



计算机科学

COMPUTER SCIENCE

基于PCPNET的点云特征线提取算法

喻孟娟, 聂建辉

引用本文

喻孟娟, 聂建辉. 基于PCPNET的点云特征线提取算法[J]. 计算机科学, 2022, 49(11A): 210800017-6.

YU Meng-juan, NIE Jian-hui. Point Cloud Feature Line Extraction Algorithm Based on PCPNET[J].

Computer Science, 2022, 49(11A): 210800017-6.

相似文章推荐 (请使用火狐或 IE 浏览器查看文章)

Similar articles recommended (Please use Firefox or IE to view the article)

[基于点云数据的交通环境下单阶段三维目标检测方法](#)

Single-stage 3D Object Detector in Traffic Environment Based on Point Cloud Data

计算机科学, 2022, 49(11A): 210900079-6. <https://doi.org/10.11896/jsjcx.210900079>

[基于点云的室内结构三维重建综述](#)

Overview of 3D Reconstruction of Indoor Structures Based on Point Clouds

计算机科学, 2022, 49(11A): 211000176-11. <https://doi.org/10.11896/jsjcx.211000176>

[基于可变形图卷积的点云表征学习](#)

Deformable Graph Convolutional Networks Based Point Cloud Representation Learning

计算机科学, 2022, 49(8): 273-278. <https://doi.org/10.11896/jsjcx.210900023>

[三维激光雷达点云空间多特征分割](#)

Spatial Multi-feature Segmentation of 3D Lidar Point Cloud

计算机科学, 2022, 49(8): 143-149. <https://doi.org/10.11896/jsjcx.210300275>

[基于局部约束特征线表示的人脸识别](#)

Face Recognition Based on Locality Constrained Feature Line Representation

计算机科学, 2022, 49(6A): 429-433. <https://doi.org/10.11896/jsjcx.210300169>

基于 PCPNET 的点云特征线提取算法

喻孟娟 聂建辉

南京邮电大学自动化学院 南京 210023

(yumengjuan1029@163.com)

摘要 特征线提取是几何模型处理的基础操作,其对三维模型的表达具有重要意义。文中基于 PCPNET 提出了一种对噪声和非均匀采样具有鲁棒性的曲率值和主曲率方向的计算方法,并在其基础上提出了一种特征线提取算法。该算法利用加权二次曲线拟合局部曲率分布,并通过判定在最大主曲率方向上与二次曲线极值点的距离来实现脊谷特征点的识别;最后,通过建立细化后潜在特征点的最小生成树(MST)实现特征点的连接,完成特征线的提取。实验结果表明,所提算法能够利用 PCPNET 对点云曲率和主曲率方向信息进行较为准确的估计,并且根据所提出的特征点识别方法可以弥补传统采用简单阈值截断导致平坦区域特征线无法正常提取的缺陷,最终能准确、完整地分别从清洁点云和噪声点云中提取特征线。

关键词: 点云;特征线;PCPNET;曲率

中图分类号 TP391

Point Cloud Feature Line Extraction Algorithm Based on PCPNET

YU Meng-juan and NIE Jian-hui

School of Automation, Nanjing University of Posts and Telecommunications, Nanjing 210023, China

Abstract Feature line extraction is the basic operation of geometric model processing, which is of great significance to the expression of 3D model. Based on PCPNET, a calculation method of curvature value and principal curvature direction which is robust to noise and non-uniform sampling is proposed, and a feature line extraction algorithm is proposed. The proposed algorithm uses the weighted quadratic curve to fit the local curvature distribution, and realizes the recognition of ridge and valley feature points by determining the distance from the extreme point of the quadratic curve in the direction of maximum principal curvature. Finally, the minimum spanning tree(MST) of the refined potential feature points is established to connect the feature points and complete the feature line extraction. Experimental results show that the proposed algorithm can use PCPNET to accurately estimate the curvature and principal curvature direction information of point cloud, and according to the proposed feature point recognition method, it can overcome the defect that the traditional simple threshold truncation can not extract the feature lines of flat area normally, and finally extract the feature lines from clean point cloud and noise point cloud accurately and completely.

Keywords Point cloud, Characteristic line, PCPNET, Curvature

1 引言

特征线提取是几何模型处理的基础操作,其结果能够为三维模型表示和理解提供重要信息,在可视化^[1]、模型优化^[2-3]与简化^[4-6]、曲面重建^[7]、曲面平滑^[8-9]等诸多领域都有广泛的应用。

特征线是特征点的有序连接,因此特征线提取的首要步骤是寻找一个度量曲面变化的指标以将潜在特征点从整体点云中识别出来。为了实现这一点,主元素分析的方法^[10-13]、曲率的方法^[14-21]以及 M 估计的方法^[22-24]被提出。但是,由于拓扑缺失、非均匀采样以及噪声干扰等问题,针对散乱点云的曲面变化度量问题仍然需要进一步的探讨。识别出潜在特征点后还需要利用曲线增长算法或最小生成树的方法进行处理,以得到有序连接的特征线。在此过程中需要考虑噪声以及非均匀采样引起的特征线断裂和分叉等问题。

本文提出了一种能够从噪声和非均匀采样点云中提取特征线的新算法。首先,利用 PCPNET 计算点云曲率和主曲率方向;然后,基于脊谷特征是局部曲率极值点的观察,采用加权二次曲线拟合局部曲率分布,并通过求取二次曲线极值点位置实现脊谷点的识别;最后,对每一区域的潜在特征点进行独立处理,利用基于曲率和距离的双边滤波算法对潜在特征点进行迭代细化并连接细化后的特征点生成特征线。本文的主要贡献如下:1)将深度网络 PCPNET 运用到主曲率方向的估算中,PCPNET 能够准确计算点云主曲率方向,并且对一系列噪声边缘和采样变化具有鲁棒性。2)采用加权二次曲线拟合局部曲率分布,并通过求取二次曲线极值点位置实现脊谷点的识别。利用具有唯一极值点的连续函数拟合离散数据,并以极值点到当前点的距离为准则判定脊谷点,可以弥补传统方法采用简单阈值截断导致平坦区域脊谷线无法正常提取的缺陷。同时,采用二次曲线而非二次曲面拟合局部数据,

基金项目:国家自然科学基金(61802240)

This work was supported by the National Natural Science Foundation of China(61802240).

通信作者:聂建辉(njh19@njupt.edu.cn)

可以减少参数个数,在邻域点数相同的情况下,可以有效提高计算效率。

本文第2节回顾相关工作;第3节介绍所提出的基于PCPNET提取特征线的算法;第4节为验证实验,并将本文算法与当前主流算法进行了比较;最后总结全文。

2 相关工作

从无拓扑连接的散乱点云中提取特征线是一项极具挑战性的工作。一般而言,其过程可分为潜在特征点识别和特征点连接两个部分。

2.1 潜在特征点识别

为识别出潜在特征点,Gumhold等^[10]首先将主元分析引入到特征线提取中来,其做法是借助PCA结果中的特征值构建曲面变化度来识别潜在特征点,并进一步利用特征向量将潜在特征点分为边界点、棱点和角点,最终构建特征点的最小生成树,完成特征点的连接;Pauly等^[12-13]扩展了上述方法,通过变换邻域点个数对点云进行多尺度的PCA分析,提高了算法对噪声点云的适应能力。虽然上述利用曲面变化度代替曲率进行特征度量的方法可以较好地表征曲面的弯曲程度,但曲面变化度仅仅是对曲面弯曲幅度的度量,不能像真实曲率一样通过取值符号的正负来表达曲面的凹凸性,因此,对于空间距离邻近的谷线和脊线往往不能正确区分。

为了能够按照标准定义求取点云曲率,研究人员引入了曲面拟合的方法。其中,Wang等^[14]提出了一种基于局部重建的点云特征线提取算法,通过判定潜在特征点隶属的曲面数量来寻找特征点,能够在提取显著特征线的同时尽可能多地保留弱特征线,但是该算法对邻域点仅采用简单的平面拟合,不适用于弯曲曲面相交形成的特征线的提取;Pang等^[15]采用拟合局部二次曲面的方法计算曲率,然后将特征点投影到离其最近的潜在特征线上得到增强的特征点,该方法虽然能够提取出较为平滑且细小的特征,但是由于需要投影到切平面进行处理,因此,容易导致信息丢失,所提取的特征线容易发生断裂;Kim等^[16-17]、Weber等^[18]都采用移动最小二乘算法估算点云曲率信息,其中,Kim还通过计算局部Voronoi图获取邻域信息,类似的方法也被Quentin等^[19]采用,但Voronoi图容易受到离群点的影响;Daniels等^[20]采用鲁棒移动最小二乘方法拟合曲面,然后将潜在特征点投影到不同曲面的交线上以获取特征线。上述这些方法都采用移动最小二乘曲面作为曲率估算的工具,运算速度受到限制,对于数据量大的点云而言时间代价较高,且对非均匀采样点云处理效果不佳。文献^[21]采用快速傅里叶变换(FFT)计算点云曲率,虽然可以进行并行加速,但其需要事先通过PCA分析为点云的每个点建立局部坐标系,并进行投影计算,这些步骤的时间复杂度同样较高,此外还需要对结果进行低通滤波才能得到满意的结果。

实际点云中都不可避免地包含测量噪声,为了克服大幅度噪声的影响,基于统计分析的方法被提出。其中,Evangelos等^[22]通过M估计大大提高了对含噪声和非均匀采样点云数据进行曲率估算的准确性,但时间复杂度过高;Min等^[23]提出了基于多尺度张量投票的特征量计算方法,算法效率较高且对噪声具有良好的适应性,但对非均匀采样点云适用性欠佳;Weber等^[24]通过邻域点高斯图聚类实现特征线的提取,具有良好的鲁棒性,但算法是针对尖锐特征线提出的,

无法实现平滑特征线的提取;Guerrero等^[25]将利用PCPNET对点云进行曲率估算,通过神经网络的泛化能力实现噪声情况下对点云曲率的准确估算,该方法将深度学习应用到点云的估计当中,同时在网络训练时加入高斯噪声,进一步增加了网络模型的鲁棒性和泛化能力。

2.2 特征点连接

特征点连接是对潜在特征点进行后续处理以生成有序连接的特征线的过程。一种连接特征点的方法是增长方法,如Enkhbayar等^[21]首先对识别到的特征点进行细化,然后从中找到一个种子点,并基于种子点和曲线走向逐步将其他点加入到特征线中生成完整的特征线;Kim^[17]则利用Voronoi图构建拓扑连接并结合曲率方向实现特征曲线生长。另一种特征点连接的方法是整体法,一般通过构建潜在特征点的最小生成树来实现,如Pauly等^[12]首先构建潜在特征点的无向连接图,然后基于曲面变化度和距离计算连接图各边的权重并构建最小生成树,最后在修剪短边后生成有序连接的特征线;Demarsin等^[11]则首先利用法向量对整体点云进行区域分割,然后对区域边界点构建最小生成树来提取封闭特征线;Gerhard等^[1]则利用最小生成树构建边界点的最小生成图,并从中抽取封闭的边界线。

3 算法

3.1 算法综述

本文提出的算法流程如图1所示。算法首先利用PCPNET计算点云中每一点的曲率值和主曲率方向,然后利用加权二次曲线拟合局部曲率分布,并通过求取二次曲线极值点位置实现脊骨特征点的识别。上述方案利用具有唯一极值点的连续函数拟合离散数据,并以极值点到当前点的距离为准则判定脊谷点,可以弥补传统方法采用简单阈值截断导致平坦区域脊谷线无法正常提取的缺陷。上述步骤结束后,构建特征点的最小生成树即可将特征点连接成特征线,完成特征线提取。




图1 本文算法流程

Fig. 1 Process of the proposed algorithm

3.2 算法实施

3.2.1 基于PCPNET的点云曲率和主曲率方向计算

PCPNET是一种能够从原始点云数据中估计局部形状特征的网络,在点云曲率和法向量的估算上具有较好的效果。但本文中的特征线提取算法需要主曲率方向的信息,因此,需要对PCPNET网络进行改动,将原输出改为输出点云曲率和主曲率方向信息。

PCPNET是一种基于局部点邻域的数据驱动方法,其中训练神经网络PCPNET在不同输入扰动下使用曲率标准值参考结果直接学习点云的曲率。其网络结构图如图2所示。其流程为给定一个点云 $P = \{p_1, \dots, p_N\}$,其局部邻域 P_i^r 以点 p_i 为中心,包含与中心距离为 r 的所有点,并且在中心点 p_i 中,将其转换为原点,并将其半径与 $1/r$ 相乘做归一化处理。PCPNET根据 P_i^r 中的信息来估计中心点的曲率。大量

实验表明 PCPNET 在点云曲率的估计上相比之前的方法具有优势。




图2 PCPNET网络结构图

Fig. 2 Network structure diagram of PCPNET

因为 PCPNET 是一种基于深度学习来估计点云中的局部三维形状特性的方法,并且由于本文特征线提取算法需要点云主曲率方向的信息,因此考虑将 PCPNET 应用于点云主曲率方向的估计。在算法中将带有较小主曲率方向标签的点云数据作为网络输入。首先,PCPNET 需要将输入点转换为规范姿态。该步骤通过使用空间变换器网络 STN1 来完成。将一组具有共享参数的函数分别应用于每个点,然后使用对称操作将每个点的结果值组合起来,从而 STN1 实现了保持输入点排序不变,然后通过 FNN1 得到特征向量 $\mathbf{g}_j = g_1(p_j), \dots, g_{64}(p_j)$,将空间变换器网络 STN2 作用在特征向量 \mathbf{g}_j 上,给出一个 64×64 变换矩阵,通过 FNN2 得到函数 h_i, h_l 的计算公式为:

$$h_l(p_j) = (FNN_2 \circ STN_2)(g_1(p_j), \dots, g_{64}(p_j)) \quad (1)$$

这种变换可以解释为一个完全连接层,该层具有邻域中所有点的特征向量 \mathbf{g} 计算的权重。这就将全局信息引入到函数 h_l 中,从而提升了网络的性能。最后将函数 h_l 汇总到 $H_l(P_i^r)$ 。 $H_l(P_i^r)$ 是邻域的一个特征,其计算式为:

$$H_l(P_i^r) = \sum_{p_j \in P_i^r} h_l(p_j) \quad (2)$$

最后对邻域特征向量 $\mathbf{H}_j = (H_1(P_i^r), \dots, H_k(P_i^r))$ 使用一个 3 层全连接网络来进行对中心点曲率和主曲率方向的回归。将网络输出改为 4 个神经元,同时输出需要的曲率和主曲率方向信息。

PCPNET 能够在不同输入扰动下使用。地面真相参考结果直接学习局部属性。在 PCPNET 中使用一个相对较小的带有曲率和主曲率方向标记的数据集来有效地对网络进行训练。PCPNET 是通过随机选择数据集中在点云数据中的一个点及其领域来训练的。

3.2.2 特征点识别

特征线上的点又称为脊谷特征点,在潜在脊谷特征点两侧沿最大主曲率方向必然出现曲率先升后降或先降后升的过程,如图 3 所示。




图3 特征点识别示意图

Fig. 3 Schematic diagram of characteristic point identification

当前点与曲率极值点距离较小,而远离脊谷点的点云

附近曲率分布则会表现出单调上升或单调下降的趋势,且当前点与曲率极值点距离较大,因此,可以通过求取最大主曲率方向上的曲率极值点得到脊谷特征点。

基于上述分析,本文利用二次曲线拟合局部曲率分布,并通过判定当前点与曲率极值点的距离实现脊谷特征点的识别。具体步骤如下:

(1) 建立以当前点 p 为原点、以点 p 的法向量为 z 轴正向、以最大主曲率方向为 x 轴的局部坐标系,并将当前点及其邻域点坐标转换至该坐标系下;

(2) 建立如式(3)所示的目标方程,其中, n 为邻域点个数, $c_0 - c_2$ 为二次曲线系数, x_i, y_i, z_i 为邻域点在局部坐标系下的坐标分量,是邻域点最大主曲率值;

$$\operatorname{argmin}_{i=1}^n w_i (c_0 x_i^2 + c_1 x_i + c_2 - k_{1i})^2 \quad (3)$$

(3) 利用线性最小二乘算法求解 $c_0 - c_2$, 进而得到曲率极值点的 x 坐标为 $x_{\max} = -c_1 / (2c_0)$;

(4) 判断曲率极值点与当前点的距离,如果 d 小于点云局部采样密度 ρ , 则将其识别为脊谷点, 否则, 说明当前点距离真实脊谷点较远, 将其识别为一般点。

上述方案利用具有唯一极值点的连续函数拟合离散数据,并以极值点到当前点的距离为准则判定脊谷点,可以弥补传统方法采用简单阈值截断导致平坦区域脊谷线无法正常提取的缺陷。同时,采用二次曲线而非二次曲面拟合局部数据,可以减少参数个数,提高效率。

3.2.3 特征点的连接

本文通过建立细化后潜在特征点的最小生成树(Minimum Spanning Tree, MST)实现特征点的连接。应当指出,细化后潜在特征点的密度远远大于点云平均采样密度,而且其分布可能是非均匀的。为保证 MST 的正常构建,首先需要对细化后的潜在特征点重新采样,生成密度等于点云平均采样间距的特征点。重采样结束后,对每条特征线中的特征点搜索其 5 近邻点,并以距离平方和作为连接权重,构建特征点的无向连接图,最后利用 Prim 算法生成该连接图的最小生成树。同时,为剪除特征线中的短边,检查生成树中每条线段的方向与细化过程中所计算的特征线方向的夹角,如果夹角大于一定阈值,则将其从最小生成树中剔除。

4 实验与分析

本文算法用 python 语言实现,本文实验在 CPU 为 i7 8700K 频率为 3.2GHz、GPU 为英伟达 GTX 1080Ti 的台式机上完成。

在网络训练中,我们的网络是通过选择随机集中的一个点云领域来训练的,同时,在本文算法中特征明显的点云模型的邻域大小设为 0.1,复杂点云模型的邻域大小设为 0.05。PCPNET 每个邻域使用固定数量的 500 点。如果邻域半径内有较少的点,则用零填充。在每个 epoch,我们从训练集中的每个点云迭代 10000 个补丁。我们在数据集上训练了多达 2000 个迭代,直到收敛。除此之外,PCPNET 网络具有很强的泛化能力,因此即使面对更加复杂的情况时,也能在棱线附近对主曲率方向做出正确的估计。为了增加鲁棒性,本文向训练数据加入幅值为平均采样间距 25% 和 50% 的零均值随机噪声,能够让网络更好地处理真实数据中含有噪声的情况。训练数据如图 4 所示。




图 4 PCPNET 训练数据图

Fig. 4 Training data graph of PCPNET

我们的训练数据集包含 4 个形状,其中一半是人为做的物体或具有平面和锐角的几何结构,另一半是对雕像的扫描。对于每个模型我们生成一个无噪声点云数据和两个分别加入幅值为平均采样间距 25%和 50%和的零均值随机噪声点云数据。实验表明,生成的这些由 3 个平面组成的锥形数据

足以代表真实数据中大多数含有复杂特征的情况。同时本文向训练数据中适当地添加噪声,能够让网络更好地处理真实数据中含有噪声的情况。

首先,将算法应用到 Cad-Workpart 和 Cad-fandisk 模型上,该模型包含有丰富且明显的几何特征,是验证算法有效性的理想数据。具体地,我们分别在两种情况下(不加噪声和加噪声)对网络进行测试,并采用文献[15]的方法在统计曲率和主曲率方向估算误差,即通过计算曲率与标准曲率的均方根大小来、和通过计算主曲率方向与标准主曲率方向的平均夹角大小来评判网络性能。相关实验结果如表 1 所列。图 5 和图 6 给出了利用 PCPNET 的对特征估算的结果。从图中可以看到,利用 PCPNET 估算的曲率值很好地反映了模型表面的特征。

表 1 PCPNET 网络结构误差

Table 1 Network structure error of PCPNET

模型	Cad-Workpart	Cad-Workpart (noise 0.25)	Cad-Workpart (noise 0.5)	Cad-fandisk	Cad-fandisk (noise 0.25)	Cad-fandisk (noise 0.5)
Curvmax	0.0736	0.0741	0.0757	0.0987	0.0965	0.0914
curvmin	0.0208	0.0209	0.0210	0.0068	0.0066	0.0074
主曲率方向	11.740	11.590	12.560	15.740	13.120	13.340




图 5 Cad-fandisk 模型 PCPNET 特征计算

Fig. 5 PCPNET feature calculation of Cad-fandisk


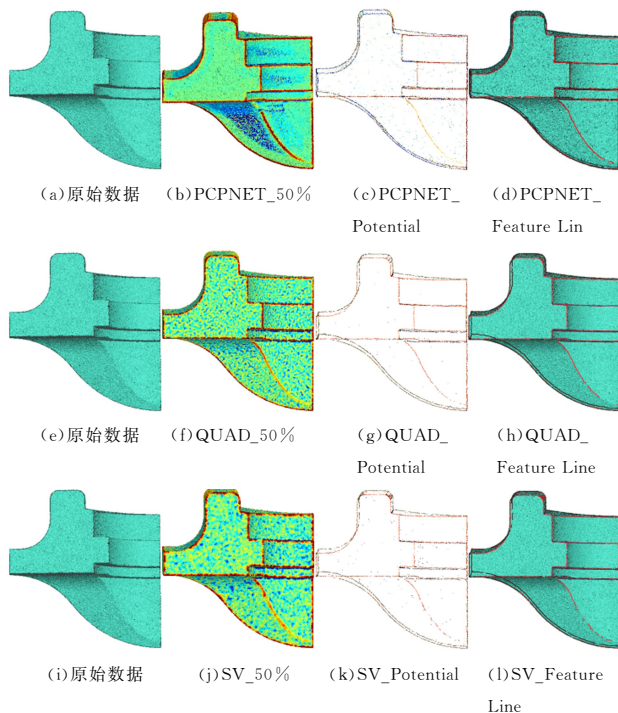


图 6 Cad-Workpart 模型 PCPNET 特征计算

Fig. 6 PCPNET feature calculation of Cad-Workpart

向原始数据加入幅值为平均采样间距 25%和 50%的零均值随机噪声后,PCPNET 计算的准确性不会受到太大影响,表明 PCPNET 对噪声具有较强的鲁棒性。同时作为对比,分别采用文献[5]提出的二次曲面拟合方法和文献[3]提出的主元分析方法度量模型表面变化程度,其结果分别显示在图 7 和图 8 的第 2 行和第 3 行。从对比中可以看出,对于添加了幅值为平均采样间距 50%的零均值随机噪声后的点云数据,二次曲面拟合方法的计算准确度迅速下降,上述情况虽然可以通过增大拟合所用邻域半径加以改善,但是大的邻域半径却导致细节部分的特征被淹没。基于主元分析的方法虽然对噪声表现出一定的抵抗能力,但是当噪声增大到一定程度后,其细节部分的特征仍然被噪声所淹没,同时为了应对噪声水平的变化,必须采用不同的邻域半径进行计算,且邻域半径与噪声水平之间并不呈现出线性关系。而采用 PCPNET 的特征线提取方法在不同噪声水平下均很好地反映了模型的细节特征。图 7 和图 8 的第 4 列是对第 3 列潜在特征点进行细化后的最终特征线。从对比中可以看出,在噪声情况下,无论是所提取特征线的数量还是单条特征线的完整

程度,基于 PCPNET 的特征线提取结果都是最理想的。



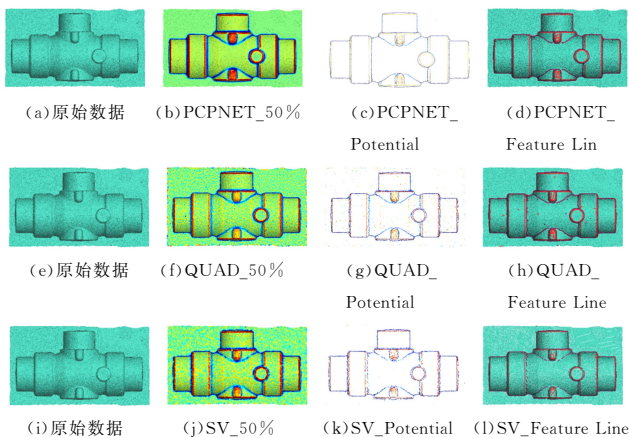
注:第 1 行为 PCPNET 计算结果,第 2 行为二次曲面计算结果,第 3 行为 PCA 计算结果;第 1 列为无噪声点云,第 2 列为添加 0.5 倍采样间距噪声后的计算结果,第 3 列为利用根据在最大主曲率方向上主曲率取得极值的点的特征点提取结果,第 4 列为特征线提取结果

图 7 Cad-fandisk 模型特征计算

Fig. 7 Feature calculation of Cad-fandisk

图 9 给出了将 PCPNET 应用于实际扫描点云的处理结果。如图 9(a)所示,由于数据来源于线结构光扫描,且扫描装置运动间隔远大于单条扫描线的点密度,因此,整体数据呈现出明显的非均匀采样特征,同时,受环境光等因素的干扰,数据中不可避免地包含了测量噪声。经过计算,图 9(b)所示数据平均采样间距为 0.06 mm,噪声水平 0.125 mm。从结果

来看,PCPNET 克服了噪声和非均匀采样因素的影响,计算结果很好地反映了模型的特征。图 9(c)给出了计算出的特征点,最终的特征线提取结果如图 9(d)所示。可以看到,在噪声和非均匀采样情况下,模型中的棱线仍然得到了完整、准确的提取,本文算法能够完整提取出 Fish 点云模型的眼睛特征。



注:第 1 行为 PCPNET 计算结果,第 2 行为二次曲面计算结果,第 3 行为 PCA 计算结果;第 1 列为原始数据,第 2 列为添加 0.5 倍采样间距噪声后的计算结果,第 3 列为利用根据在最大主曲率方向上主曲率取得极值的点的特征点提取结果,第 4 列为特征线提取结果

图 8 Cad-Workpart 模型特征计算

Fig. 8 Feature calculation of Cad-Workpart




图 9 Fish 模型特征线提取结果

Fig. 9 Feature line extraction results of Fish model

在 Venus 和 Fish 点云模型上统计不同噪声水平和非均匀采样情况下特征线位置的变化,不同噪声下模型特征线提取如图 10 所示,同时将本文算法与文献[29]算法在添加 50%噪声的点云数据下进行比较,结果如图 10(d)所示。

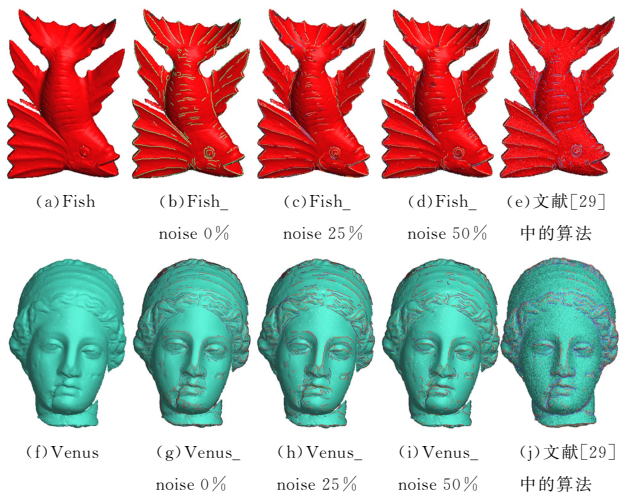


图 10 Fish 和 Venus 模型在不同噪声下基于 PCPNE 的特征线提取结果

Fig. 10 PCPNE feature line extraction results of Fish and Venus models under different noises

可以看出本文算法在噪声情况下提取出的特征线更加完整和有序,说明本算法对噪声更具有鲁棒性。两种算法误差结果如表 2 所列。图 11 给出了采用本文算法对 Armadillo 模型进行特征线提取的结果,并且也和文献[29]中的算法进行了对比。结果证明,本文算法对复杂模型的特征线提取依旧有较好的结果。同时消除了因为非均匀采样而形成断线的现象,提取的特征线也更加完整。

表 2 不同噪声下特征线偏移误差

Table 2 Characteristic line offset error under different noises

模型	Fish (noise 0.25)	Fish (noise 0.5)	Venus (noise 0.25)	Venus (noise 0.5)
误差	0.0184	0.0530	0.0274	0.0371



(a)原始数据 (b)PCPNET (c)初始特征点 (d)特征线提取 (e)文献[29]中的算法

图 11 Armadillo 模型特征线提取结果

Fig. 11 Feature line extraction results of Armadillo model

结束语 本文将 PCPNET 应用到特征线的提取中。算法首先利用 PCPNET 对点云曲率和主曲率方向进行估算,然后利用脊谷点是在最大主曲率方向上主曲率取得极值的点,采用加权二次曲线拟合局部曲率分布,并通过求取二次曲线极值点位置实现脊谷点的识别,最后完成特征线的提取。实验证明,本文的方法在处理复杂特征、噪声和非均匀采样时取得了很好的效果,能够完整地提取出特征线。

参考文献

- [1] GERHARD H B, RUWEN S, REINHARD K. Deteting holes in point set surfaces[J]. Journal of WSCG, 2006, 14(1): 1213-1220.
- [2] ATTENE M, FALCIDIENO B, ROSSIGNAC J, et al. Sharpen-bend: Recovering curved sharp edges in triangle meshes produced by feature-insensitive sampling[J]. IEEE Trans. Vis. Comput. Graph, 2005, 11(2): 181-192.
- [3] SCHEIDEGGER C E, FLEISHMAN S, SILVAC T. Triangulating point set surfaces with bounded error[C]// Proceedings of Symposium on Geometry Processing. 2005: 63-72.
- [4] ALEX M, BEHR J, COHEN O D, et al. Computing and rendering point set surfaces[J]. IEEE Trans. Vis. Comput. Graph, 2003, 9(1): 3-15.
- [5] FLEISHMAN S, COHEN O D, SILVA C T. Robust moving least-squares fitting with sharp features [J]. ACM Trans. Graph, 2005, 24(3): 544-552.
- [6] GARLAND M, HECKBERT P S. Surface simplification using quadric error metrics[C]// Proceedings of ACM SIGGRAPH. 1997: 209-216.
- [7] JONES T R, DURAND F, DESBRUN M. Non-iterative, feature preserving mesh smoothing [J]. ACM Trans. Graph, 2003, 22(3): 943-949.
- [8] DESBRUN M, MEYER M, SCHRODER P et al. Implicit fairing

- of irregular meshes using diffusion and curvature flow[C]// Proceedings of ACM SIGGRAPH. 1999:317-324.
- [9] HOPPE H. New quadric metric for simplifying meshes with appearance attributes [C] // Proceedings of IEEE Visualization. 1999:59-66.
- [10] GUMHOLD S, WANG X, Mcleod R; Feature extraction from point clouds[C]// Proceedings of the 10th International Meshing Roundtable. Los Alamitos; IEEE Computer Society Press, 2001, 293-305.
- [11] DEMARSIN K, VANDERSTRAETEN D, VOLODINE T, et al. Detection of closed sharp edges in point clouds using normal estimation and graph theory[J]. Computer Aided Design, 2007, 39(4): 276-283.
- [12] PAULY M, KEISER R, GROSS M. Multi-scale feature extraction on point-sampled surfaces[J]. Computer Graphic Forum. 2003, 22(3), 281-289.
- [13] LI B, SCHNABEL R, KLEIN R, et al. Robust normal estimation for point clouds with sharp features [J]. Computers & Graphics, 2010, 34(1): 94-106.
- [14] WANG X C, LIU X P, LI B J, et al. Feature detection on point cloud via local reconstruction[J]. Journal of Computer Aided Design & Computer Graphics, 2013, 25(5): 659-665.
- [15] PANG X F, PANG M Y, XIAO C X. An algorithm for extracting and enhancing valley-ridge features from point sets[J]. Acta Automatica Sinica, 2010, 36(8): 1073-1083.
- [16] KIM S K, KIM C H. Finding ridges and valleys in a discrete surface using a modified MLS projection [J]. Computer Aided Design, 2005, 37(14), 1533-1542.
- [17] KIM S K. Extraction of ridge and valley lines from unorganized points[J]. Multimed. Tools Appl, 2013, 63(1), 265-279.
- [18] WEBER C, HAHMANN S, HAGEN H, et al. Sharp feature preserving MLS surface reconstruction based on local feature line approximations[J]. Graphic Models, 2012, 74(6), 335-345.
- [19] QUENTIN M, MAKS O, LEONIDAS G. Voronoi-based curvature and feature estimation from point clouds[J]. IEEE Trans. on Visualization and Computer Graphics, 2011; 17(6): 743-756.
- [20] DANIELS J II, HALK, OCHOTTA T et al. Spline-based feature curves from point-sampled geometry[J]. The Visual Computer, 2008, 24(6), 449-462.
- [21] ENKHBAYAR A, YUTA M, KATSUTUGU M et al. Feature line extraction from unorganized noisy point clouds using truncated fourier series[J]. The Visual Computer, 2013, 29(6), 617-626.
- [22] EVANGELOS K, DEREK N, PATRICIO S et al. Extract lines of curvature from noisy point clouds[J]. Computer-Aided Design, 2009, 41(4): 282-292.
- [23] PARK M K, LEE S J, LEE K H. Multi-scale tensor voting for feature extraction from unstructured point clouds[J]. Graphical Models, 2012, 74(4): 197-208.
- [24] WEBER C, HAHMANN S, HAGEN H. Sharp feature detection in point clouds[C]// Proceedings of the Shape Modeling International Conference. Los Alamitos; IEEE Computer Society Press, 2010, 175-186.
- [25] GUERRERO P, KLEIMAN Y, OVSIJANIKOV M. PCPNET: Learning Local Shape Properties from Raw Point Clouds[J]. Computer Graphics Forum, 2018, 2(37): 75-85.
- [26] PAULY M, GROSS M, KOBBELTL P. Efficient simplification of point-sampled surfaces[C]// Proceedings of IEEE Visualization. Los Alamitos; IEEE Computer Society Press, 2002: 163-170.
- [27] YAGOU H, OHTAKE Y, BELYAEV A. Mesh smoothing via mean and median filtering applied to face normals[C]// Proceedings of Geometric Modeling and Processing-Theory and Applications. 2002: 124-135.
- [28] CHARLES R Q, SU H, KAICHUM M, et al. Pointnet: Deep learning on point sets for 3D classification and segmentation [C]// CVPR. 2017: 77-85.
- [29] NIE J H. Extracting feature lines from point clouds based on smooth shrink and iterative thinning [J]. Graphical Models, 2016, 84: 38-49.



YU Meng-juan, born in 1997, postgraduate. Her main research interests include discrete geometric processing and so on.



NIE Jian-hui, born in 1984, Ph.D, associate professor, postgraduate supervisor, is a member of China Computer Federation. His main research interests include geometric processing and optical measurement.