验一对三维点云模型进行均匀采样; 实验二对本文检测关键点的方法与 Harris3D、SIFT、内部形状签名 (ISS) 关键点检测方法在抗噪性、关键点的数量、时间效率方面进行对比分析。采用三种不同的实验数据集进行关键点检测实验来验证本文算法是否能提取出有效的关键点。数据集分别为: 1) 斯坦福大学的标准三维模型数据库^[13]; 2) 西澳大学 (UWA) 三维模型数据集^[7]; 3) Salti 等^[14]用于实验验证的数据集中的场景模型。数据集 3) 可以通过 SHOT 网站获得。实验中对三个数据集中的三维点云模型分别添加方差为 0.1、0.2、0.3 倍面片分辨率 (单位为 mr) 的高斯噪声。图 1 给出了本文实验使用的各个数据集原始三维点云模型的图例, 其中场景模型 scene1、scene2、scene3 分别对应数据集 3) 模型库中的 scene1、scene18 和 scene34。

本文关键点检测方法采用 VS2013 平台 + PCL1.8, 开发语言为 C++, 且 Harris3D、SIFT、ISS 关键点检测方法采用点云库 (PCL) 的开源代码。实验的软硬件环境为: 64 位 Windows 7 操作系统, Intel i5 3.20 GHz CPU, 8 G 内存。

4.1 均匀采样实验结果及分析

针对三个数据集中的点云模型, 采用均匀采样的方式降低点云的复杂性。具体的均匀采样实验方

案如下:对于数据集 1)中的模型 bunny、armadillo、dragon,均匀采样的尺度 r 分别为 3, 5, 7 mr;对于数据集 2)中的模型 chef、chicken、parasaurolophus,均匀采样的尺度 r 均为 5 mr;对于数据集 3)中的场景模型 scene1、scene18、scene34,均匀采样的尺度 r 均为 3 mr。表 1 所示为每个点云模型的原始点数量、均匀采样的点数量、均匀采样比率(均匀采样的点数量/原始点数量)、均匀采样耗时,以及均匀采样效率(均匀采样耗时/原始点数)。

对三维点云进行均匀采样,不能损失模型的主要点。对于点数较少、面片分辨率较大的模型,设置较低倍数的面片分辨率为采样尺度,例如 bunny 的点数较少、面片分辨率较大,设置采样尺度 $r =$

3 mr,达到降低模型复杂度的目的,且均匀采样的点数不会太少,并保留了模型的主要点。对于点数较多、面片分辨率较小的模型,设置倍数较高的面片分辨率为采样尺度,例如 dragon 的点数较多、面片分辨率较小,设置采样尺度 $r = 7$ mr,达到降低模型复杂度的目的。对于场景模型,由于场景中每个模型的面片分辨率大小不尽相同,应尽量设置较低倍数的面片分辨率为采样尺度,例如场景模型 scene1、scene2、scene3 均设置采样尺度 $r = 3$ mr。由表 1 通过计算可知,平均均匀采样的时间为 0.0024 ms,即 10000 点规模的点云均匀采样仅需 24 ms,其能够满足检测关键点对时间的需求。




图 1 本文使用的 3D 点云图例

Fig. 1 Examples 3D point cloud used in this paper

表 1 3D 点云均匀采样的点信息和均匀采样的时间

Table 1 3D point cloud uniform sampling point information and the time of uniform sampling

Point cloud	Number of original points	Number of uniform sampling points	Rate of uniform sampling points / %	Time of uniform sampling / ms	Efficiency of uniform sampling / ms
Bunny	35947	7778	21.63	83	0.0023
Armadillo	172974	12348	7.14	202	0.0012
Dragon	437645	40409	9.23	1185	0.0027
Chef	176920	12176	6.88	327	0.0018
Chicken	135142	9573	7.08	183	0.0014
Parasaurolophus	184933	13987	7.56	218	0.0012
Scene1	167414	40145	23.98	592	0.0035
Scene2	202248	47897	23.68	1076	0.0053
Scene3	234564	55670	23.73	577	0.0025

4.2 检测关键点实验结果及分析

为验证本文算法的有效性,与 Harris3D、SIFT、ISS 关键点检测方法在抗噪性、关键点的数量、时间

效率方面进行对比分析。其中抗噪性分析为点云模型添加噪声后关键点的可再现分析,例如三维点云模型 M 中的一个关键点 p_i ,在给模型 M 添加了方

差为 0.1 mr 高斯噪声后检测的关键点中查找最近点 $p_{j_{0.1}}$ 。如果 p_i 与 $p_{j_{0.1}}$ 的欧氏距离满足 $\|p_i - p_{j_{0.1}}\|_2 < \delta$, 则认为关键点 p_i 是可再现的, 其中 δ 为可再现的阈值。再现性是关键点最重要的特征^[15], 其体现了关键点检测算法在一个给定噪声的场景点云与相应的模型点云中找到相同关键点

的能力。关键点检测算法的具体实验方案: 均匀采样的参数见均匀采样实验, 多尺度邻域半径 $R = \{15 \text{ mr}, 16 \text{ mr}, 17 \text{ mr}\}$, 共 3 个尺度, 点云的法向量是基于最近的 40 个点获得, (9) 式离散程度的阈值 ϵ 设为 1, 本文实验进行 $\delta = 1 \text{ mr}$ 和 $\delta = 2 \text{ mr}$ 两次实验。




图 2 检测关键点的结果

Fig. 2 Detecting results of key points

表 2 检测 3D 点云的关键点数量和消耗的时间

Table 2 Number of key points in the 3D point cloud and the time consumed

Point cloud	Number of original points	Number of proposed detecting key points	Number of Harris3D detecting key points	Number of SIFT detecting key points	Number of ISS detecting key points	Time of proposed detecting key points / ms	Time of Harris3D detecting key points / ms	Time of SIFT detecting key points / ms	Time of ISS detecting key points / ms
Bunny	35947	3384	664	108	479	12127	3279	1079	1934
Armadillo	172974	5896	983	150	2299	29005	41815	4718	12945
Dragon	437645	19486	3300	265	12012	73260	85938	9030	35215
Chef	176920	4362	569	29	1422	25049	45310	3233	16569
Chicken	135142	3331	556	139	1333	20591	35569	3389	28615
Parasaurulophus	184933	4945	1004	171	2466	29270	44330	4466	21497
Scenel	167414	18311	3553	1103	2326	92480	45798	9160	22704
Scene2	202248	18886	4274	1139	2845	98087	61916	15102	29471
Scene3	234564	24485	4934	1372	3274	142315	95050	18434	67658

图 2 所示为利用本文方法对原始的三个点云模型检测关键点的结果, 灰色的点为点云模型原始点, 红色的点为检测的关键点, 其中 'armadillo' 是针对 'armadillo' 进行关键点检测后的结果, 其他图与之类似。表 2 所示为每个点云模型原始点数量, 以及在本文方法和 Harris3D、SIFT、ISS 4 种关键点检测方法下检测的关键点数量和检测关键点的耗时。图 3 所示为三个数据集在添加不同噪声后, 本文方法与 Harris3D、SIFT、ISS 关键点检测方法的抗噪性分析结果。图 3 中实线表示可再现性阈值 $\delta = 1 \text{ mr}$, 虚线表示可再现性阈值 $\delta = 2 \text{ mr}$, 折线图的纵轴表示该数据集中点云模型的关键点再现率的均值, 横轴表示添加噪声的方差, 图 3(a) 折线图表示斯坦福大学模型库中 bunny、armadillo、dragon 三个点云模

型, 利用本文方法和 Harris3D、SIFT、ISS 在可再现性阈值 $\delta = 1 \text{ mr}$ 和 $\delta = 2 \text{ mr}$ 下可再现关键点比例的均值, 图 3(b)、(c) 均与之类似。

由图 3 可知, 通过多个模型库中的点云模型利用本文方法检测的关键点相比 Harris3D、SIFT、ISS 关键点检测方法在不添加噪声和添加 0.1, 0.2, 0.3 mr 的高斯噪声后, 在可再现性阈值为 $\delta = 1 \text{ mr}$ 和 $\delta = 2 \text{ mr}$ 的情况下均具有良好的抗噪性。同时从表 2 可以看出, 本文方法可以检测出较多的关键点数量, 这是因为本文关键点检测利用的 SHOT 描述子对噪声具有良好的稳健性, 且对点云中的点进行多尺度描述, 分析选择点的描述子在多尺度下独特的点作为关键点, 设置合理的离散程度阈值 ϵ 以提高关键点的再现性, 同时保证了关键点的数量。本

文方法对于点云模型 armadillo、dragon、chef、chicken、parasaurolophus 的耗时小于 Harris3D 方法,大于 SIFT、ISS 方法,对于点云模型 bunny 和点云场景 scenel、scene2、scene3,本文方法次于 Harris3D、SIFT、ISS 方法。这是因为点云模型 bunny 和点云场景 scenel、scene2、scene3 均匀采样的尺度相对较小,需要进行 SHOT 描述子多尺度分

析的点数较多,导致消耗的时间较多。但是本文方法很大程度上提高了关键点的再现性,且在基于局部特征的 3D 对象识别系统中进行关键点检测后需要对关键点进行特征描述^[16],本文方法在关键点检测阶段同时完成了对关键点的特征描述,节省了对关键点特征描述时间,满足基于局部特征的 3D 对象识别的时间要求。




图 3 抗噪性分析结果。(a) UWA 模型库;(b)斯坦福大学模型库;(c) SHOT 网站的点云模型

Fig. 3 Anti-noise analysis results. (a) UWA model library; (b) Stanford University model library; (c) point cloud model of SHOT website

本文提出的基于 SHOT 描述子多尺度分析检测的关键点的算法,不仅具有良好的抗噪性,而且有效的改善了检测关键点获取数量较少的问题和缩减了检测关键点对于不同的点云模型寻找最佳固定尺度繁琐、耗时的过程。

5 结 论

提出了一种基于 SHOT 描述子多尺度分析检测关键点的方法。利用均匀采样降低点云模型复杂度,通过 SHOT 描述子较强的描述性,进行 SHOT 描述子多尺度描述和分析,提取描述子离散程度较大的点作为关键点。相较于 Harris3D、SIFT、ISS 关键点检测方法,本文方法具有更好的抗噪性,且降低了不同点云模型对关键点检测的尺度半径的设置要求。目前利用 SHOT 描述子进行多尺度描述和分析在时间效率方面并不理想,这也是下一步的改进方向。

参 考 文 献

[1] Guo Y L, Bennamoun M, Sohel F, *et al.* 3D object recognition in cluttered scenes with local surface features: a survey[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2014, 36(11): 2270-2287.

[2] Shu C X, He Y T, Sun Q K. Point cloud registration based on convolutional neural network[J]. Laser & Optoelectronics Progress, 2017, 54(3): 031001.

舒程珣, 何云涛, 孙庆科. 基于卷积神经网络的点云配准方法[J]. 激光与光电子学进展, 2017, 54(3): 031011.

- [3] Xiong F G, Huo W, Han X, *et al.* Study on removal of mismatching keypoints in 3D point cloud[J]. Acta Optica Sinica, 2018, 38(2): 0210003.
- 熊风光, 霍旺, 韩燮, 等. 三维点云中关键点误匹配剔除方法研究[J]. 光学学报, 2018, 38(2): 0210003.
- [4] Zhang Q S, Zhou Y, Hu X M, *et al.* Hand vein recognition based on three dimensional point clouds matching[J]. Acta Optica Sinica, 2015, 35(1): 0115005.
- 张祺深, 周雅, 胡晓明, 等. 基于三维点云匹配的手掌静脉识别[J]. 光学学报, 2015, 35(1): 0115005.
- [5] Frome A, Huber D, Kolluri R, *et al.* Recognizing objects in range data using regional point descriptors [C] // Proceedings of European Conference on Computer Vision, 2004: 224-237.
- [6] Mian A S, Bennamoun M, Owens R. Three-dimensional model-based object recognition and segmentation in cluttered scenes [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2006, 28(10): 1584-1601.
- [7] Mian A, Bennamoun M, Owens R. On the repeatability and quality of keypoints for local feature-based 3D object retrieval from cluttered scenes[J]. International Journal of Computer Vision, 2010, 89(2/3): 348-361.

- [8] Yamany S M, Farag A A. Surface signatures: an orientation independent free-form surface representation scheme for the purpose of objects registration and matching[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2002, 24 (8): 1105-1120.
- [9] Matei B, Shan Y, Sawhney H S, *et al.* Rapid object indexing using locality sensitive hashing and joint 3D-signature space estimation[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2006, 28 (7): 1111-1126.
- [10] Sipiran I, Bustos B. Harris 3D: a robust extension of the Harris operator for interest point detection on 3D meshes[J]. The Visual Computer, 2011, 27: 963.
- [11] Flint A, Dick A, van den Hengel A. Thrift: local 3D structure recognition[C]//Proceedings of 9th Biennial Conference of the Australian Pattern Recognition Society on Digital Image Computing Techniques and Applications, 2007: 182-188.
- [12] Tombari F, Salti S, Stefano L D. Unique signatures of histograms for local surface description [C] // Proceedings of European Conference on Computer Vision, 2010: 356-369.
- [13] Curless B, Levoy M. A volumetric method for building complex models from range images [C] // Proceedings of the 23rd Annual Conference on Computer Graphics and Interactive Techniques, 1996: 303-312.
- [14] Salti S, Tombari F, Stefano L D. A performance evaluation of 3D keypoint detectors[C]//Proceedings of International Conference on 3D Imaging, Modeling, Processing, Visualization and Transmission, 2011: 236-243
- [15] Tombari F, Salti S, Stefano L D. Performance evaluation of 3D keypoint detectors[J]. International Journal of Computer Vision, 2013, 102(1/2/3): 198-220.
- [16] Xiong F G, Han X. A 3D surface matching method using keypoint-based covariance matrix descriptors [J]. IEEE Access, 2017, 5: 14204-14220.