

基于分层墨卡托投影的激光雷达点云数据局部特征描述

顾尚泰^{1*}, 王玲^{1**}, 马燕新², 马超¹

¹ 中国人民解放军国防科技大学电子科学学院, 湖南 长沙 410073;

² 中国人民解放军国防科技大学气象海洋学院, 湖南 长沙 410073

摘要 为了高效提取激光雷达点云数据的局部几何结构特征, 实现三维(3D)目标的配准、检测和识别, 提出了一种基于分层墨卡托投影(HMec)的局部点云特征描述子。首先, 采用传统方法进行特征提取; 然后, 利用具有保角特性的墨卡托投影, 将3D点云数据的局部邻域点分层投影到多个墨卡托平面上; 最后, 分别统计各墨卡托平面的分布直方图, 得到特征点的局部特征描述子。HMec特征描述子能很好地保留点云的局部几何结构特征, 从而提高特征描述子的辨别力。在Bologna和3DMatch数据集上的测试结果表明, 相比其他9种局部特征描述子, HMec特征描述子的辨别力更强、噪声鲁棒性更好。

关键词 激光雷达; 点云; 三维数据; 局部特征; 墨卡托投影; 分层投影

中图分类号 TN249

文献标志码 A

doi: 10.3788/AOS202040.2015001

Local Feature Description of LiDAR Point Cloud Data Based on Hierarchical Mercator Projection

Gu Shangtai^{1*}, Wang ling^{1**}, Ma Yanxin², Ma Chao¹

¹ College of Electronic Science, National University of Defense Technology, PLA, Changsha, Hunan 410073, China;

² College of Meteorology and Oceanography, National University of Defense Technology, PLA, Changsha, Hunan 410073, China

Abstract In order to efficiently extract the local geometric structure features of LiDAR point cloud data and realize the registration, detection and recognition of three-dimensional (3D) targets, a local point cloud feature descriptor based on hierarchical Mercator projection (HMec) is proposed in this paper. First, the traditional method is used for feature extraction. Then, the local neighborhood points of 3D point cloud data are projected onto multiple Mercator planes using the Mercator projection with conformal feature. Finally, the local feature descriptors of feature points are obtained by counting the histogram of each Mercator plane. HMec feature descriptor can retain the local geometric structure features of point cloud, so as to improve the discrimination of feature descriptor. The test results on Bologna and 3DMatch datasets show that HMec feature descriptors have stronger discrimination and better noise robustness than the other nine local feature descriptors

Key words LiDAR; point clouds; three-dimensional data; local feature; Mercator projection; hierarchical projection

OCIS codes 280.3640; 150.0155; 150.6910

1 引 言

激光雷达通过采集反射点的距离获取三维(3D)目标的表面形状、邻域、结构等信息, 利用激光雷达点云数据进行目标检测、识别、匹配的关键是提取点云的特征描述。对点云的特征描述可以分为全

局特征描述和局部特征描述两类, 全局特征描述是用一组特征向量描述整体点云的几何特性^[1-3]; 局部特征描述则是通过一组向量对关键点周围的邻域关系、结构信息^[3]、统计信息^[4]进行特征描述。相比全局特征描述, 点云的局部特征描述不需要将目标点云从场景中分割出来, 对杂乱和被遮挡的点云数据

收稿日期: 2020-05-13; 修回日期: 2020-06-13; 录用日期: 2020-07-06

* E-mail: shangtai_gu@163.com; ** E-mail: wanglanne@139.com

鲁棒性更好,得到了广泛应用。

局部特征描述的优劣取决于局部特征描述子的选取,现有的局部特征描述子可分为手工提取的特征描述子和基于学习的特征描述子。基于学习的特征描述子,通过海量点云数据和标签对神经网络的权值进行训练。Simo-Serra 等^[8]提出了基于多个视角图像训练网络的方法,但由于三维模型的视角太多,网络不能获得所有视角下的方位信息。Charles 等^[9-10]提出的 PointNet 和 PointNet++ 直接将点云作为神经网络的输入。随后人们提出的 3DMatch^[11]、紧凑几何特征(CGF)^[12]、FoldNet^[13]、和 3Dfeat-Net^[14]等都借助 PointNet^[9]模块,直接将点云作为数据输入,从而实现特征提取、模型匹配、目标检测与识别等工作,但这些基于神经网络提取的特征也存在不足,如特征向量的可解释性不强、关键点周围的邻域结构信息和邻域点内部的相关性被破坏、需要大量有标签的训练样本。

手工特征描述子通过提取局部点云的几何结构特征完成特征描述,如 Spin image^[3]、点特征直方图(PFH)^[2]、旋转投影统计量描述子^[4]以及局部特征统计直方图^[13]。无论是点云的体素化方法还是局部坐标投影方法,都会使局部点的相对关系和结构信息发生畸变。因此,本文提出了一种基于分层墨卡托投影的局部点云特征描述子,可在有效提取邻域局部结构信息的同时,将特征点附近的相对几何关系较小失真地投影到墨卡托特征平面上,以获得特征点附近的结构信息。

2 分层墨卡托投影方法

通常采用体素栅格化或多视角平面投影的方式^[4]提取激光雷达的点云数据局部特征,但这些方法会损失邻近点之间的相对关系和结构信息。墨卡托投影方法是一种等角正轴圆柱形投影,该方法假设地球被一个中空的圆柱包裹,且圆柱与地球赤道相切。在地球中心放置一个无向光源,可将地球上的任意位置投影到圆柱体上,形成一个圆柱体表面空间,再将该表面展开成二维平面坐标系。该方法通过坐标变换实现三维坐标向二维坐标的转换,能保证点与点之间的角度关系。

2.1 墨卡托投影

墨卡托投影只对球内和球表面各点对于球心的经纬度进行投影,损失了径向距离信息,墨卡托投影的正解可表示为

$$\begin{aligned} X_M &= K \ln \left[\tan \left(\frac{\phi}{2} + \frac{\pi}{4} \right) \cdot \left(\frac{1 - e \sin \phi}{1 + e \sin \phi} \right)^{\frac{e}{2}} \right] \\ Y_M &= K (\lambda - \lambda_0) \\ K &= \frac{a^2/b}{\sqrt{1 + e^2 \cos^2 \phi_0}} \cdot \cos \phi_0 \end{aligned} \quad (1)$$

式中, a 为椭圆长轴, b 为椭圆短轴, e 为椭圆离心率, ϕ_0 为初始纬度, λ_0 为初始经度, ϕ 为纬度, λ 为经度, X_M 、 Y_M 为球经过墨卡托投影后的横、纵坐标, K 为卯酉圈曲率半径。

若将待投影面看作标准的球面,即 $a = b = 1$, $e = 0$, $\phi_0 = \lambda_0 = 0$,则墨卡托平面坐标与标准球内点的经纬度关系可表示为

$$\begin{aligned} X_M &= \lambda \\ Y_M &= \ln \left[\tan \left(\frac{\phi}{2} + \frac{\pi}{4} \right) \right] \end{aligned} \quad (2)$$

2.2 局部参考坐标系

局部参考坐标系位于三维表面,且独立于三维视觉中的原始坐标系,广泛应用于三维局部特征的描述,可得到旋转不变的三维空间信息。性能好的局部参考坐标必须具备的两个性质:1) 基于该局部参考坐标下的特征描述具有刚体旋转不变性,即该局部参考坐标系独立于全局坐标系;2) 在支撑域内能保证空间关系和几何信息无损失。实验使用文献^[16]提出的局部参考系构建方法,通过分解 K 近邻的相对距离互相关矩阵 \mathbf{M} 的特征值,对局部法向量进行总体最小二乘(TLS)估计, \mathbf{M} 可表示为

$$\mathbf{M} = \frac{1}{k} \sum_{i=0}^k (\mathbf{p}_i - \hat{\mathbf{p}})(\mathbf{p}_i - \hat{\mathbf{p}})^T, \hat{\mathbf{p}} = \frac{1}{k} \sum_{i=0}^k \mathbf{p}_i, \quad (3)$$

式中, k 为邻域点的个数, \mathbf{p}_i 为第 i 个邻域点的位置, $\hat{\mathbf{p}}$ 为所有邻域点的坐标均值。可以发现,法向量是 \mathbf{M} 最小特征值对应的特征向量,且法向量的符号是在保证全局法向量相容性的条件下进行选择。为了在局部参考系中反映出邻域点的距离关系,对各点进行加权,可表示为

$$\mathbf{M}' = \frac{1}{\sum_{i:d_i \leq R} (R - d_i)} \sum_{i:d_i \leq R} (R - d_i)(\mathbf{p}_i - \mathbf{p})(\mathbf{p}_i - \mathbf{p})^T, \quad (4)$$

式中, \mathbf{p} 为特征点坐标, R 为局部邻域半径, $d_i = \|\mathbf{p}_i - \mathbf{p}\|^2$ 为任意邻域范围内点到特征点的欧氏距离。已有研究表明,尽管 \mathbf{M}' 的第三个特征向量不表示局部向量,但三维表面描述的优劣程度取决于局部参考系较高的可重复性和正交坐标的鲁棒性。

特征向量法虽然能解决局部参考坐标的尺度问

题,但其符号的可重复性仍需要进一步讨论。为了消除符号模糊,实现局部参考坐标的可重复性,通过对比 x 轴和 z 轴上的两个统计量定义,得到去模糊的 x 轴为

$$\begin{aligned} S_x^+ &\doteq \{i:d_i \leq R \wedge (\mathbf{p}_i - \mathbf{p}) \cdot \mathbf{x}^+ \geq 0\} \\ S_x^- &\doteq \{i:d_i \leq R \wedge (\mathbf{p}_i - \mathbf{p}) \cdot \mathbf{x}^- > 0\}, \quad (5) \\ x &= \begin{cases} x^+, & |S_x^+| \geq |S_x^-| \\ x^-, & \text{otherwise} \end{cases} \end{aligned}$$

式中, x^+ 为特征值分解得到的正向特征向量坐标, \wedge 为并逻辑运算, x^- 为其对应的相反向量坐标, S_x^+ 、 S_x^- 分别为邻域内与 x^+ 、 x^- 同向相对位置的点个数。若邻域范围内与 x^+ 同向的点较多,则局部参考坐标就是最小特征值对应的特征向量;若邻域范围内与 x^- 同向的点较多,则将最小特征值对应的特征向量翻转后作为该特征点的局部参考坐标。

2.3 分层墨卡托投影

由(2)式可知,传统的墨卡托投影将邻域内的点根据其经纬度投影到同一墨卡托平面上,但忽略了邻域内各点与特征点之间的径向结构关系。投影后得到的是经纬度相近但径向距离差较大的关键点,直接对特征点邻域进行墨卡托投影难以区分这两个关键点,因此需按照相对径向距离进行分层墨卡托投影,如图1所示。




图1 分层墨卡托投影示意图

Fig. 1 Schematic diagram of hierarchical Mercator projection

可将(2)式重新定义为

$$\begin{aligned} X'_M &= \lambda \cdot r \\ Y'_M &= \ln \left[\tan \left(\frac{\phi}{2} + \frac{\pi}{4} \right) \right] \cdot r, \quad (6) \end{aligned}$$

式中, r 为邻域内某点与特征点的径向距离。第 i 个邻域点的墨卡托坐标 $(X_{M,i}^n, Y_{M,i}^n)$ 可表示为

$$\begin{cases} X_{M,i}^n = \lambda_i \cdot \frac{n \cdot R_0}{N} \\ Y_{M,i}^n = \ln \left[\tan \left(\frac{\phi_i}{2} + \frac{\pi}{4} \right) \right] \cdot \frac{n \cdot R_0}{N} \\ \frac{(n-1) \cdot R_0}{N} < r_i \leq \frac{n \cdot R_0}{N}, \end{cases} \quad (7)$$

式中, N 为分层墨卡托投影的总层数, R_0 为局部球形邻域的半径, n 为当前投影面的层数, λ_i 为第 i 个邻域点的方位角,其值域为 $[-\pi, \pi]$, ϕ_i 为第 i 个邻域点的俯仰角,其值域为 $[-\pi/2, \pi/2]$, r_i 为第 i 个邻域点与邻域中心的径向距离。图2为五层墨卡托投影的平面,可以发现,投影平面随 R_0 的增大逐渐增大。




图2 分层墨卡托投影的平面(5层)

Fig. 2 Plane of hierarchical Mercator projection (5 layers)

2.4 局部特征参数化

经 N 层墨卡托投影后的局部点云具有 N 个特征平面,每个特征平面上都有一组点分布,点云的局部特征参数化,就是将 N 个特征平面上的点进行参数化表示。将每个特征平面划分成尺寸为 $l \times l$ 的网格,统计每个网格中落入的邻域点数。根据每层落到墨卡托平面上点的总数对每次统计量进行归一化,得到 $N \times l \times l$ 的特征分布直方图,图3为 $N=5, l=7$ 的3层墨卡托投影示意图。

3 实验结果

为了验证基于分层墨卡托投影的激光雷达点云局部特征描述子的鉴别力及对噪声的鲁棒性,分别在斯坦福 Bologna 数据集^[19]和3DMatch数据集^[11]上进行了5组实验。用精确率与召回率曲线(PRC)作为局部特征描述子鉴别力的评价标准,其平均精度可通过计算 PRC 的曲线下面积(AUC)^[4]得到,PRC的绘制过程如下。

1) 从场景和模型中提取关键点,并按照所选特征提取所有关键点的特征。

2) 在模型关键点的特征中找到与每个场景的关键点特征 f_i^S 欧氏距离最近和次近的关键点特征,分别记为 f_i^M 和 $f_i^{M'}$ 。

$$\|f_i^S - f_i^M\|_2 / \|f_i^S - f_i^{M'}\|_2 \leq \tau, \quad (8)$$

式中, τ 为给定的特征相似度门限,如果两个特征满足(8)式,则认为两组特征点匹配^[20]。

3) 考察 f_i^S 的真值点是否在 f_i^M 真值点的极小

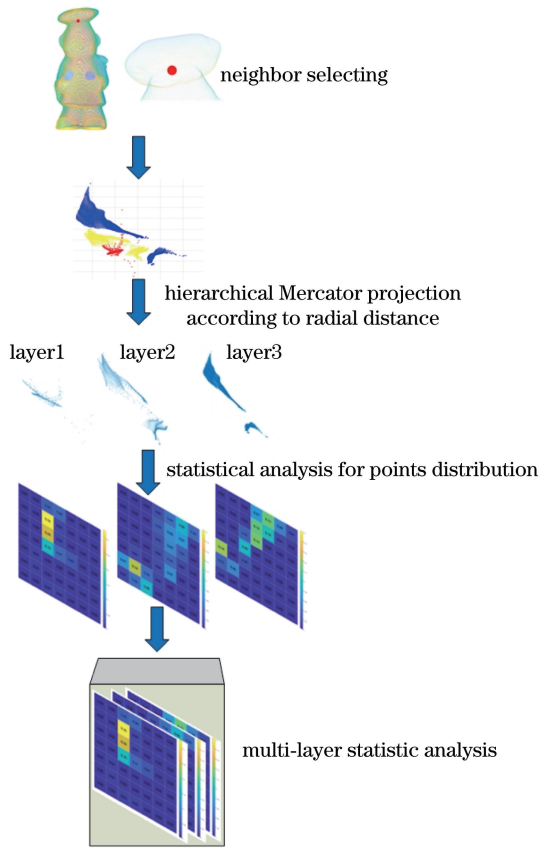


图 3 分层墨卡托投影的流程图(3层)

Fig. 3 Flow chart of hierarchical Mercator projection (3 layers)

邻域内,如果是,则认为该组特征正确匹配,特征匹配的精度 $X_{\text{precision}}$ 和召回率 X_{recall} 可表示为

$$X_{\text{precision}} = \frac{N_{\text{cm}}}{N_{\text{mf}}}, \quad (9)$$

$$X_{\text{recall}} = \frac{N_{\text{cm}}}{N_{\text{cf}}}, \quad (10)$$

式中, N_{cm} 为正确匹配点的个数, N_{mf} 为特征匹配点的个数, N_{cf} 为模型场景之间对应特征点的个数,

Bologna 数据集包含六个来自 Stanford 3D Scanning Repository^[19] 的模型和 45 个由原始模型进行旋转、平移等刚性变换后得到的场景; 3DMatch 数据集包含 8 组由 RGB-D (Red, Green, Blue-depth) 相机重建的场景模型。Bologna 数据集和 3DMatch 数据集^[11] 都包含多个不同角度观测的同一场景和物体数据。为了验证特征描述子的准确性,应对同一目标的不同角度进行测试实验。

以两个数据集为基础,测试分层墨卡托投影的投影层数对分辨性能的影响,并将 20 层分层墨卡托投影得到的局部特征描述子 (HMec-20) 与方向直方图签名 (SHOT)^[16]、旋转投影统计 (RoPS)^[4]、多属性统计直方图 (MaSH)^[8]、三重正交局部深度图

(Toldi)^[13] 等手工局部几何特征描述子进行对比,分析了不同特征描述子对噪声和点云稀疏程度的鲁棒性。实验环境:CPU 为 2.2 GHz 的 Core i7-8750H, RAM 为 8 GB, 计算机系统为 64-bit Microsoft Windows10, 软件为 Matlab。

3.1 分层墨卡托投影特征层数对识别性能的影响

理论上,局部特征的精细度和识别性能随层数的增加而增加,但随着分层投影面的增加,对邻域的划分越细致,算法对噪声的鲁棒性会逐渐下降,导致算法的分辨力减弱。实验数据的噪声方差为 0.3 倍点云分辨率,局部邻域的支撑半径为 50 倍点云分辨率,每层划分成尺寸为 3×3 的直方图网格,根据本算法分别绘制了层数为 1、3、5、10、20、30、50、100 的 PRC,如图 4 所示,其运行时间和平均匹配精度如表 1 所示。

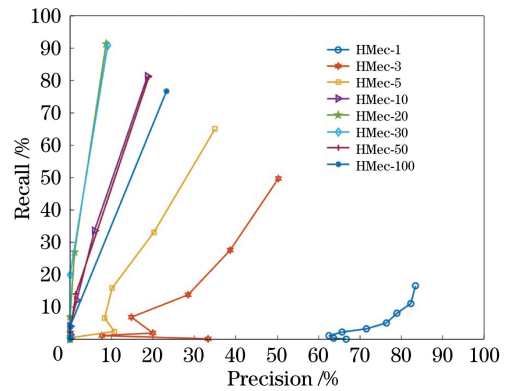


图 4 墨卡托投影层数对算法识别性能的影响(Bologna 数据集)

Fig. 4 Influence of the number of Mercator projection layers on the recognition performance of the algorithm (Bologna dataset)

表 1 分层墨卡托特征提取的运算时间和平均精度(Bologna 数据集)

Table 1 Runtime and average precision of hierarchical Mercator projection (Bologna dataset)

Number of layers	Runtime /s	Average accuracy /%
1	1034.8359	0.0381
3	758.0363	0.3251
5	690.6250	0.5222
10	598.6700	0.7456
20	602.9223	0.8804
30	835.4665	0.8767
50	1278.1252	0.7408
100	13052.3727	0.6823

由图 3 和表 1 可知,20 层以上的墨卡托投影识别性能远远优于 10 层以下的投影方式。但随着层数的增加,识别性能和识别效率均有所下降。原因是投影层数增加时,建立 K 维树 (K -D 树) 的时间

剧增,导致邻近点搜索缓慢,且噪声会对落入网格的点产生影响。

在 3DMatch 数据集上再次进行上述实验,得到 1,3,5,10,20,30 层的分层墨卡托投影特征的 PCR 如图 5 所示,其运行时间和平均匹配精度如表 2 所示。可以发现,20 层以上的墨卡托投影在 3DMatch 数据集上的识别性能同样优于 10 层以下的投影方式,但随着层数的增加,算法的识别性能和识别效率均有所下降,与 Bologna 数据集上的实验结果相同。由表 2 的数据可知,特征提取所需的时间随投影特




图 5 墨卡托投影层数对算法识别性能的影响(3DMatch 数据集)

Fig. 5 Influence of the number of Mercator projection layers on the recognition performance of the algorithm (3DMatch dataset)




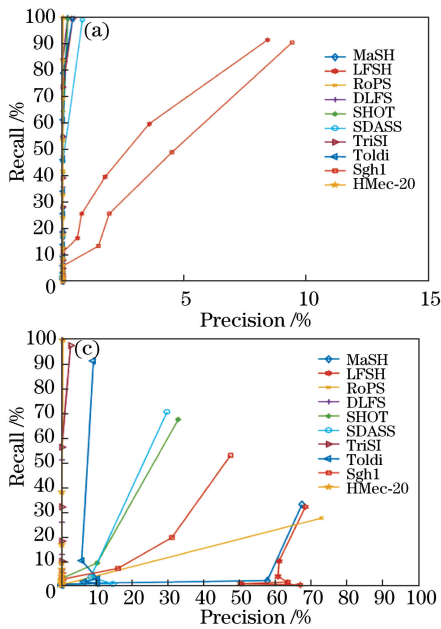


图 6 不同特征提取算法的 PRC。(a)噪声方差为 0.3 倍点云分辨率;(b)噪声方差为 0.5 倍点云分辨率;(c)噪声方差为 0.8 倍点云分辨率;(d)噪声方差为 1.5 倍点云分辨率

Fig. 6 PRC of different feature extraction algorithms. (a) Noise variance is 0.3 times point cloud resolution; (b) noise variance is 0.5 times point cloud resolution; (c) noise variance is 0.8 times point cloud resolution; (d) noise variance is 1.5 times point cloud resolution rate

征平面的增加会有大幅度增加,但性能不能达到最优。在保证计算资源和识别效率的情况下,后续实验均采用 20 层分层墨卡托投影(HMec-20)得到的局部特征描述子。

表 2 分层墨卡托特征提取的运算时间和平均精度 (3DMatch 数据集)

Number of layers	Runtime /s	Average accuracy /%
1	4732.5692	0.0433
3	3069.1723	0.1214
5	1135.2417	0.3044
10	625.3645	0.5471
20	858.3694	0.7182
30	25685.2360	0.5958

3.2 分层墨卡托投影特征对噪声的鲁棒性

为分析该算法对噪声的鲁棒性,在 Bologna 数据集点云模型上分别添加方差为 0.3、0.5、0.8、1.5 倍点云分辨率的高斯白噪声,并计算 MaSH^[8]、局部特征统计量直方图(LFSH)^[3]、SDASS(Statistic of deviation angles on subdivided space)^[12]、DLFS(Divisional local feature statistics)^[15]、SHOT^[16]、RoPS^[4]、TriSI(Tri-Spin-Image)^[20]、Toldi^[13]、Sgh1(Spatial and geometric histogram)^[18]以及 HMec-20 特征描述子的 PRC,如图 6 所示,不同特征描述

子的运算时间与平均精度如表 3 所示。

表 3 不同特征提取算法的平均精度和运算时间

Table 3 Average accuracy and operation time of different feature extraction algorithms

Algorithm	Run-time /s	Average accuracy in different noise /%			
		0.3	0.5	0.8	1.5
TriS	655.6498	0.979	0.885	0.600	0.803
Sgh1	1100.8573	0.986	0.974	0.777	0.142
RoPS	1593.7144	1.000	0.996	0.999	0.994
SHOT	854.8046	0.997	0.994	0.962	0.006
MaSH	219.6354	0.999	0.828	0.151	0.027
SDASS	122.6109	1.000	0.940	0.165	0.035
Toldi	25.0574	0.994	0.983	0.363	0.803
LFSH	308.2209	0.881	0.507	0.120	0.029
DLFS	913.4914	0.856	0.690	0.575	0.077
HMec-20	557.4517	1.000	1.000	1.000	0.995

由图 6 可知,本算法对点云噪声的鲁棒性较好,尤其是在设备精度不高或测量条件恶劣时获得的点云数据适应性较强。由表 3 可知,在噪声方差相同的情况下,相比其他手工提取的特征描述子,HMec-20 特征描述子的鲁棒性更好。由于本算法并未对关键点进行提取,而是将完整点云作为特征提取的输入,因此在运算时间上仍有提升空间。

4 结 论

使用分层墨卡托投影提取激光雷达点云数据的局部特征和几何特征,并对点云进行具有鲁棒性的特征描述。在斯坦福 Bologna 和 3DMatch 数据集上的实验结果表明,本算法能充分保留并提取点云数据的局部邻域结构信息和几何信息,特征描述性能更优异,为三维点云配准、模型重建、目标识别提供了一种有效的局部特征描述方法。

参 考 文 献

- [1] Aldoma A, Vincze M, Blodow N, et al. CAD-model recognition and 6DOF pose estimation using 3D cues [C]//2011 IEEE International Conference on Computer Vision Workshops (ICCV Workshops), November 6-13, 2011, Barcelona, Spain. New York: IEEE, 2011: 585-592.
- [2] Rusu R B, Bradski G, Thibaux R, et al. Fast 3D recognition and pose using the viewpoint feature histogram[C]//2010 IEEE/RSJ International Conference on Intelligent Robots and Systems, October 18-22, 2010, Taipei, Taiwan, China. New York: IEEE, 2010: 2155-2162.
- [3] Johnson A E, Hebert M. Using spin images for efficient object recognition in cluttered 3D scenes[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 1999, 21(5): 433-449.
- [4] Guo Y L, Sohel F, Bennamoun M, et al. Rotational projection statistics for 3D local surface description and object recognition [J]. International Journal of Computer Vision, 2013, 105(1): 63-86.
- [5] Hu J B, Liu Z, Zhang P F, et al. Feature extraction of scattered point clouds based on discrete Morse theory [J]. Acta Optica Sinica, 2019, 39(6): 0615002. 胡佳贝, 刘喆, 张鹏飞, 等. 基于离散 Morse 理论的散乱点云特征提取 [J]. 光学学报, 2019, 39(6): 0615002.
- [6] 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.
- [7] Ren Q C. Method for extraction of point cloud feature line [J]. Laser & Optoelectronics Progress, 2019, 56(6): 062803. 任前程. 一种点云特征线提取方法 [J]. 激光与光电子学进展, 2019, 56(6): 062803.
- [8] Simo-Serra E, Trulls E, Ferraz L, et al. Discriminative learning of deep convolutional feature point descriptors[C]//2015 IEEE International Conference on Computer Vision (ICCV), December 7-13, 2015, Santiago, Chile. New York: IEEE, 2015: 118-126.
- [9] Charles R Q, Su H, Kaichun M, et al. PointNet: deep learning on point sets for 3D classification and segmentation[C]//2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), July 21-26, 2017, Honolulu, HI, USA. New York: IEEE, 2017: 77-85.
- [10] Qi C R, Yi L, Su H, et al. PointNet++: deep hierarchical feature learning on point sets in a metric space[EB/OL]. [2020-04-20]. <https://arxiv.org/abs/1706.02413>.
- [11] Zeng A, Song S R, Nießner M, et al. 3DMatch: learning local geometric descriptors from RGB-D reconstructions [C] // 2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), July 21-26, 2017, Honolulu, HI, USA. New York: IEEE, 2017: 199-208.
- [12] Khoury M, Zhou Q Y, Koltun V. Learning compact geometric features[C]//2017 IEEE International Conference on Computer Vision (ICCV), October 22-29, 2017, Venice, Italy. New York: IEEE,

- 2017: 153-161.
- [13] Yang Y Q, Feng C, Shen Y R, et al. FoldingNet: point cloud auto-encoder via deep grid deformation [C] // 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition, June 18-23, 2018, Salt Lake City, UT, USA. New York: IEEE, 2018: 206-215.
- [14] Yew Z J, Lee G H. 3DFeat-Net: weakly supervised local 3D features for point cloud registration [M] // Ferrari V, Hebert M, Sminchisescu C, et al. Computer Vision-ECCV 2018. Lecture Notes in Computer Science. Cham: Springer, 2016, 11219: 630-646.
- [15] Zhao B, Xi J T. Efficient and accurate 3D modeling based on a novel local feature descriptor [J]. Information Sciences, 2020, 512: 295-314.
- [16] Tombari F, Salti S, Stefano L. Unique signatures of histograms for local surface description [M] // Daniilidis K, Maragos P, Paragios N, et al. Computer Vision-ECCV 2010. Lecture Notes in Computer Science. Berlin, Heidelberg: Springer, 2010, 6313: 356-369.
- [17] Novatnack J, Nishino K. Scale-dependent/invariant local 3D shape descriptors for fully automatic registration of multiple sets of range images [M] // Forsyth D, Torr P, Zisserman A, et al. Computer Vision-ECCV 2008. Lecture Notes in Computer Science. Berlin, Heidelberg: Springer, 2008, 5304: 440-453.
- [18] Sun Y, Abidi M A. Surface matching by 3D point's fingerprint [C] // Proceedings Eighth IEEE International Conference on Computer Vision, ICCV 2001, July 7-14, 2001, Vancouver, BC, Canada. New York: IEEE, 2001: 263-269.
- [19] Levoy M, Gerth J, Curless B, et al. The Stanford 3D scanning repository [DB/OL]. (2005-05-07) [2020-04-25]. <http://graphics.stanford.edu/data/3Dscanrep/>.
- [20] Guo Y, Sohel F A, Bennamoun M, et al. TriSI: a distinctive local surface descriptor for 3D modeling and object recognition [C] // Conference 8th International Joint Conference on Computer Vision, Imaging and Computer Graphics Theory and Applications, February 21-24, 2013, Barcelona, Spain. Barcelona, Spain: Scitepress, 2013, 1: 86-93.