

# 一种特征感知的三维点云简化算法

王成福<sup>\*\*</sup>, 耿国华<sup>\*</sup>, 胡佳贝, 张勇杰

西北大学信息科学与技术学院, 陕西 西安 710127

**摘要** 提出一种特征感知的三维点云简化方法。通过构造八叉树搜索每个点的  $k$  近邻点, 并计算每个点的法向量, 以此检测并保留边缘点; 使用期望最大化算法对点云进行聚类, 并确定高曲率的点; 使用边缘感知的有向 Hausdorff 距离方法进行点云精简, 合并前述点云并删除重复点, 实现模型简化。该方法适用于不同曲率变化的模型, 并且能够在保留尖锐特征的同时显示模型整体轮廓。实验结果表明, 该方法不仅能够保留原始模型的几何特征和轮廓外貌, 而且有效地避免了简化过程中的孔洞现象, 几何简化误差较低。

**关键词** 图像处理; 数字博物馆; 三维点云简化; 期望最大化算法; 有向 Hausdorff 距离

中图分类号 TP391.41

文献标识码 A

doi: 10.3788/LOP56.111004

## Feature-Aware Three-Dimensional Point Cloud Simplification Algorithm

Wang Chengfu<sup>\*\*</sup>, Geng Guohua<sup>\*</sup>, Hu Jiabei, Zhang Yongjie

School of Information Science and Technology, Northwest University, Xi'an, Shaanxi 710127, China

**Abstract** In this paper, we propose a simplified method of feature-aware for a three-dimensional point cloud. First, the  $k$ -nearest neighbor points of each point are searched by constructing an octree, and the normal vector of each point is calculated to detect and preserve the edge points. Then, the expectation maximization algorithm is utilized to cluster the point clouds and determine the points with high curvature. Finally, these point clouds are simplified by a method which utilizes the edge-aware directed Hausdorff distance, the above point clouds are merged, the duplicate points are deleted, and thus, the model is simplified. The proposed method is suitable for the models with different curvature changes, and it can display the overall contour of the model while retaining the sharp features. The experimental results show that the proposed method not only preserves the geometric features and contour appearance of the original model, but also effectively avoids the hole phenomenon in the simplification process. The geometric simplification error of the method is considerably low.

**Key words** image processing; digital museum; three-dimensional point cloud simplification; expectation maximization algorithm; directed Hausdorff distance

**OCIS codes** 100.2000; 100.6890

## 1 引言

随着计算机软硬件的更新和发展, 以及网络技术的不断成熟, 数字博物馆技术<sup>[1]</sup>逐渐成为研究热点。数字博物馆具有一些特有功能, 如存储数字化和资源共享等。数字博物馆技术成为文化遗产和自然遗产虚实展示的重要技术手段。通过硬件设备和网络快速获得博物馆展品已经成为研究热点。其

中, 精确有效地对点云数据进行简化和压缩成为虚实展示的关键技术<sup>[2]</sup>。通过三维(3D)扫描仪<sup>[3]</sup>获得的数据非常密集, 数据量庞大。随着 3D 扫描设备精度的提高, 研究人员所获得的数据量增加, 数据冗余现象越来越严重。考虑到数字博物馆的存储技术数字化以及资源共享的功能, 如果不对原始数据进行简化、直接建模, 大量的时间和资源将会被消耗掉, 同时网络传输的负担会不断增加, 数字博物馆的

收稿日期: 2018-11-29; 修回日期: 2018-12-06; 录用日期: 2018-12-25

基金项目: 国家自然科学基金(61731015)、国家重点研发项目(2017YFB1402103)、陕西省产业创新链项目(2016TZC-G-35)、西北大学 2017 研究生自主创新项目(YZZ17182)、青岛市自主创新重大专项(2017-4-3-2-xcl)

\* E-mail: 920759301@qq.com; \*\* E-mail: 976375270@qq.com

用户体验也会变差。

常用的三维模型简化方法可以分为两类:基于网格的简化<sup>[4]</sup>和基于点云的简化<sup>[5-6]</sup>。基于网格的简化需要构造多边形网格,该方法的缺点是需要网格拓扑相互一致,并且其网格生成复杂。基于点云的简化方法不仅可避免存储点的连接信息,减少内存消耗,加快简化速度,还能够保证重建表面的质量。因此,基于点云的简化方法更具优势,已成为研究的热点。

三维点云数据的简化可以分为两大类:基于模型拓扑结构的点云简化和基于特征保留的点云简化。Weir等<sup>[7]</sup>依据体包围盒对点云进行简化,将大包围盒不断拆分成多个大小近似一致的小包围盒,并用小包围盒最靠近中心的点代表整个包围盒中所有点。该方法简单高效,但难以保证简化模型的精度。Shen等<sup>[8]</sup>提出一种特征保留的三维点云简化算法:1)根据点云密度进行下采样;2)在点云下采样后计算平均曲率,得到点云的特征;3)使用区域增长聚类方法根据曲率阈值得到简化点云。该方法不但需要消耗大量时间,而且无法获取更多的全局特征。李仁忠等<sup>[9]</sup>提出了一种散乱点云的均匀精简算法,通过创建一个 $k$ 邻域三维体素栅格,同时结合包围盒法对输入的点云数据进行 $k$ 邻域距离计算和法线估计,以此来确定每个小立方栅格的重心,并用其近似表示小立方栅格内所有数据点。该方法虽然可以达到精简点云的目的,但是在曲率变化明显的区域损失了过多的特征点。Han等<sup>[10]</sup>提出一种基于法向量的边缘保留点云简化算法,但该方法在平坦区域容易产生孔洞。张雨禾等<sup>[11]</sup>提出一种基于局部特征检测算子和潜在曲面平均弯曲度的散乱点云简化算法,在较好地保留原始点云轮廓特征的同时可以简化点云,降低了点云简化误差,但该方法的检测特征点计算量大,比较耗时。Mahdaoui等<sup>[12]</sup>提出一种基于密度函数和香农熵估计的点云迭代简化方法,该算法适用于不同密度的不同点云,简化点云的重建效果接近原始点云模型。袁小翠等<sup>[13]</sup>提出了一种特征点保留的三维点云简化算法,该方法不但可以减少点云,而且能够较好地保持原始曲面的局部和全局特征;但是,该方法在对一些非封闭曲面的特征进行简化时容易失去边界特征。总体来说,现有基于点云的简化方法适用于曲率变化不大、外貌轮廓不复杂的点云模型,并且现有点云简化方法所得的结果无法保留其全局或局部特征信息。

为此,本文提出一种特征保留的三维点云简化方法。通过提取边缘点尽可能地保留点云的全局特征;使用期望最大化算法根据点的局部分布对点云进行聚类,计算平均曲率,确定局部特征点;对非特征点进行边缘感知的点云简化。

## 2 三维点云轮廓提取

点云简化问题可以概括为:假设原始点云模型为 $M$ ,求 $M$ 的一个子集 $P$ ,在满足简化比的条件下,使得子集 $P$ 在删除冗余点的同时能够尽可能地保留全局特征和局部特征。简化比可表示为

$$\eta = \frac{\hat{P}}{\hat{M}}, \quad (1)$$

式中: $\hat{P}$ 为简化点云模型中的点云个数; $\hat{M}$ 为原始点云模型中的点云个数。

三维点云模型简化的目的在于简化点云冗余数据的同时保留模型的几何特征。一般情况下,边缘点云比非边缘点云具有更多的特征,因此应在点云简化过程中保留这些边缘点云处的尖锐点。为此,可通过构造八叉树建立每个点的空间拓扑关系,从而找出每个点的邻近点,逐步检测并提取边缘点<sup>[14]</sup>。

### 2.1 $k$ 邻点的建立与法向量的估计

点云通常是海量且无序的,故需要构造最小空间包围盒来划分空间,并使用八叉树搜索 $k$ 个相邻点<sup>[15]</sup>。空间包围盒的大小为

$$C_{\text{size}} = \max(\Delta x, \Delta y, \Delta z), \quad (2)$$

式中: $\Delta x = x_{\text{max}} - x_{\text{min}}$ ,  $\Delta y = y_{\text{max}} - y_{\text{min}}$ ,  $\Delta z = z_{\text{max}} - z_{\text{min}}$ ,其中 $x_{\text{max}}$ 和 $x_{\text{min}}$ , $y_{\text{max}}$ 和 $y_{\text{min}}$ , $z_{\text{max}}$ 和 $z_{\text{min}}$ 分别是点云 $x, y, z$ 的最大值和最小值。空间包围盒是八叉树的根节点,将空间包围盒平均分成8个小立方体,8个立方体是根节点的叶节点。根据此规则划分每个立方体,直到达到指定的分割级别,如图1所示。八叉树的结构如图2所示。




图1 八叉树的空间分割

Fig. 1 Space segmentation of octree

因此,八叉树具有以下特征:如果八叉树非空,




图 2 八叉树结构  
Fig. 2 Octree structure

那么树中的任何一个节点都没有子节点或有 8 个子节点。如果空间包围盒被划分为  $n$  层,则可以构造一个具有  $n+1$  层的八叉树,每个立方体对应一个唯一节点,每个节点的空间位置编码  $Q$  为

$$Q = q_{n-1} \cdots q_m \cdots q_1 q_0, \quad (3)$$

式中: $q_m$  是八进制数, $m \in \{0, 1, \cdots, n-1\}$ ,表示  $n$  层中的任意一层。如果  $q_m$  表示该节点在其兄弟节点之间的序号,则  $q_{m+1}$  表示  $q_m$  节点的父节点在其同胞兄弟节点间的序号。这样,从  $q_0$  到  $q_{n-1}$  完整地表示出八叉树中的每个叶子节点到树根的路径,如图 2 中黑色节点之间表示的路径,其黑色叶子节点的编码为  $\{12, 67\}$ 。

搜索节点  $p$  的  $k$  邻点(近邻点分为点近邻、边近邻和面近邻),即搜索  $p$  的叶节点最近的  $k$  个节点和  $p$  的相邻叶节点,也就是搜索立方体中的节点(节点  $p$  所在的立方体)及其 26 个相邻立方体,故使用八叉树结构可极大地提高相邻点的搜索速度。

由于某些点云可能不包含法向量信息,故需要计算每个点的法向量。计算点云法向量常用的方法有基于 Delaunay 方法和基于回归方法。本文使用经典的主成分分析(PCA)回归方法来计算点云的法向量。1) 通过最小二乘法将任意点及其相邻点拟合到局部平面;2) 用拟合平面代替原来的局部曲面;3) 点云中某点的法向量可以根据其拟合平面的法向量计算而得。在上述步骤中,点云中的点  $p$  及其  $k$  个相邻点的拟合平面  $F$  为

$$F(n, d) = \arg \min_{(n, d)} \sum_{i=1}^k (n\bar{p} - d_i)^2, \bar{p} = \frac{1}{k} \sum_{i \in N_p} p_i, \quad (4)$$

式中: $n$  是平面  $F$  的法向量; $d_i$  是点  $p$  邻域点到坐标原点的距离; $\bar{p}$  是质心; $N_p$  是点  $p$  的  $k$  个相邻点的集合; $i$  为点序号; $p_i$  是点  $p$  邻域中的任意邻近点。平面  $F$  包含点  $p$ ,法向量  $n$  满足  $|n|^2 = 1$ ,因此该问题简化为一个半正定协方差矩阵  $U$  的特征值分解, $U$  的表达式为

$$U = \frac{1}{k} \sum_{i=1}^k (p_i - \bar{p})(p_i - \bar{p})^T, \quad (5)$$

其最小特征值对应的特征向量即为点  $p$  的法向量估计。

### 2.2 边缘点检测

边缘点检测的步骤为:1) 利用点和法向量的拓扑关系构造最小二乘平面;2) 将拟合平面附近的每个点投影;3) 根据投影的均匀性提取边缘点。均匀性投影的判断标准可以是角度偏差和角度间隔,但二者的计算复杂度高。本文抛弃角度比较的思路,采用坐标值比较。

假设  $p$  是点云中的某点,使用八叉树搜索其  $k$  近邻,构造最小二乘平面并将邻近点投影到平面,创建三个平面  $xpy$ 、 $xpz$  和  $ypz$ ,分别平行于平面  $xoy$ 、 $xoz$  和  $yoz$ 。通过点  $p$ ,将平面  $xpy$ 、 $xpz$  和  $ypz$  作为参考平面,当参考平面两侧的投影数量之差与参考平面两侧投影数量之和的比大于指定阈值时,点  $p$  被判断为边缘点。以点  $p$  和平面  $xpy$  为例,如图 3 所示,平面  $xpy$  上方有 11 个点,平面下方有 4 个点,因此差值与和的比值为  $7/15$ 。




图 3 投影点附近点示意图

Fig. 3 Schematic of neighbor points near projection point

## 3 局部分布的聚类

聚类方法旨在确定小均匀区域中的点集并使点集在空间上相似,在不显著丢失几何特征信息的情况下去除冗余点。聚类过程使用考虑点集的局部分布的期望最大化(EM)算法<sup>[16]</sup>。

EM 算法<sup>[17]</sup>是一种基于概率的聚类算法,类似于  $k$  均值方法。 $k$  均值方法是将  $n$  个对象分成  $k$  个簇(簇内相似度高,簇与簇之间相似度低)。EM 算法扩展了这种基本方法,允许更均匀的聚类生成。通常,EM 算法在每次迭代中具有两个步骤——期望和最大化。在期望步骤中,假设观察到潜在变量,利用算法估计可能性的期望,即对每一个数据点计算其所属聚类的概率,作为权重。在最大化步骤中,计算最大似然值,最大化先前估计的预期可能性,即利用上述计算的权重来估计每个聚类的

均值和方差,进而求取聚类的总体概率或极大似然。新的参数值用于后续的交互,直到算法收敛。

给定变量数据集  $\{x_1, x_2, \dots, x_n\}$  和迭代混合模型的初始参数值  $(w_{0,c}, \mu_{0,c})$ , 其中,  $c$  是  $k$  个初始簇的一个。基本的迭代分组算法步骤如下:

- 1) 在第  $j$  次迭代中计算每个簇中每个点的成员概率。
- 2) 更新混合模型参数。
- 3) 验证是否达到收敛,如果不是,则继续步骤 1 中的第  $j+1$  次迭代。

在第  $j$  次迭代中,对于任意一点  $x_i$ , 簇  $c$  中的成员概率为

$$p(c | x_i) = \frac{w_{j,c} p_j(x_i | c)}{p_j(x_i)}, \quad (6)$$

式中:  $p_j$  表示第  $j$  次迭代中样本所属簇的概率。

如上所述,新参数值为

$$w_{j+1,c} = \frac{1}{n} \sum_{i=1}^n p(c | x_i), \quad (7)$$

$$\mu_{j+1,c} = \frac{\sum_{i=1}^n x_i \cdot p(c | x_i)}{\sum_{i=1}^n p(c | x_i)}, \quad (8)$$

$$\sum_{0,c} = \frac{\sum_{i=1}^n p(c | x_i) (x_i - \mu_{j+1,c}) (x_i - \mu_{j+1,c})^T}{\sum_{i=1}^n p(c | x_i)}. \quad (9)$$

对于收敛验证,使用在第  $j$  和  $j+1$  次迭代中混合模型的对数似然之差。在第  $j$  次迭代中的对数似然度为

$$E_j = \sum_{i=1}^n \lg[p_j(x_i)] = \sum_{i=1}^n \lg \left[ \sum_{c=1}^k w_{j+1,c} \cdot p_j(x_i | c) \right]. \quad (10)$$

如果  $|E_j - E_{j+1}| \leq \epsilon$ , 则达到收敛,否则计算新的迭代,其中  $\epsilon$  表示给定迭代误差阈值。需要注意的是:对于簇的规模来说,随着簇规模的增加,时间以非线性的方式增加。在整个过程中,簇计算是最耗时的阶段,简化步骤是较快的阶段。原始点云和 EM 聚类簇分别如图 4、5 所示。

## 4 曲率计算

点云的曲率<sup>[18-19]</sup>可以反映局部表面的变化程度,它在几何变换(例如平移和旋转)下保持不变,因此也被称为不变量。从几何意义上讲,曲率是切



图 4 原始点云

Fig. 4 Original point cloud




图 5 EM 聚类簇

Fig. 5 EM cluster

向量变化的速率。若  $S(r, t)$  表示一个常规的连续的三维参数曲面,  $S$  上在  $S(r_0, t_0)$  处的主曲率  $k_1(r_0, t_0)$  和  $k_2(r_0, t_0)$  被定义为该点曲率的最大值和最小值。根据欧拉定理,曲面  $S(r, t)$  切平面方向上法线曲率为

$$k_n(\theta) = k_1 \cos^2 \theta + k_2 \sin^2 \theta, \quad (11)$$

式中:  $\theta$  是第 1 主方向与切线方向上的夹角。高斯曲率  $K$  和平均曲率  $H$  是由曲面的主曲率唯一确定的,即

$$\begin{cases} K = k_1 \cdot k_2 \\ H = (k_1 + k_2)/2 \end{cases}. \quad (12)$$

高斯曲率的主要限制是当任何主曲率为零时其等于零。平均曲率的问题在于极小曲面总是具有  $H=0$ 。另一个有利的度量是绝对曲率  $A$ , 其表达式为

$$A = |k_1| + |k_2|. \quad (13)$$

因此,无论曲率类型如何,人们都可以使用最小二乘回归算法进行局部曲面拟合,在给定点拟合曲面,计算曲率  $K$ 、 $H$  和  $A$ 。曲率可以用于描述局部几何变化。因此,为了避免简化尖锐的特征点,在估计点云的曲率时,需要标记估计曲率超过固定阈值的曲率。阈值集通过计算该点所属簇内局部平均曲率的均值来获得。具体来说,估计给定聚类中所有点的平均曲率  $A_i$ , 计算平均曲率的均值  $\overline{A_i}$ , 并满足以下规则:

- 1) 如果  $A_i > \overline{A_i}$ , 表示在点  $i$  处发生表面的显著区域,将此点标记为特征点。
- 2) 如果  $A_i < \overline{A_i}$ , 表示在点  $i$  处是没有尖锐特征平滑区域,此点可以在下一阶段减少。

图 6 显示了原始模型及其曲率估计图(轮廓点和特征点),在简化点云模型过程中,保存这些点可




图6 曲率估计选择的特征点和非特征点。

(a)原始点云;(b)曲率估计点云

Fig. 6 Feature points and non-feature points selected by curvature estimation. (a) Original point cloud; (b) curvature estimation point cloud

以保留边界和几何特征。因此,下一阶段只使用非特征点进行简化。

## 5 基于 Hausdorff 距离的点云简化算法

### 5.1 有向 Hausdorff 距离

在数学中,Hausdorff 距离<sup>[20-21]</sup>测量两个点集之间的距离,可以描述两组点集之间的相似程度。假设有两组集合  $\mathbf{X} = \{x_1, x_2, \dots, x_n\}$ ,  $\mathbf{Y} = \{y_1, y_2, \dots, y_m\}$ , 则这两个点集之间的 Hausdorff 距离定义为

$$H(\mathbf{X}, \mathbf{Y}) = \max[l(\mathbf{X}, \mathbf{Y}), l(\mathbf{Y}, \mathbf{X})], \quad (14)$$

$$l(\mathbf{X}, \mathbf{Y}) = \max_{x_i \in \mathbf{X}} \min_{y_j \in \mathbf{Y}} |x_i - y_j|, \quad (15)$$

式中: $H(\mathbf{X}, \mathbf{Y})$ 称为双向 Hausdorff 距离, $l(\mathbf{X}, \mathbf{Y})$ 和  $l(\mathbf{Y}, \mathbf{X})$ 分别称为从  $\mathbf{X}$  集到  $\mathbf{Y}$  集和从  $\mathbf{Y}$  集到  $\mathbf{X}$  集的有向 Hausdorff 距离。使用有向 Hausdorff 距离(DHD)进行点云简化,如图7所示。假定原始点云  $\{x_1, x_2, x_3, y_1, y_2\}$ , 并且  $N = \{y_1, y_2\}$  表示已经采样的特征点,使用 DHD 从  $M$  中选择一个新的特征点加入  $N$ 。此时,(15)式则可以理解为:1) 分别计算从  $x_1, x_2$  和  $x_3$  到  $y_1$  的欧几里德距离,并保存最近的值  $d_{11}$ ;2) 与第1步相同,分别计算从  $x_1, x_2$  和  $x_3$  到  $y_2$  的距离,并保存最近的值  $d_{32}$ ;3) 比较并选择  $d_{11}$  和  $d_{32}$  之间的最大值。显然,  $d_{32} > d_{11}$ , 因此,将  $x_3$  作为新的采样点,并且将  $N$  更新为  $N = \{y_1, y_2, x_3\}$ 。

DHD 方法是一种从随机种子点开始的增量区




图7 有向 Hausdorff 距离

Fig. 7 Directed Hausdorff distance

域生长方法。本质上来讲,DHD 是一种基于距离的自适应加权方法。与其他简化方法不同的是,在 DHD 中,当前采样点的位置对如何从原始点云中选择新特征点起着至关重要的作用。因为点云的边界点与内点的距离相对较远,所以 DHD 方法对轮廓和角点的采样是非常有效的。

### 5.2 点云简化

综上所述,点云简化算法步骤如下:

- 1) 通过构造八叉树搜索每个点的  $k$  近邻点并计算每个点的法向量。
- 2) 检测边缘点并保留。
- 3) 使用期望最大化算法,根据点的局部分布对点云进行聚类。
- 4) 确定高曲率的点(不会被删除的特征点)。
- 5) 边缘感知的 DHD 点云简化。
- 6) 合并步骤 2、步骤 4 和步骤 5 获得的采样点,删除重复点。

## 6 实验结果和分析

选取斯坦福兔子、椅子和兵马俑(TW)点云模型作为实验对象。斯坦福兔子模型包含弯曲度较大的曲面,椅子模型包含尖锐特征和较平坦区域,兵马俑模型包含曲面和较复杂的特征。为了验证本文点云简化算法的有效性,从简化效果、重建效果和简化速度三方面进行评估,并与曲率自适应方法和  $K$  均值聚类简化方法分别进行对比实验。

### 6.1 简化效果

不同简化率  $\eta$  下的简化效果如图8所示,可以看出,本文算法在有效提取尖锐特征点(簇中高平均曲率的点)的基础上进一步检测并保留了边缘点。两者结合,在简化点云的过程中更好地保留了不同点云模型的轮廓,使三维点云模型的体貌展现得更为真实全面。

### 6.2 重建效果

在简化阶段之后,将特征点集和简化数据集连接起来并去除重复点,形成简化后的点云。图9显示不同点云模型在不同简化率下的重建效果(为了便于展示,对重建模型进行了三角剖分、封装和渲染)。可以看出,随着简化率的减少,简化后的封装模型会失去一些纹理信息和局部细节特征,但封装简化后的模型基本保留了原始模型的几何特征和轮廓外貌(在简化率 20% 以上)。重建效果进一步证明,在不同模型中,基于边缘感知的 DHD 点云简化有效地保留了边界和角点等几何特征。

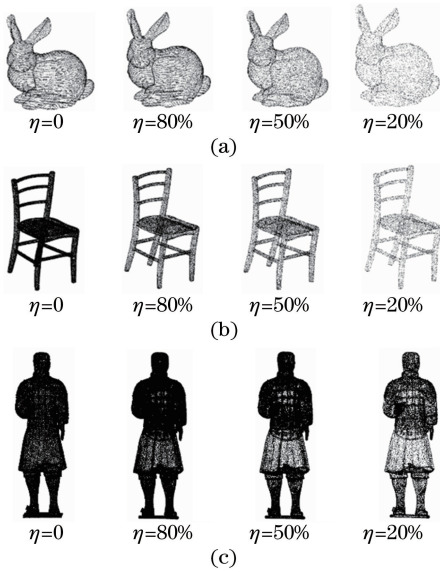


图8 不同点云模型的简化效果。(a)斯坦福兔子;  
(b)椅子;(c)兵马俑

Fig. 8 Simplification effect of each point cloud model.

(a) Bunny; (b) chair; (c) TW

### 6.3 简化速度

整个点云简化过程分为边缘点检测、聚类曲率估计和点云简化三个阶段。采用整个过程的平均时间作为简化速度的评判标准,评估数据如表1所示,E表示边缘点检测,C表示聚类曲率估计,S表示点云简化。由表1可知,在不同简化率下,当簇数不变时,边缘点检测和聚类曲率估计阶段的时间是一致

表1 不同简化率下不同点云模型的简化速度

Table 1 Simplification speed of each point cloud model at different simplification rates

Point cloud model	Original point cloud	Cluster number	Simplification time / ms								
			$\eta=80\%$			$\eta=50\%$			$\eta=20\%$		
			E	C	S	E	C	S	E	C	S
Bunny	35949		125	1063	258	125	1063	493	125	1063	674
Chair	49960	30	83	913	324	83	913	587	83	913	732
TW	349863		1076	10672	3124	1076	10672	5936	1076	10672	8784
Bunny	35949		125	1422	206	125	1422	411	125	1422	578
Chair	49960	50	83	1385	289	83	1385	562	83	1385	694
TW	349863		1076	23625	2937	1076	23625	5464	1076	23625	8293
Bunny	35949		125	2065	197	125	2065	383	125	2065	502
Chair	49960	70	83	1968	264	83	1968	551	83	1968	675
TW	349863		1076	36735	2754	1076	36735	5269	1076	36735	7931

### 6.4 对比实验及误差分析

本文提出一种特征保留的点云简化方法,通过结合EM聚类和曲率估计方法提取局部细节特征。因此,对比实验中,在同等级硬件环境下同曲率自适应简化算法(CAA)和聚类简化方法(CSM)进行对比分析,如表2所示。在相同点云模型和简化比下,

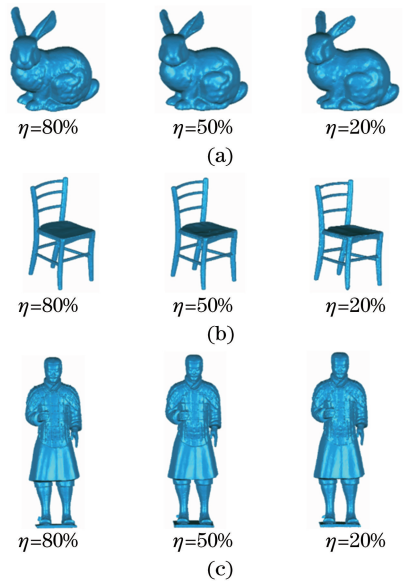


图9 不同简化率下的重建效果。(a)斯坦福兔子;  
(b)椅子;(c)兵马俑

Fig. 9 Reconstruction effect at different simplification rates.

(a) Bunny; (b) chair; (c) TW

的,其简化速度的差异主要集中在点云简化阶段(基本上是一个数量级的)。在相同简化率下,随着簇数的增加,计算成本逐渐增加,简化时间以非线性的方式增加,简化速度也逐渐变慢。随着簇数的增加和简化率的降低,误差逐渐减少,这是可预测的,因为该算法提取出更多的特征点,使拟合曲面误差变小,但时间成本增加。

不同方法的简化时间、最大误差和平均误差的差异进一步验证了本文所提算法的有效性。

## 7 结论

为了满足数字博物馆存储数字化和资源共享等功能的要求,需要精确和有效地对三维点云数据进

表2 同一模型下不同算法简化速度及误差对比

Table 2 Comparison of simplification speed and error for different algorithms under same model

Point cloud model	Simplification ratio /%	Simplified algorithm	Simplified time /ms	Maximum error /( $10^{-4}$ mm)	Average error /( $10^{-4}$ mm)
Bunny	50	CAA	5000	3163	1042
		CSM	<3500	2178	612
		Proposed	<3000	2086	473

行简化,故提出一种结合边缘点保留和EM聚类(允许生成更均匀的聚类)的三维点云简化算法。1)通过构造二叉树搜索每个点的 $k$ 近邻点,并计算每个点的法向量,以此检测边缘点并保留;2)使用期望最大化算法根据点的局部分布对点云进行聚类,并确定高曲率的点;3)使用边缘感知的DHD方法进行点云简化,合并上述点云并删除重复点。该方法可以在曲率较大的地方尽可能保留稠密的点云,在曲率较小的地方仅保留稀疏的点云,在保留原始模型尖锐特征的同时尽可能展示其整体轮廓。重建的简化点云基本保留了原始模型的几何特征和轮廓外貌,实现了较低的几何简化误差。

本文采用基于EM聚类的特征提取方法,因此存在聚类簇数量的估计问题。研究一种生成更均匀的聚类簇的方法和解决聚类簇数量的自动估计方法将是未来研究的重点。

### 参 考 文 献

- [1] Zhou M Q, Geng G H, Wu Z K. Digital museum [M] // Zhou M Q, Geng G H, Wu Z K. Digital Preservation Technology for Cultural Heritage. Berlin, Heidelberg: Springer, 2012: 207-233.
- [2] Pan Z G, Cheok A D, Yang H W, *et al.* Virtual reality and mixed reality for virtual learning environments[J]. Computers & Graphics, 2006, 30(1): 20-28.
- [3] Yang B S, Liang F X, Huang R G. Progress, challenges and perspectives of 3D LiDAR point cloud processing [J]. Acta Geodaetica et Cartographica Sinica, 2017, 46(10): 1509-1516.  
杨必胜, 梁福逊, 黄荣刚. 三维激光扫描点云数据处理研究进展、挑战与趋势 [J]. 测绘学报, 2017, 46(10): 1509-1516.
- [4] Ko M C, Choy Y C. 3D mesh simplification for effective network transmission [C] // 5th IEEE International Conference on High Speed Networks and Multimedia Communication (Cat. no.02EX612), July 3-5, 2002, Jeju Island, South Korea. New York: IEEE, 2002: 284-288.

- [5] Chen X J, Zhang G, Hua X H. Point cloud simplification based on the information entropy of normal vector angle [J]. Chinese Journal of Lasers, 2015, 42(8): 0814003.  
陈西江, 章光, 花向红. 于法向量夹角信息熵的点云简化算法 [J]. 中国激光, 2015, 42(8): 0814003.
- [6] Sareen K K, Knopf G K, Canas R. Contour-based 3D point cloud simplification for modeling freeform surfaces [C] // 2009 IEEE Toronto International Conference Science and Technology for Humanity (TIC-STH), September 26-27, 2009, Toronto, ON, Canada. New York: IEEE, 2009: 381-386.
- [7] Weir D J, Milroy M J, Bradley C, *et al.* Reverse engineering physical models employing wrap-around B-spline surfaces and quadrics [J]. Proceedings of the Institution of Mechanical Engineers, Part B: Journal of Engineering Manufacture, 1996, 210(2): 147-157.
- [8] Shen Y H, Li H Y, Xu P. Simplification with feature preserving for 3D point cloud [C] // 2015 8th International Conference on Intelligent Computation Technology and Automation (ICICTA), June 14-15, 2015, Nanchang, China. New York: IEEE, 2015: 819-822.
- [9] Li R Z, Yang M, Liu Y Y, *et al.* An uniform simplification algorithm for scattered point cloud [J]. Acta Optica Sinica, 2017, 37(7): 0710002.  
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): 0710002.
- [10] Han H Y, Han X, Sun F S, *et al.* Point cloud simplification with preserved edge based on normal vector [J]. Optik-International Journal for Light and Electron Optics, 2015, 126(19): 2157-2162.
- [11] Zhang Y H, Geng G H, Wei X R, *et al.* Point clouds simplification with geometric feature reservation [J]. Journal of Computer-Aided Design & Computer Graphics, 2016, 28(9): 1420-1427.  
张雨禾, 耿国华, 魏潇然, 等. 保留几何特征的散乱点云简化算法 [J]. 计算机辅助设计与图形学学报, 2016, 28(9): 1420-1427.
- [12] Mahdaoui A, Bouazi A, Hsaini A M, *et al.* Entropic

- method for 3D point cloud simplification [M] // Ben Ahmed M, Boudhir A. Innovations in Smart Cities and Applications. Cham: Springer, 2018: 613-621.
- [13] Yuan X C, Wu L S, Chen H W. Feature preserving point cloud simplification [J]. Optics and Precision Engineering, 2015, 23(9): 2666-2676.  
袁小翠, 吴禄慎, 陈华伟. 特征保持点云数据精简 [J]. 光学精密工程, 2015, 23(9): 2666-2676.
- [14] Liu Y, Wang C Y, Gao N, *et al.* Point cloud adaptive simplification of feature extraction [J]. Optics and Precision Engineering, 2017, 25(1): 245-254.  
刘迎, 王朝阳, 高楠, 等. 特征提取的点云自适应精简 [J]. 光学精密工程, 2017, 25(1): 245-254.
- [15] Huang Y, Da F P, Tang L. Three-dimensional point cloud compression algorithm based on improved octree [J]. Acta Optica Sinica, 2017, 37 (12): 1210003.  
黄源, 达飞鹏, 唐林. 基于改进二叉树的三维点云压缩算法 [J]. 光学学报, 2017, 37(12): 1210003.
- [16] Kaulbersch H, Baum M, Willett P. An EM approach for contour tracking based on point clouds [C] // 2016 IEEE International Conference on Multisensor Fusion and Integration for Intelligent Systems, September 19-21, 2016, Baden-Baden, Germany. New York: IEEE, 2017:529-533.
- [17] Jin X, Han J W. Expectation maximization clustering [M] // Sammut C, Webb G. Encyclopedia of Machine Learning and Data Mining. Boston, MA: Springer, 2016: 1-2.
- [18] Tian Q, Wang Y M, Zhang R J. Segmentation for point cloud on the grid-based clustering of curvature [J]. Journal of Beijing University of Civil Engineering and Architecture, 2008, 24(4): 22-25.  
田庆, 王晏民, 张瑞菊. 基于网格化曲率聚类的点云分割 [J]. 北京建筑工程学院学报, 2008, 24(4): 22-25.
- [19] Ma W F, Zhou X H, Xu W X, *et al.* A point cloud reduction method based on local curvature feature [J]. Engineering of Surveying and Mapping, 2015, 24 (11): 13-16, 21.  
麻卫峰, 周兴华, 徐文学, 等. 一种基于局部曲率特征点云精简算法 [J]. 测绘工程, 2015, 24(11): 13-16, 21.
- [20] Knauer C, Löffler M, Scherfenberg M, *et al.* The directed Hausdorff distance between imprecise point sets [J]. Theoretical Computer Science, 2011, 412 (32): 4173-4186.
- [21] Wu J M, Han X, Li D Z, *et al.* Point cloud simplification based on angle of inter-normal and Hausdorff distance [J]. Microelectronics & Computer, 2014, 31(4): 52-55.  
武敬民, 韩燮, 李定主, 等. 基于法向夹角与 Hausdorff 距离的点云精简方法研究 [J]. 微电子学与计算机, 2014, 31(4): 52-55.