

文章编号 1004-924X(2015)09-2666-11

特征保持点云数据精简

袁小翠, 吴禄慎*, 陈华伟

(南昌大学 机电工程学院, 江西 南昌 330031)

摘要: 由于三维扫描设备采集的点云数据庞大, 本文提出了一种特征保持的点云精简方法以在减少冗余数据的同时更好地保持原始曲面的几何特征。首先, 利用 K 均值聚类法在空间域对点云全局聚类, 对点云构建 K-d 树并以 K-d 树的部分节点作为初始化聚类中心。然后, 用主成分分析法估计点云法矢和候选特征点, 遍历每个聚类, 若类中包含特征点则将该类细分为多个子类, 细分时将聚类映射到高斯球。最后, 基于自适应均值漂移法对高斯球上的数据进行分类, 高斯球上的聚类结果对应为空间聚类细分结果, 各聚类中心的集合为精简结果。以多个实物模型为例验证了算法的有效性。结果表明, 本文方法精简的点云在平坦区域保留少数点, 在高曲率区域保留更多的点。相比于非均匀网格、层次聚类、K 均值点云精简法, 该方法对包含尖锐特征的曲面精简误差最小, 更好地保留了原始曲面的几何特征。

关键词: 点云精简; 主成份分析; K 均值聚类; 均值漂移; 高斯映射

中图分类号: TP391.7 **文献标识码:** A **doi:** 10.3788/OPE.20152309.2666

Feature preserving point cloud simplification

YUAN Xiao-cui, WU Lu-shen, CHEN Hua-wei

(School of Mechanical and Electrical Engineering,
Nanchang University, Nanchang 330031, China)

* Corresponding author, E-mail: wulushen@163.com

Abstract: 3D scanning devices generally produce a large amount of dense points. This paper presents a feature preserving point cloud simplification method to reduce redundant points while preserving original geometric features well. Firstly, K-mean clustering algorithm was employed to globally gather similar points in a spatial domain. By constructing a K-d tree structure for the point cloud, some nodes of the K-d tree were used as initial clustering centroids. Then, normal vector of point cloud and candidate feature points were estimated with principal component analysis method. Traversing every cluster, if feature points were contained in the cluster, the cluster was subdivided into a series of sub-clusters and the cluster was mapped to a Gaussian sphere. Finally, adaptive mean shift algorithm was employed to classify the data in Gaussian sphere and the clusters in Gaussian sphere were corresponded to the sub-clusters in the spatial domain. The cluster centroids present the simplification data. Several real object models were used to verify the effectiveness of the proposed method. The experiment results demonstrate that the proposed method generates sparse sampling points in flat areas and high density points in high curvature regions. As comparing with the non-uniform grid, hierarchical agglomerative, and K-means methods, the proposed method obtains the

收稿日期: 2015-03-30; 修订日期: 2015-06-03.

基金项目: 国家自然科学基金资助项目 (No. 51365037, No. 51065021)

smallest simplification error and preserves original geometric features.

Key words: point cloud simplification; principal component analysis; K-mean clustering; mean shift; Gauss mapping

1 引言

三维扫描技术已广泛应用于产品设计、制造和质量评估^[1]。三维数据采集一般有接触式测量^[2]和非接触式测量^[3]。接触式测量采集的数据更准确,但是采集速度慢,不适用于大型、复杂的物体。相反,非接触式数据采集设备(如三维激光扫描仪、结构光扫描仪)采集速度快,能够用于各种大型、复杂物体的数据采集^[4-5]。然而,非接触式扫描设备获取的点云数据密度大,不仅占用了大量的存储空间,而且影响点云后续处理速度,例如点云拼接,曲面重构等。因此,数据精简是点云处理必不可少的一步。

点云精简的方法大致可以分为两种:一种是三角面片简化法^[6],另一种是直接点云精简法或者三角面片和直接点云相结合的简化法。三角面片简化法需要将点云重构成三角面片,并通过减少冗余的三角面片达到简化目的,然而构造三角形需要花费大量的运算时间,复杂度大。直接点云精简法无需对点云进行三角化处理,精简速度更快,效率更高,受到越来越多的关注。

直接点云简化法主要根据点云的微分信息和几何信息对点云进行若干次划分,选取合适的点代表局部区域点,或者计算点到其邻域点拟合平面的距离,根据最小距离或者点的最大冗余度逐步删除多余点。Martin^[7]等人将图像处理中的中值滤波原理应用于点云精简中,提出了均匀网格法,其原理是通过建立一种均匀网格,将点云分配到相应的网格中,在分配到同一个给定网格的所有点中,选择一个中值点来表示所有属于这个单元格的点。均匀网格简化法没有考虑特征点,简化后的点云丢失了曲面的细节特征。Lee^[8]等在均匀网格划分的基础上加入了点云法矢偏差,提出了非均匀网格简化法。具体为当网格中的点云法矢偏差大于给定阈值时对网格进行再次划分,直到网格中点云法矢偏差小于阈值。非均匀网格法在平坦区域保留少数点云,在特征区域保留更多的点云。相比均匀网格法,非均匀网格简化法能更好地保留曲面的几何形状。周煜^[9]等人结合

八叉树编码技术和平均曲率对点云精简,当立方体中点云平均曲率小于用户给定阈值时删除对应的点,对于大于阈值的立方体需再次进行划分,迭代删除平均曲率较小的点。Alexa^[10]等人提出了移动最小二乘点云精简法,对点云的邻域构造移动最小二乘平面,计算点到其拟合平面的距离,通过删除最小距离点来达到精简的目的,但是该方法不能保留曲面的特征点。Song^[11]等人改进了Alexa^[10]的方法,先检测曲面的特征点,迭代删除点到拟合平面距离最小的点。该改进方法虽能够保留特征点,但是较耗时。Pauly^[12]等人将三角面片简化法中的层次聚类法,区域生长法应用到直接点云精简中。Song^[13]等人采用全局聚类算法对点云进行精简,以最小化几何偏移为目的(即使输入点云和精简后点云的误差最小)选取合适的聚类中心代表每一类。Miao^[14]等人提出了曲率相关点云精简法,采用自适应均值漂移法对点云在空间域和特征域进行聚类。Shi等人^[15]提出了自适应K均值精简法,K均值聚类法对点云空间聚类,遍历各个类,若类内的法矢偏差大于用户给定阈值时将该类细分成两类,迭代判断各类内法矢偏差并细分为两类,直到类内的法矢偏差小于给定阈值,最后,对平坦区域的聚类保留聚类中心,对非平坦区保留法矢偏差最大的点。Shi^[15]在其实验中指出相比于曲率相关点云精简方法^[14],K均值聚类精简法的精简误差更小。

点云精简的难点在于如何删除冗余点的同时保留原始模型的几何特征。在平坦区域,如平面,可以一个或者少数点代表局部区域;在非平坦区域,如两个曲面交接处的高曲率区域,若以一个点代表局部区域会造成局部曲面体积收缩,丢失曲面的细节特征,曲面重建时难以恢复原始曲面的尖锐特征。本文采用多种方法相结合对3D点云精简,使精简后的点云模型能更好地保留原始曲面的尖锐特征,精简误差更小。本文点云精简的主要内容有:用主成分分析法(Principal Component Analysis, PCA)估计点云法矢和尖锐特征点,用K均值对点云空间聚类,非平坦聚类高斯映射,并采用自适应均值漂移法对高斯图分类。

2 本文方法

2.1 K 均值法空间聚类

点云 K 均值聚类的目的是将点云分成若干个子集,使子集中的点在空间上相似。K 均值聚类的关键在于聚类中心初始化,聚类结果依赖于初始化聚类中心。最简单的聚类中心初始化方法是随机选取 K 个数据作为初始聚类中心,但聚类结果不稳定。为了避免 K 均值聚类结果不稳定,提出了 k-means++ 方法^[16],k-means++ 与 K 均值的主要区别是初始化聚类中心的选择,k-means++ 选取初始化聚类中心的原则是使每个聚类中心距离最大。当数据需要划分的类较少时,k-means++ 方法一般能获得满意的结果,但当初始化聚类中心数目较大时,k-means++ 初始化方法耗时较多。由于点云数量从几万到几百万不等,需要快速准确的初始化方法。此外,为了使点云聚类时快速收敛,初始化的聚类中心最好能均匀分布在模型的各处。因此,可以在局部邻域内选取一个点作为初始化聚类中心。K-d 树是一种快速邻域查找法,本文对点云数据构建 K-d 树,以 K-d 树的部分节点作为初始化聚类中心。本文采用的 K-d 树聚类中心初始化伪代码如算法 1 所示。

算法 1:聚类中心初始化伪代码

输入:点云数据 $P = \{p_i, i=1, 2, \dots, n\}$ (n 为点云的数量),点云的 K 邻域
 输出: s 个聚类中心 $C = \{c_i, i=1, 2, \dots, s\}$
 对输入点云构建 K-d 树
 For $i=0$ to n do
 If p_i 是非标记点
 寻找 p_i 的 K 邻域,并将其 K 邻域点设为已标记点
 End if
 p_i 作为其中一个聚类中心点
 End for

K 均值聚类过程如图 1 所示,其中,图 1(a) 是兔子模型,图 1(b) 是 K-d 树初始化的聚类中心,可以看出初始化得到的聚类中心均匀分布在点云模型的各处,再次利用 K-d 树最近点搜索策略,将点云中的各个点归入欧氏距离最近的聚类中,通过多次迭代,直到各个聚类中心变化小于 ϵ , ϵ 为容差。图 1(c) 为 K 均值全局聚类结果,局部区域中一种颜色表示一个聚类。

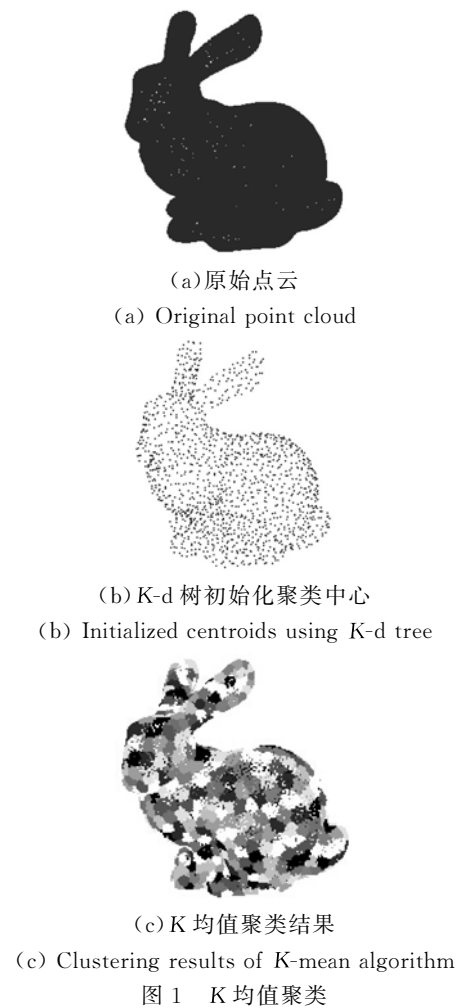



Fig. 1 K-mean clustering for point cloud

2.2 PCA 方法估计法矢及特征点

法矢估计的目的是将非平坦聚类映射为高斯图,将包含特征点的聚类细分为多个子聚类。文献中有许多点云法矢估计方法,大致分为基于回归方法和基于 Delaunay 方法。基于回归方法由 Hoppe 等人^[17]首次提出称为 PCA 法矢估计法,此方法假设点云的采样表面处处光滑,用点云邻域拟合平面,平面的法矢对应点的法矢。在平坦区域,PCA 方法能比较准确地估计点云的法矢,在高曲率区域如两个曲面的交界处,点的 k 近邻或者固定距离邻域点各向同性,即特征点的 k 邻域位于两个或者多个曲面上,使估计的法矢被平滑。图 2 为点云法矢估计示意图,图 2 中红色点表示特征点,蓝色点表示特征点的邻域点(彩图见期刊电子版),图 2(a) 中特征点的邻域各向同性,其邻域点位于两个面,拟合的平面如虚线所示,特征点的法矢被平滑,而且特征点的法矢与平坦区域的法矢偏差较大。为了更准确的估计点云法

矢, 提出了各向异性邻域(即点的邻域只位于一个连续曲面上)拟合法矢, 如文献[18-19], 图 2(b)特征点的邻域只位于一个曲面上, 特征点的法矢几乎垂直于所在曲面, 而且略等于其邻域点的法矢。本文的目的不在于求解准确的点云法矢, 相反, 利用 PCA 方法求解得到的特征点处的法矢不同于平坦区域的法矢, 对非平坦区域进行高斯映射时, 特征点映射为高斯球上不同于平坦点的聚类。



(a)PCA 方法估计法矢

(a)Normal vectors estimated by PCA method


$$C = \frac{1}{k_1} \sum_{i=1}^{k_1} (p_i - u)(p_i - u)^T = \frac{1}{k_1} \begin{bmatrix} p_1 - u \\ p_2 - u \\ \vdots \\ p_{k_1} - u \end{bmatrix} \begin{bmatrix} p_1 - u \\ p_2 - u \\ \vdots \\ p_{k_1} - u \end{bmatrix}^T, p_i \in P. \quad (1)$$

协方差矩阵 C 定义了局部曲面的几何信息, 其为一个对称的半正定矩阵。 C 被分解为 3 个特征向量: v_2, v_1, v_0 。3 个特征向量对应的特征值分别为 $\lambda_2, \lambda_1, \lambda_0$, 其中 $\lambda_2 \geq \lambda_1 \geq \lambda_0$ 。最小特征值所对应的特征向量 v_0 即为局部曲面的法向量。

最小特征值 λ_0 表示点沿着曲面法矢的变化情况, 因此可以利用各点的最小特征值的变化来估计高曲率区域。点 p_i 的曲面变化表示为:

$$\omega_i = \frac{\lambda_0}{\lambda_0 + \lambda_1 + \lambda_2}. \quad (2)$$

$\omega_i=0$ 时, p_i 为平面点, ω_i 值越大, 曲面越尖锐。据此可根据 ω_i 值判断点 p_i 是否处于高曲率区域。如果 ω_i 大于给定阈值 Thresh, 则表示点 p_i 处于高曲率区域, 本文称 p_i 为候选特征点。以经典的 Smooth-feature 点云模型为例, PCA 方法估计的法矢和特征点结果如图 3 所示。图 3(b)、(c)分别为点云法矢方向和特征点检测结果(红色线表示法矢方向, 红色点表示特征点)。图 3(d)、(e)为图 3(a)矩形区域的放大。特征点邻域各向异性, PCA 方法估计的法矢在特征点处被平滑, 使得特征点的法矢与平坦区域点云法矢偏差较大, 曲面越尖锐, 特征点法矢与平坦点的法矢偏差越大, 如图 3(e)黑色矩形框内所示。



(b) 准确的点云法矢


(b) Precise normal vectors

图 2 法矢示意图

Fig. 2 schematic of normal vectors


PCA 方法估计法矢: 给定点集 $P = \{p_1, p_2, \dots, p_n\}$, 其中 n 为点云总数, 点 p_i 的最近 k_1 邻域表示为 $Nb(p_i)$, u 表示为邻域 $Nb(p_i)$ 的重心,

$u = \frac{1}{k_1} \sum_{p_i \in Nb} p_i$, 点 p_i 的协方差矩阵 C 定义为:



(a) Smooth-feature 模型

(a) Smooth-feature model



(b) 模型法矢方向

(b) Normal direction of model

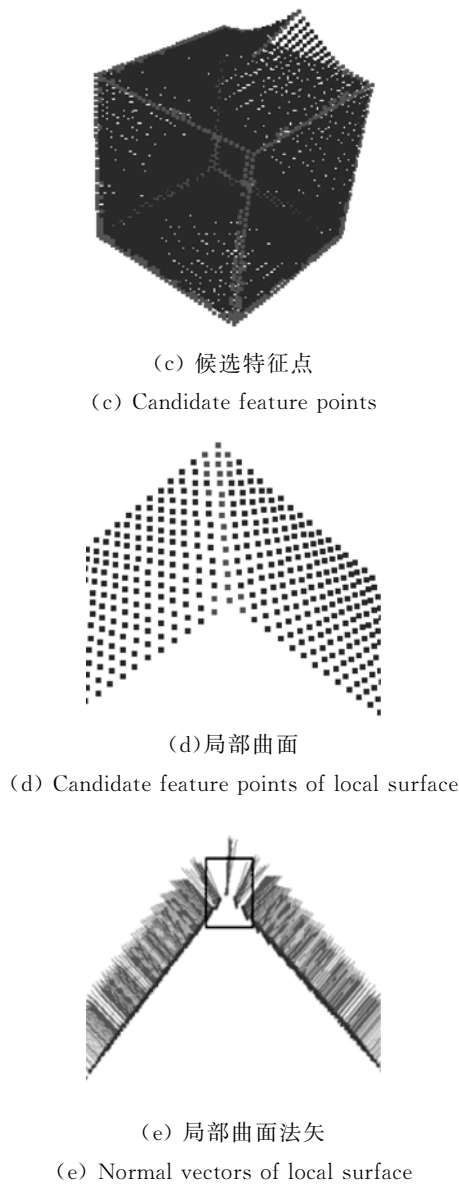


图 3 Smooth-feature 模型候选特征点及法矢

Fig. 3 Candidate feature points and normal vectors of Smooth-feature model

2.3 高斯球上自适应均值漂移聚类

点云高斯映射的目的是将非平坦聚类细分为多个子类,使特征点和平坦点形成不同的聚类。设 $T = T(u, v) \subset \mathbb{R}^3$ 为一正则曲面,该曲面的法矢方向一致,将点 $q \in T$ 处曲面的单位法矢量的始端平移到单位球 $T^2 = \{(x, y, z) \in \mathbb{R}^3 \mid x^2 + y^2 + z^2 = 1\}$ 的中心,使表面上的点与球面上的点相对应,这种对应被称为曲面 T 的高斯映射 $G: T \rightarrow T^2$ 。曲面 T 的高斯映射的像记为 $G(T)$,被称作 T 的高斯图,单位球 T^2 则被称为高斯球。如果一连通曲面为平面,则该曲面的高斯图为高斯球

上的一点;反之,如果一连通曲面的高斯图为高斯球上的一点,则该曲面为平面。然而,估计的法矢总是存在误差,平面的高斯图为高斯球上的密集分布的聚类^[20]。

K 均值聚类后,平坦区域的聚类中心可以代替整个簇,但若聚类中包含特征点,以聚类中心代替整个类将造成曲面体积收缩。因此,需将聚类再次细分,细分时聚类可以分为多个平坦区域和特征点,利用 PCA 估计的法矢在特征点处不同于平坦区域,将包含特征点的聚类映射到高斯图。平坦区域的点云映射为高斯图上的多个聚类,特征点映射为独立的一个或者多个聚类。如图 4 所示,图 4(a)为图 3(a)中矩形框内的点云,其曲面为折角面,特征点为两个平面的交叉点,两个不同平面映射为高斯球上的两个聚类,如图 4(b)红色点所示,特征点映射为另一个或者多个聚类,如黑色点所示。对高斯球上的点进行聚类,高斯球上各子聚类对应为空间点云的子聚类。因为无法事先指定聚类细分为多少个子聚类,所以需要使用无参聚类算法对高斯图上的数据进行自动划分。均值漂移算法对特征空间中的样本点进行聚类时,无需指定聚类数目,广泛应用于计算机视觉领域^[21]。本文采用自适应均值漂移算法对高斯图聚类。





图 4 折角面法矢及其高斯球


Fig. 4 Normal and Gaussian sphere of dihedral surface

设 K 均值聚类得到的某一聚类点云表示为 $Q = \{q_i, i=1, 2, \dots, m\}$, 且点集 Q 的点云法矢方向一致。点集 Q 的高斯图表示为 $G(Q) = [x(q), q \in Q] = \{x_i, i=1, 2, \dots, m\}$, $x(q)$ 为点 q 的法矢, x_i 为点集 Q 中第 i 个点的法矢, m 为点集 Q 的点云数目。 $G(Q)$ 为均值漂移聚类算法的输入数据, 则任意一点 x 的均值漂移向量为:

$$m_{g,h}(x) = \left[\frac{\sum_{i=1}^m \frac{1}{h^{d+2}} x_i g\left(\left\|\frac{x-x_i}{h}\right\|^2\right)}{\sum_{i=1}^m \frac{1}{h^{d+2}} g\left(\left\|\frac{x-x_i}{h}\right\|^2\right)} - x \right], \quad (3)$$


其中: $g(x)$ 为核函数, h 为带宽, d 表示空间维数, 此处 $d=3$ 。均值漂移聚类的关键是确定带宽 h , 若 h 值偏大, 产生的聚类数多, 若 h 小, 则聚类数少。由于空间中有些点分布稀疏, 有些点密集, 采用固定的 h 难以满足实际要求, 需要自适应核窗 h , 使每个点 x_i 对应一个 h_i , Mayer^[22] 和 Anand^[21] 等人指出, 当带宽 $h_i = |x_i - x_{i,j}|$ 是一种简单有效的自适应核带宽时, $x_{i,j}$ 为 x_i 的邻域点, 则 $|x_i - x_{i,j}|$ 表示点 x_i 到其邻域点的欧式距离。对于高斯图上任意一点 x_i , 本文取带宽 $h_i = \max_{x_{i,j} \in N(x_i)} (|x_i - x_{i,j}|)$, $N(x_i)$ 为点 x_i 的 k_2 邻域, 采用 Epanechnikov 核^[21] 作为均值漂移聚类的核函数对高斯图上各点执行均值漂移算法, 得到各点的模态, 合并距离最近各模态, 得到高斯图聚类结果, 高斯图上各聚类所对应的点云为局部曲面细分结果。

图 5(a) 为图 3(a) 中矩形区域内点云 K 均值聚类结果, 用 9 种颜色显示 20 多个聚类, 局部区域中一种颜色代表一个聚类。



(a) 二面角 K 均值聚类结果

(a) K-mean clustering results for dihedral surface



(b) 二面角细分结果

(b) Subdivision results for Fig. 5 (a)

图 5 非平坦聚类细分结果

Fig. 5 Subdivision results of non-flat cluster

在高曲率区域, 如图 5(a) 中红色椭圆区域内青色所代表的聚类, 聚类中心不能准确地表示整个曲面, 需将其细分, 自适应均值漂移聚类后得到了图 5(b) 所示的结果, 红色椭圆圈内有多个子聚类, 一种颜色表示为一个聚类, 同一直线上的橙色(特征点)点可以用一个点来代替, 同一直线上的多个黄色点用一个点能准确代替。为了更形象地表示聚类细分过程, 图 6 为局部区域点云细分示意图, 其中颜色相同的点表示同一个聚类。




图 6 非平坦区域点云精简示意图

Fig. 6 Schematic of simplification procedure for point cloud in non-flat region

3 实例应用与分析

为了验证算法的有效性, 对包含尖锐特征边的点云模型进行精简。采用 C++ 语言在 Microsoft visual studio 2008 上实现点云精简算法, 并且调用 OpenGL 库函数显示点云, 实验所用的计算机配置为 Intel Core 2. 30 GHz CPU, 内存为 1. 19GB。

为了评估精简点云的质量, 测量了精简点云与

原始点云的最大误差和平均误差^[15]。

最大误差:

$$\Delta_{\max}(S, S^*) = \max_{q \in S} d(q, S^*). \quad (4)$$

平均误差:

$$\Delta_{\text{ave}}(S, S^*) = \frac{1}{\|S\|} \sum_{q \in S} d(q, S^*), \quad (5)$$

式中 $d(q, S^*)$ 表示原始曲面 S 上采样点 q 到精简点云曲面 S^* 上投影点 q^* 的欧氏距离。

3.1 参数选择

本文点云精简算法中有 4 个参数需要设定,分别为 Thresh, K , k_1 , k_2 。Thresh 为高曲率区域选择阈值, Thresh 需要用户设定, 在本文实验过程中 Thresh 默认为 0.01。 K 为 K 均值聚类算法中 K -d 树聚类中心初始化算法中输入的参数 K 。 K 值决定了精简后点云的数量, K 值越大, 精简后的点云数量越小, K 也需要用户指定。 k_1 用来在 PCA 法估计中拟合平面的邻域大小, k_1 越大, 特征点法矢与平坦点法矢的夹角越小, 反之则夹角越大。在对聚类高斯映射时, 若特征点与平坦点的法矢偏差小, 则不容易将特征点和平坦点区分开, 聚类结果误差大。 Hoppe^[17] 指出 PCA 方法估计点云法矢时邻域大小取 8~32 时比较合适, 本文估计法矢取 k_1

=8。 k_2 为均值漂移算法中的邻域大小, 用来确定核带宽, 当待细分的聚类中包含的数据点小于 6 时, k_2 等于数据点的个数, 否则 k_2 默认为 6。

3.2 精简结果

对包含尖锐特征点的底座和齿轮模型进行精简, 尖锐特征点为两曲面交叉的边界点或者多个曲面交叉的角点。 为了更形象地显示点云模型及精简结果, 将点云三角化显示。 通过测量精简后的点云与原始模型的误差来量化评估精简模型的质量, 选用平均误差与最大误差来定量表征。 底座模型的点云数量为 385×10^3 , 精简到 41×10^3 和 26×10^3 , 精简结果如图 7 所示。 当精简到 41×10^3 时 $\Delta_{\max} = 0.010$, $\Delta_{\text{ave}} = 2.7 \times 10^{-4}$, 精简到 26×10^3 时 $\Delta_{\max} = 0.022$, $\Delta_{\text{ave}} = 1.2 \times 10^{-3}$ 。 齿轮模型点云数量为 424×10^3 , 精简到 43×10^3 及 25×10^3 , 精简结果如图 8 所示, 精简为 43×10^3 时 $\Delta_{\max} = 0.011$, $\Delta_{\text{ave}} = 3.2 \times 10^{-4}$, 精简为 25×10^3 时 $\Delta_{\max} = 0.027$, $\Delta_{\text{ave}} = 1.43 \times 10^{-3}$ 。 从两模型的精简结果可以看出, 本文方法精简的点云在平坦区域保留了少数点云, 在高曲率区域留了较多点, 精简后的模型特征点依然清晰可见, 如图 7~8 矩形框内所示。




Fig. 7 Simplification of foundation model. The first and second rows are point cloud and triangulated model respectively





图 8 齿轮模型精简结果;第一、二行分别为点云和三角化模型

Fig. 8 Simplification of gear model. The first and second rows are point cloud and triangulated model respectively

3.3 算法有效性验证

为了验证算法的有效性,将本文方法与经典的直接点云精简方法进行比较,包括层次聚类^[12],非均匀网格^[8]及文献^[14]的 K 均值聚类精简方法。通过计算不同模型的精简误差来比较几种方法的精简结果。选用两种完全不同的模型进行比较:一种是连接器模型,其点云分布均匀,曲面相交的过渡边比较平缓;另一个是铸件模型,为散乱点云,过渡边比较尖锐。两模型点云数量分别为 $180 \times 10^3, 290 \times 10^3$ 。图 9 是连接器精简比例为 1/10 的结果,图 10 是铸件模型精简比例为 1/15 的结果。从图 9、10 可以看出本文方法及非均匀网格简化法在高曲率区域保留了较多点,平坦区域保留少数点,K 均值聚类法精简后的点云

分布比较均匀,高曲率区域不保留大量的点。对于连接器模型,层次聚类法得到的精简误差最大,K 均值方法的最大误差最小,本文方法与非均匀网格的最大误差接近,但是本文方法得到的平均误差最小。对于包含尖锐特征的铸件模型,本文方法的精简误差远小于其他 3 种。此外,本文对两模型进行不同比例精简的精简误差如图 11、12 所示。对过渡边比较平缓的连接器模型,当精简比例不大时,如比例小于 1/20 时,除了层次聚类法,其他 3 种方法的精简误差相接近。对于铸件模型,当精简比例较小时(1/5),几种方法的误差近似相等,当精简比例增大时,本文的精简误差远小于其他 3 种方法,而且随着精简比例增大,本文得到的精简误差变化较小,其他方法的精简误差变化大。



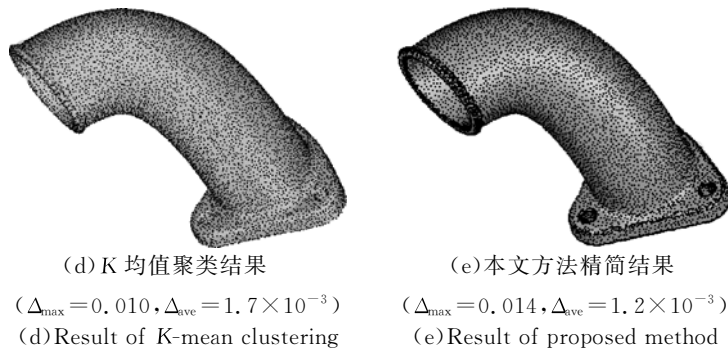


图 9 连接器模型精简结果比较

Fig. 9 Simplification of connector model

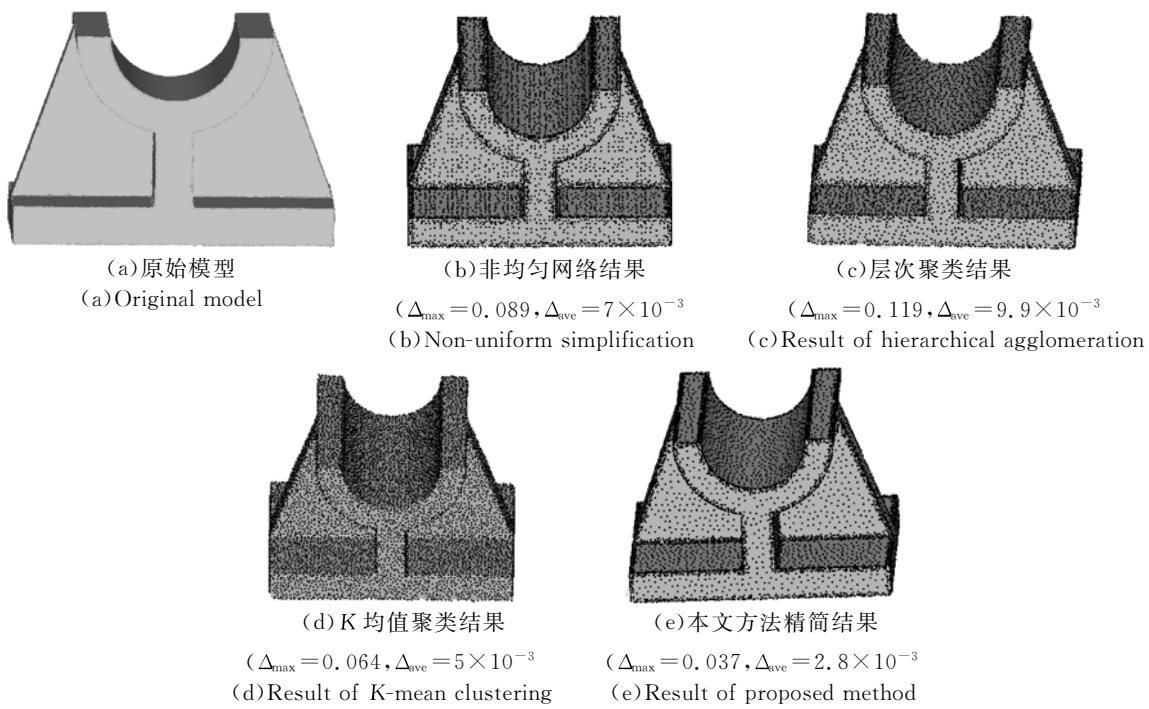


图 10 铸件模型精简结果比较

Fig. 10 Simplification of cast model




图 11 连接器模型的精简误差比较

Fig. 11 Comparison of simplification errors for connector model




图12 铸件模型的精简误差比较

Fig. 12 Comparison of simplification errors for cast model

4 结 论

本文研究了一种特征保留的点云精简方法。以各向异性邻域拟合点云法矢,使得特征点的法矢与平坦点的法矢偏差较大;采用K均值对点云空间进行全局聚类,在平坦区域以聚类中心代表整个类,对包含特征点的聚类细分为多个子类,以各子类的聚类中心代替该类;细分时将聚类映射到高斯球,同一连续曲面的点映射为高斯球上的一个聚类,特征点映射为独立于平坦点的多个聚类;自适应均值漂移法在高斯球上对数据聚类,高斯球上各子类对应为空间聚类细分的子类。精简

后的点云在平坦区域保留少数点,在高曲率区域保留更多的点。将本文方法与非均匀网格,层次聚类,K均值聚类精简方法进行了对比。结果显示,当曲面过渡边比较平缓时,本文精简的最大误差略小于K均值方法得到的精简误差;当曲面的过渡边比较尖锐时,本文的精简误差(包括平均和最大误差)远小于其他3种,更好地保持了原始曲面的尖锐特征。


本文方法对封闭曲面的点云精简能获得较满意的效果,但对于非封闭曲面精简会丢失一部分边界信息,因此下一步工作会考虑完善非封闭曲面模型的精简。

参考文献:

- [1] 李磊刚,梁晋,唐正宗,等. 用于工业三维点测量的接触式光学探针[J]. 光学精密工程, 2014, 22(6):1477-1485.
LI L G, LIAN J, TANG ZH Z, *et al.*. Optical and contact probe for industrial measurement of 3-D points [J]. *Opt. Precision Eng.*, 2014, 22(6): 1477-1485. (in Chinese)
- [2] XIE F, ZHAO J, JU F. The point cloud collection of the incisor teeth of beaver and re-construction of its curved surface [J]. *Advanced Materials Research*, 2012, 426:387-390.
- [3] DEFISHER S, BECHTOLD M, MOHRING D. A non-contact surface measurement system for free-form and conformal optics [C]. *SPIE Defense, Security, and Sensing*, 2011, 8016: 80160W-1-80160W-6.
- [4] MIAN S H, MANNAN M, AL-AHMARI A. Accuracy of a reverse-engineered mould using contact and non-contact measurement techniques [J]. *International Journal of Computer Integrated Manufacturing*, 2015, 28(5):419-436.
- [5] 史金龙,钱强,庞林斌,等. 大尺度钢板的三维测量和拼接[J]. 光学精密工程, 2014, 22(5):1165-1170.
SHI J L, QIAN Q, PANG L B, *et al.*. Three-dimensional measurement and registration for large scale plates [J] *Opt. Precision Eng.*, 2014, 22(5): 1165-1170. (in Chinese)
- [6] MAGLO A, COURBET C, ALLIEZ P, *et al.*. Progressive compression of manifold polygon meshes[J]. *Computers & Graphics*, 2012, 36(5): 349-359.
- [7] MARTIN R, STROUD I, MARSHALL A. Data reduction for reverse engineering[J]. RECCAD. Deliverable document 1 COPERUNICUS project. No. 1068. Computer and Automation Institute of Hungarian Academy of Science. January, 1996.
- [8] LEE K, WOO H, SUK T. Point data reduction using 3D grids[J]. *The International Journal of*

- Advanced Manufacturing Technology*, 2001, 18 (3):201-210.
- [9] 周煜, 张万兵, 杜发荣, 等. 散乱点云数据的曲率精简算法[J]. 北京理工大学学报, 2010, 30(7): 785-789.
ZHOU Y, ZHANG W B, DU F R, *et al.*. Algorithm for reduction of scattered point cloud data based on curvature [J]. *Transactions of Beijing Institution Technology*, 2010, 30(7):785-789. (in Chinese)
- [10] ALEXA M, BEHR J, COHEN-OR D, *et al.*. Computing and rendering point set surfaces[J]. *IEEE Transactions on Visualization and Computer Graphics*, 2003, 9(1):3-15.
- [11] SONG H, FENG H Y. A progressive point cloud simplification algorithm with preserved sharp edge data[J]. *The International Journal of Advanced Manufacturing Technology*, 2009, 45 (5-6): 583-592.
- [12] PAULY M, GROSS M, KOBBELT L P. Efficient simplification of point-sampled surfaces[C]. *Proceedings of the conference on Visualization'02*, 2002:163-170.
- [13] SONG H, FENG H Y. A global clustering approach to point cloud simplification with a specified data reduction ratio[J]. *Computer-Aided Design*, 2008, 40(3):281-292.
- [14] MIAO Y, PAJAROLA R, FENG J. Curvature-aware adaptive re-sampling for point-sampled geometry[J]. *Computer-Aided Design*, 2009, 41(6): 395-403.
- [15] SHI B Q, LIANG J, LIU Q. Adaptive simplification of point cloud using k-means clustering[J]. *Computer-Aided Design*, 2011, 43(8):910-922.
- [16] JAIN A K. Data clustering: 50 years beyond K-means[J]. *Pattern Recognition Letters*, 2010, 31 (8):651-666.
- [17] HOPPE H, DEROSE T, DUCHAMP T, *et al.*. *Surface reconstruction from unorganized points* [M]. ACM, 1992.
- [18] 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.
- [19] WANG Y, FENG H Y, DELORME F É, *et al.*. An adaptive normal estimation method for scanned point clouds with sharp features[J]. *Computer-Aided Design*, 2013, 45(11):1333-1348.
- [20] WANG Y, HAO W, NING X, *et al.*. Automatic segmentation of urban point clouds based on the Gaussian map[J]. *The Photogrammetric Record*, 2013, 28(144):342-361.
- [21] ANAND S, MITTAL S, TUZEL O, *et al.*. Semi-supervised kernel mean shift clustering[J]. 2013, 36(6):1201-1215.
- [22] MAYER A, GREENSPAN H. An adaptive mean-shift framework for MRI brain segmentation[J]. *IEEE Transactions on Medical Imaging*, 2009, 28(8):1238-1250.

作者简介:



袁小翠(1988—),女,江西抚州人,博士研究生,2010年于南昌航空大学获得学士学位,2012年于南昌大学由硕士研究生转为硕博连读研究生,主要研究方向为图像处理与逆向工程。E-mail: yuanxc2012@163.com



吴禄慎(1953—),男,江西乐平人,硕士生,教授,博士生导师,1978年于北京航空航天大学获得学士学位,1990年于清华大学获得硕士学位,主要从事面外“moire”法、三维光学图像测量与逆向工程的研究。E-mail: wulushen@163.com

(版权所有 未经许可 不得转载)