引文格式：陈强. 基于特征空间值筛选的点云关键点提取[J]. 地理空间信息, 2024, 22(1): 16-19. doi:10. 3969/j.issn. 1672-4623.2024.01.004

# 基于特征空间值筛选的点云关键点提取

陈　强[1,2]
（1. 上海市测绘院，上海 200063；2. 自然资源部超大城市自然资源时空大数据分析应用重点实验室，上海 200063）

**摘　要：**针对传统的三维激光扫描点云关键点提取算法存在的计算效率低下、对噪声敏感以及算法不稳定等问题，提出了一种基于特征空间值筛选的关键点提取算法。首先建立用于特征提取的网络架构模型，以点云集内所有点与其邻域点的法向量夹角集合为输入，以一维特征空间向量为输出，按特征空间向量大小排序，选取其中最大 $n$ 个值对应的点作为关键点。实验结果表明，该算法的关键点具有较高的可重复性和运行效率，且对于噪声的鲁棒性更好；在小场景、大场景数据中平均重复率分别约提高了23.0%和9.3%；关键点主要分布于特征变化明显区域，可较好地表达点云特征。

**关键词：**三维激光扫描；关键点检测；法向量夹角；特征空间；重复性
**中图分类号：**P225　　**文献标志码：**B　　**文章编号：**1672-4623（2024）01-0016-04

## Key Point Extraction of Point Cloud Based on Feature Space Value Screening

CHEN Qiang[1,2]
(1. Shanghai Surveying and Mapping Institute, Shanghai 200063, China;
2. Key Laboratory of Spatio-temporal Big Data Analysis and Application of Natural, Shanghai 200063, China)

**Abstract:** Aiming at the low computational efficiency, noise sensitivity and instability of traditional key point extraction algorithm of 3D laser scanning point cloud, we proposed a key point extraction algorithm based on feature space value screening. Firstly, the algorithm establishes a network model for feature extraction. The input of model is the set of angles between the normal vectors of all points in the point cloud and their neighborhood points, and the output of model is one-dimensional feature space vectors. Then, this algorithm sorts the feature space vectors according to the value size, takes the corresponding points with the maximum $n$ values as the key points. The experimental results show that the key points of algorithm have high repeatability and operation efficiency, and have better robustness to noise. The average repetition rate in small scene noise data is increased by about 23.0%, and in large scene data is increased by about 9.3%. The key points are mainly distributed in the area with obvious feature changes, which can better express the feature of point cloud.

**Key words:** 3D laser scanning, key point detection, normal vector angle, feature space, repeatability

激光扫描技术得到的点云数据是对物体的真实表达，具有比二维图像更丰富、层次更深的信息。丰富的信息也为点云数据处理带来了很多问题，激光扫描得到的原始数据量巨大，组织或搜索这样的大数据都是极其耗时的，因此从原始数据中高效提取出稳定且具有代表性的关键点是目前三维点云研究的热点之一[1-3]。提取关键点可大大减少原始数据量，对于后续的点云搜索效率、配准精度和三维物体识别[4-5]等具有重要意义。直接对点云进行下采样，得到精简点云作为关键点，该方式效率高，但通常不包含或包含很少的局部特征信息，如李仁忠[6]等提出了一种点云均匀精简算法，通过建立三维点云的体素栅格对原始点云进行下采样，该算法效率较高但未考虑关键点的局部特征；李琪琪[7]和李国远[8]等采用曲率约束的方式对点云进行精简，该类算法在大曲率位置点云分布较密集，相反则较稀疏，曲率的计算相对复杂且对噪声敏感。考虑局部特征的关键点检测算法能较好地保留原始点云特征，计算效率较低，但得到的关键点可重复性较高，位置分布具有一定特性，如 Allaire S[9]等将二维尺度不变特征变换（SIFT）算法拓展至三维点云，可有效得到局部特征明显的关键点，但计算效率非常低；周坤[10]等将三维 SIFT 算法应用于地形重建中，对 SIFT 算法进行了拓展；Zhong Y[11]提出了内在形状描述（ISS）关键点检测算法，根据每个点与其邻域点的协方差矩阵特征值比值筛选关键点，该算法在局部特征上保留较好，但对噪声敏感；Sipiran I[12]等将二维 Harris 算法拓展至三维，根据每个点与其邻域点的法向量生成局部曲面表达形式，再从中选取极值点作为关键点，该算法对于点云表面特征明显的区域具有较好的提取效果，但对于多样性场景提取效果较差。

收稿日期：2022-07-03。
作者简介：陈强（1995—），硕士，主要研究方向为大地测量、点云数据处理与算法应用，E-mail：1182695648@qq.com。

针对上述问题，本文提出了一种基于特征空间值筛选的关键点提取算法，首先计算所有点的法向量，求出各点与其邻域点的法向量夹角；然后建立特征提取网络架构模型，以法向量夹角为模型输入，将每个点的输入映射至一维的特征空间值，对特征空间值进行排序，筛选得到关键点。实验结果表明，该算法得到的关键点位置主要分布于特征变化明显区域，具有更高的可重复性和运行效率，对于噪声的鲁棒性也更好。

## 1　算法原理

### 1.1　法向量夹角的计算

法向量夹角从几何意义上能近似反映局部曲率，相较于直接计算曲率，法向量夹角包含更丰富的表面变化信息且计算量更小，因此计算法向量夹角对于最终确定关键点非常重要。法向量计算方式较多，本文选取主成分分析法求解[13]。首先创建每个点与其邻域点的协方差矩阵，即

$$\boldsymbol{C}=\frac{1}{k}\sum_{i=1}^{k}\left(P_i-\bar{P}\right)\left(P_i-\bar{P}\right)^{\mathrm{T}} \tag{1}$$

式中，$P_i$ 为邻域点；$\bar{P}$ 为邻域点的质心。

求出协方差矩阵的特征值和特征向量后，选取最小特征值对应的特征向量作为法向量，完成法向量定向[14]。法向量夹角越大意味着曲率越大，这样的输入不仅涵盖了点云的表面变化信息且较大程度地剔除了冗余信息。两点间的法向量夹角计算公式为：

$$\angle\left(\boldsymbol{n}_1,\boldsymbol{n}_2\right)=a\cos\left(\frac{\boldsymbol{n}_1\times\boldsymbol{n}_2}{\left|\boldsymbol{n}_1\right|\times\left|\boldsymbol{n}_2\right|}\right) \tag{2}$$

式中，$\boldsymbol{n}_1$、$\boldsymbol{n}_2$ 分别为两点的法向量。

将法向量夹角拓展至单个点与 $k$ 邻域的点，得到含有 $k$ 个法向量夹角的向量，如第 $r$ 个点为：

$$F=\left(\angle\left(\boldsymbol{n}_r,\boldsymbol{n}_1\right),\angle\left(\boldsymbol{n}_r,\boldsymbol{n}_2\right),\cdots,\angle\left(\boldsymbol{n}_r,\boldsymbol{n}_k\right)\right) \tag{3}$$

$F$ 即为下一步模型的输入，对于该过程中涉及的法向量夹角邻域点数将在参数实验中分析。

### 1.2　模型建立与关键点确定

算法需要建立一个特征提取模型，参考文献[15]的实验表明，卷积层+全连接层的编码器网络架构模型可将点云和点云衍生信息转换至特定的特征空间，从而量化输入的信息。因此，本文针对已有的法向量夹角信息和关键点提取的特点，建立网络架构模型（图1），输入设置为所有点与其邻域点的法向量夹角 $F$，输出映射为一维特征空间向量。$F$ 对应图中的单个 $k$ 维输入向量，将所有点的信息合并再输入卷积层，输出维度分别为64、128、1 024，卷积层对输入的不规则特征进行再编码，得到规则的升维的特征向量；然后输入归一化层对特征向量做归一化处理，使得值的范围不会溢出，得到升维且归一化的特征空间信息；再将上述结果作为全连接层的输入，输出维度分别为1 024、512、256、1；最终得到一维特征空间向量。特征空间向量每个值的大小反映的是对应点处表面特征变化大小，因此算法按特征空间向量值大小排序，根据关键点数从中取出最大 $n$ 个值的对应点，即需要的关键点。

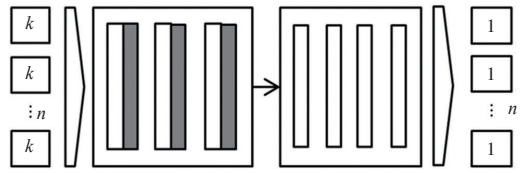



图1　特征提取模型架构图

算法输入的法向量夹角信息经过模型映射，最终得到的特征空间向量反映的是点云局部表面变化程度，而筛选后的最大 $n$ 个点具有最大的变化信息，因此具有最明显的表面变化特征，得到的关键点具有一定的代表性；同时由于法向量夹角信息对于点云空间变换具有不变性，且该输入经网络模型映射为一维向量后成了量化值，不同站点的同名点间应当具有近似的特征空间值，因此不同站点提取的关键点具有高度的可重复性。

## 2　实验结果与分析

### 2.1　实验环境与数据来源

实验电脑内存为8 GB，算法由Python语言和Tensorflow2.0实现，对照组的Harris3D和SIFT算法由PCL1.8[16]实现。实验选取Stanford 3D Scanning Repository的斯坦福雕像扫描仪获取的Lucy雕像点云和Robotic 3D Scan Repository的Riegl VZ-400扫描仪获取的大规模城市数据（命名为City）两组数据。

### 2.2　评价指标

关键点提取得到的点通常具有代表性和可重复性，代表性是指反映原始点云主要特征的程度；可重复性是指同场景不同站点点云经过关键点提取后，应当具有较高的重复性。重复性通常用最近点距离阈值内的点数占总点数的比例表示，即重复率[17]。

对照算法选取ISS（ISS关键点）算法、Voxel算法、Uniform算法、Sift算法、Curvature算法和Harris

算法。参考点位偏差阈值选取，首先选取一个点云密度 $n$ 倍的常数作为标准，再从0~2之间均匀选取若干数，以这组数作为图表的横坐标，然后将这组数与标准数相乘得到一系列阈值，预先求出两幅实验点云的真实转换矩阵并配准，若同名点间的误差小于阈值则认为满足重复的条件。

### 2.3 关键点可重复性和稳健性评估

对Lucy数据进行实验，分析邻域点参数对可重复性的影响，添加10 db强度的高斯白噪声，设置参考点位偏差阈值的标准为5 mm。由图2可知，当邻域点数由20递增至100时，整体重复率呈增长趋势，但当邻域点数增加到40时，重复率几乎不再增长，且邻域点增加将导致计算时间显著增加，综合可重复性与效率因素可知40个邻域点较优。

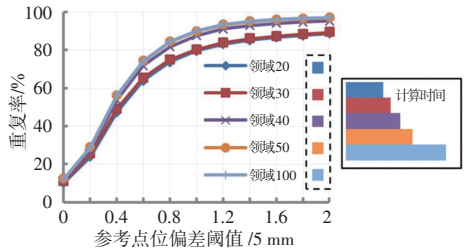
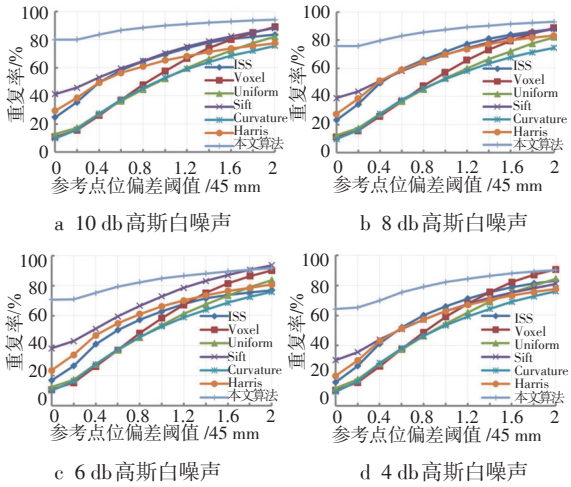



图2 邻域点参数实验图

在Lucy数据中分别添加10 db、8 db、6 db和4 db强度的噪声，验证算法对不同强度噪声的稳健性。设置参考点位偏差阈值的标准为45 mm。由图3可知，各算法间重复率相对关系基本不变，即本文算法>Sift>Harris>ISS>Voxel>Uniform>Curvature，随着参考点位偏差阈值的增大，算法间的重复率差距减小，因此本文算法具有比传统算法更高的可重复性和更强的稳健性。

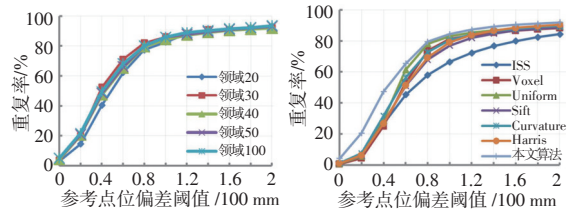



a 10 db高斯白噪声　b 8 db高斯白噪声

c 6 db高斯白噪声　d 4 db高斯白噪声

图3 Lucy噪声数据算法对比图

为验证不同场景点云数据的参数，利用City数据再次进行参数实验，设置参考点位偏差阈值的标准为100 mm。由图4可知，当邻域点数为30时重复率达到极大值；本文算法在所有实验组算法中具有最高的重复率。



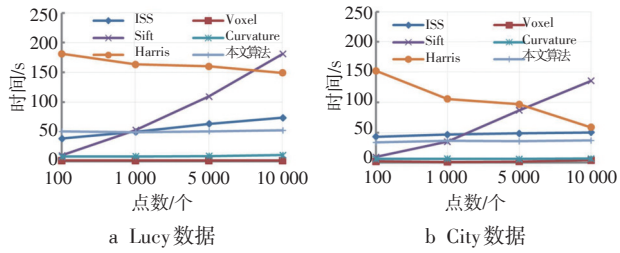

a 参数对比　b 算法对比

图4 City数据算法对比图

综上所述，本文算法在邻域点数为30~40时具有较高的可重复性，与传统算法相比，具有更高的可重复性和运行效率，且对噪声的稳健性更好，在Lucy噪声数据中平均重复率约提高23.0%，在City数据中平均重复率约提高9.3%。

### 2.4 关键点提取效率与空间位置分析

关键点提取算法的计算效率决定了算法的实用性，空间位置分布则更直观地展现了关键点分布差异。由于Voxel算法和Uniform算法的提取结果在效率和位置分布上极为近似，因此实验以Voxel算法为代表，分别对两组数据提取10 000、5 000、1 000、100个关键点。由图5可知，两组数据中不同算法计算时间的相对关系基本保持一致，即Harris>Sift>ISS>本文算法>Curvature>Voxel，Curvature和Voxel算法的计算效率最高，但Curvature算法的稳定性最差，Voxel算法得到的关键点是随机均匀分布的，完全未考虑到点云特征。因此，综合计算效率、稳定性、局部特征保留程度来看，本文算法最优。



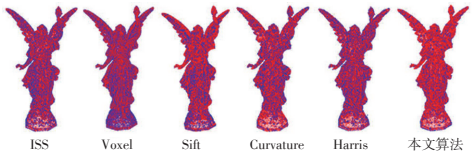

a Lucy数据　b City数据

图5 多分辨率计算效率对比

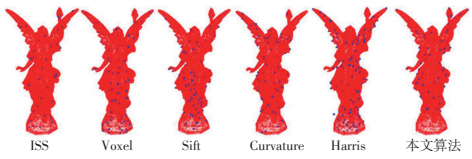
为分析不同算法提取的关键点空间位置，分别将两组数据提取的关键点与原始数据进行叠加对比。由图6可知，Lucy数据中本文算法关键点集中于多个特征变化明显的区域，其余算法位置分散，在平坦区域和其他特征变化不明显区域仍有分布。

由City数据提取的100个关键点叠加图（图7）可知，本文算法提取的关键点几乎不存在噪声点，对点云中特征变化明显区域的覆盖率较高，提取的关键点

具有较高的代表性和可识别性。

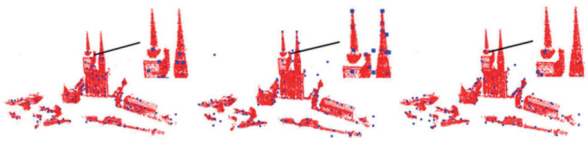



a 关键点数为10 000

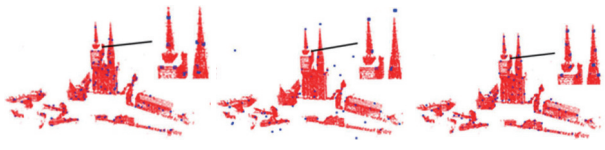



b 关键点数为100

图6　Lucy数据关键点位置分布图



a ISS　　b Voxel　　c Sift



d Curvature　　e Harris　　f 本文算法

图7　City数据关键点位置分布图

由实验结果可知，本文算法的计算效率高于ISS、Harris和Sift算法，不及Curvature、Voxel和Uniform算法，但是Curvature算法的稳定性最差，Voxel和Uniform算法完全未考虑点云特征，且根据位置分布，本文算法得到的关键点含噪声点最少，关键点位置主要分布在特征变化明显、边缘点和角点区域，比传统算法分布更集中和稳定。

## 3　结　语

针对传统关键点提取算法计算效率低、可重复性差的问题，提出了一种基于特征空间值筛选的关键点提取算法。首先计算所有点的法向量，求取各点与其邻域点的法向量夹角；再建立特征提取网络架构模型，以法向量夹角作为模型输入，将其映射为一维的特征空间值；最后对特征空间值进行排序，筛选得到关键点。本文分别在两组不同规模场景中进行实验，与传统算法相比，本文算法提取的关键点具有更高的可重复性和运行效率，且对于噪声的鲁棒性更好，小场景、大场景数据中平均重复率分别约提高23.0%和9.3%，关键点位置主要分布于特征变化明显区域，可较好地表达点云的整体和局部特征，得到的关键点能进一步应用于点云配准、目标识别等任务中。然而，本文算法的参数自适应性还需进一步加强，后续将对此进行着重研究。

## 参考文献

[1] 李绕波，袁希平，甘淑，等. 多因素参与的3D特征点检测方法[J]. 测绘科学技术学报，2021，38(5)：499-506

[2] 张亚，山锋，王涛. 三维激光扫描技术点云数据采集与配准研究[J]. 地理空间信息，2021，19(3)：24-27

[3] 许振瑛，何宁，晁建刚，等. 三维点云关键点局部坐标系重构方法研究[J]. 载人航天，2022，28(3)：344-349

[4] 王鹏，李少达，赵雪. 基于B-SHOT特征和3D-NDT的点云自动配准[J]. 地理空间信息，2018，16(12)：26-27

[5] 付鲲，陈雷. 基于曲率信息的人工蜂群点云配准算法[J]. 计算机应用研究，2020，37(4)：999-1 003

[6] 李仁忠，杨曼，刘阳阳，等. 一种散乱点云的均匀精简算法[J]. 光学学报，2017，37(7)：97-105

[7] 李琪琪，花向红，赵不钒，等. 一种基于曲率泊松碟采样的散乱点云精简方法[J]. 测绘通报，2020(增刊1)：176-180

[8] 李国远，梁周雁，石信肖，等. 基于曲率特征约束的激光点云精简方法研究[J]. 计算机与数字工程，2020，48(8)：2 034-2 037

[9] Allaire S，Kim J J，Breen S L，et al. Full Orientation Invariance and Improved Feature Selectivity of 3D SIFT with Application to Medical Image Analysis[C]. 2008 IEEE Computer Vision and Pattern Recognition Workshops，2008

[10] 周坤，谷晨鹏，张东，等. SIFT和ORB特征检测算法在地形三维重建中的研究与应用[J]. 测绘与空间地理信息，2021，44(3)：44-48

[11] Zhong Y. Intrinsic Shape Signatures: A Shape Descriptor for 3D Object Recognition[C]. IEEE International Conference on Computer Vision Workshops，2009

[12] Sipiran I，Bustos B. Harris 3D: A Robust Extension of the Harris Operator for Interest Point Detection on 3D Meshes[J]. Visual Computer，2011，27(11)：963

[13] 孙培芃，卜俊洲，陶庭叶，等. 基于特征点法向量的点云配准算法[J]. 测绘通报，2019(8)：48-53

[14] 麻卫峰，王金亮，张建鹏，等. 一种改进法向量估算的点云特征提取[J]. 测绘科学，2021，46(11)：84-90

[15] Wang Z，Zhang L Q，Zhang L，et al. A Deep Neural Network with Spatial Pooling (DNNSP) for 3D Point Cloud Classification[J]. IEEE Transactions on Geoscience and Remote Sensing，2018，56(8)：4 594-4 604

[16] 朱德海. 点云库PCL学习教程[M]. 北京：北京航空航天大学出版社，2012

[17] 兰渐霞，王泽勇，李金龙，等. 基于正态形状索引的关键点提取算法[J]. 激光与光电子学进展，2020，57(16)：184-193