

文章编号 1004-924X(2017)01-0245-10

特征提取的点云自适应精简

刘 迎, 王朝阳, 高 楠, 张宗华*

(河北工业大学 机械工程学院, 天津 300130)

摘要:作为一种反映物体形貌的三维信息,点云数据的原始数据量十分庞大,直接对过多的数据进行操作会影响后续重建等工作。本文提出了一种新的点云特征提取自适应精简算法。首先对原始点云进行空间划分,构建点的 k 邻域,设置特征参数,进行特征分析,识别不同区域的信息和数据。然后针对平面数据预先进行边界的检测和提取,对剩余部分进行精简。最后,针对非平面区域,先提取特征,再根据曲率的不同进行不同程度的精简。办公室数据扫描实验结果表明,处理大小为百万以内点的点云模型可以在几秒之内完成,精简比能够达到 90% 以上,与原始数据间的误差较小:平面部分在精简前后平均偏差均在 0.02 mm 以内,波动很小,为 0.005 7 mm;非平面区域精简前后的平均偏差均在 0.08 mm 左右,差值仅为 0.000 3 mm,精简精度得以保证。因此,利用提出的算法处理后的数据能更好地展示物体的形貌。

关键词:点云精简;自适应精简; k 邻域;面拟合

中图分类号:TH741;TP311.1 **文献标识码:**A **doi:**10.3788/OPE.20172501.0245

Point cloud adaptive simplification of feature extraction

LIU Ying, WANG Chao-yang, GAO Nan, ZHANG Zong-hua*

(College of Mechanical Engineering, Hebei University of Technology, Tianjin 300130, China)

* Corresponding author, E-mail: zhzhangtju@hotmail.com, zhzhang@hebut.edu.cn

Abstract: Point cloud data, as a kind of three-dimensional information reflecting the object shape, have quite a large amount of original data, so if directly operating on excessive data, it will affect subsequent work such as point clouds reconstruction, etc. This paper proposes a novel adaptive simplification algorithm for point cloud feature extraction. First, space should be divided with respect to the original point cloud, and then k neighborhood of the point should be built, and feature parameters should be set up, and then feature analysis should be conducted, and finally information and data of different parts should be identified. Then, for the planar data, the boundary is detected and extracted and the remaining parts are simplified. Finally, for the nonplanar data, the feature is extracted and then simplifications are implemented in varying degrees according to different curvatures. Experiments show that it takes no more than several seconds to process a point cloud model with almost a million points. Simplification proportion can reach above 90%, and the error corresponding to original data is smaller: the average deviation of the planar data is less than 0.02 mm before and after simplification, with a small fluctuation at 0.005 7 mm; the average deviation of the nonplanar data is likely to fluctuate around 0.08 mm and the difference is only 0.000 3 mm before and

收稿日期:2016-06-12;**修订日期:**2016-08-02.

基金项目:国家自然科学基金资助项目(No. 51675160, 61171048);河北省应用基础研究计划重点基础研究资助项目(No. 15961701D);河北省高层次人才资助项目(No. GCC2014049);河北省人才工程培养经费资助项目(No. A201500503)

after simplification, guaranteeing the simplification accuracy. Therefore, the data processed by proposed algorithm can display the object shape better.

Key words: point cloud simplification; adaptive simplification; k neighborhood; surface fitting

1 引言

获取点云数据的方法很多,其中光学三维扫描设备以其精度高、速度快等优势成为该行业中的佼佼者^[1]。通常,原始点云数据量十分庞大,在实际应用中只需通过其中一部分数据就能代表整个形象,很多数据信息是不必要的,因此需要对其进行精简处理^[2]。


比较经典的精简方法有:包围盒法,随机采样法,聚类法。包围盒法^[3-5]要先选一个大的包围盒体把所选取的点云数据包围起来,接着再把这个大的包围盒划分成多个大小均匀的小盒体,并找到小盒的中心点,再将每个小盒中所有的数据点都用其对应的中心点来代替。该算法原理简单,易于实现,而且对均匀分布点云数据的精简处理效果较好。但该算法缺点也较显著,由于包围盒的大小是人为设定的,中心点通过计算得到,而且有可能不是原数据中的点,所以点云的精简精度不能够得到保证。随机采样法首先要建立一个可以容纳点云范围尺寸的随机函数,由用户设定待处理点云的精简比,通过该函数连续产生随机数。之后根据随机数去寻找将要被删除的点,达到精简比后整个过程结束。该方法原理简单,操作容易,精简速度也很快。但随机性较大,不能够保证数据精度,一般会作为其他算法的辅助方法。聚类法是将点云数据中具有某种相似性的点聚集为多个类,再利用一些比较简单的精简方法对子类进行处理。根据聚类方式的不同,这种方法可分为区域增长聚类法和层次聚类法^[6]。由于在一个有限的空间里,如果点云比较密集,那么其点与点之间的距离就相对较小,而对应的平均距离也就较小,根据这一原理,万军等人提出了平均点距法^[7]。这种方法精简处理速度快、效率比较高,适用于大量散乱的三维数据,但是对密度变化大的点云数据的处理效果较差。黄承亮等提出了对包围盒法的改进,具体做法是将包围盒法中的中心点用其重心点来代替^[8],这样能够保证点云数据处理的准确性,并且能更好地保证模型的整体性。由于点云边界数据^[9]是展现三维模型整体形貌最

直观的部分,并且曲率在一定程度上还可以反映点云各处的分布情况,某点的曲率越大,则其越可能是特征点,精简程度应当越小。但是,这些算法大多采用同一尺度对点云的不同区域进行处理,对于不同的场合(例如变化不均匀)的点云模型其处理效果均不太理想,会出现局部空洞现象。针对以上不足,本文提出了点云特征提取的自适应精简算法:通过设置特征参数,进行特征分析,提取点云特征,之后对非特征区域根据曲率进行不同程度的精简。

2 基本原理

2.1 点云边界提取

点云边界点大多是边缘特征数据,因此在精简点云数据之前需要先提取点云的边界。通过对局部点阵进行统计分析可以找出边缘数据。先对点云进行 k 邻域^[10,11]搜索,计算每个点的 k 邻域各点到该点的距离,从而得到对应的局部平均距离。接着,对这些值进行统计,得到标准差,平均距离在标准范围的点就认为是边缘点。判断标准是通过标准差和点云的全局平均距离来定义的。根据上述准则,在编译器中实现边界提取的功能。在程序中,保留了两个可变参量,邻域值 k 和标准差倍数阈值 ρ ,用于设置不同的边界参数。假如规定 μ 为估计的平均距离, σ 为标准差,此时如果点云中各点与其邻域的距离大于 $\mu \pm \sigma \cdot \rho$,那么就把该点当成边界点提取出来。如图 1 是对一个手掌的点云数据在 $k=50$ 、 $\rho=0.1$ 时提取出来的边界。



(a)原始点云 (b)手掌边界
(a)Original point cloud (b)Palm boundary

图 1 手掌模型
Fig. 1 Palm model

2.2 点云特征点识别与提取

一个点云数据中能有效反映物体形貌的部分除了边界特征以外,还有内部特征点。为了使精简后的数据能更逼近原型,需要对内部特征点进行识别和提取,保留足够的特征^[12]。

2.2.1 局部平均距离

局部平均距离是指一个点云中各点与其邻域内所有点的欧式距离平均值。邻域的选取方式种类很多,这里继续采用 k 邻域的方式。Amenta^[13]和 Andersson^[14]已经证实这种邻域估计相比一般方式更可靠。点云中任意一点 q 的 k 邻域写成点集的形式为 $\omega(q_i)(i=1,2,\dots,k)$ 。此邻域仅与 q 点有关,每个点的邻域和其它点的邻域均无关,即所有点的邻域两两之间互不相关。对任

$$\mathbf{H} = \mathbf{P} = \frac{1}{k} \sum_{i=1}^k (q_i - \bar{q})(q_i - \bar{q})^T, \mathbf{P} \cdot \boldsymbol{\mu}_m = \lambda_m \cdot \boldsymbol{\mu}_m, m \in \{0,1,2\}, \quad (2)$$

其中: k 为点 q_i 的近邻点个数, \bar{q} 为其邻域点集的三维重心, λ_m 是矩阵 \mathbf{P} 的第 m 个特征值, $\boldsymbol{\mu}_m$ 为 λ_m 对应的特征向量。每个特征值可定义为对应特征向量方向上度量局部曲面的变分。总变分可表示为邻域内数据点 q_i 到 \bar{q} 距离的平方和,则:


$$\sum_{q_i \in \omega(q_i)} |q_i - \bar{q}|^2 = \sum_{m=0}^2 \lambda_m. \quad (3)$$

经过上述矩阵分析,求解的 \mathbf{P} 的最小特征值对应的特征向量即被看作是点 q 的估计法向量 \mathbf{n} 。这里假设 $\lambda_2 \geq \lambda_1 \geq \lambda_0$,则 $\mathbf{n} \approx \boldsymbol{\mu}_0$ 。利用这种估计,可得到点云的法向模型。

2.2.3 曲率计算

在上述法向量求解过程中,说明了特征值表示曲面沿各自特征向量方向上的变化。 λ_0 表示的是沿法向量方向的变化, λ_1 和 λ_2 描述的则是邻域内各点分布在切平面上的情况。于是可以定义 φ 为点 q 在其邻域 $\omega(q_i)$ 的曲面变分:

$$\varphi = \frac{\lambda_0}{\lambda_0 + \lambda_1 + \lambda_2}. \quad (4)$$



(a)原始点云
(a)Original point clouds


一点 q 的 k 邻域计算局部平均距离如下:

$$d(q) = \frac{1}{k} \sum_{i=1}^k |q_i - q|. \quad (1)$$

局部平均距离作为特征参数的一部分,该值越大表示此点是特征点的可能性就越高。

2.2.2 点云表面法向估计

点云表面法向量是表征物体形貌的重要几何特性^[15]。法线估计常用基于局部表面拟合的方法^[16-17]来实现。其思路是先找寻点云的局部邻域切平面,点云中一点的法向量可通过估计其局部切平面的法线得到。首先对点云中每个点 $q(x, y, z)$ 建立其 k 邻域 $\omega(q_i)$,再由拟合平面代替原来的局部曲面,最后利用主元分析法就可近似得到点的法向量,由此得式(2):



(b)曲率模型

(b)Curvature model

图 2 天鹅模型

Fig. 2 Swan model

点云表面任意点处的曲率 cur 可通过其邻域的曲面变分近似得到,于是 $cur_i \approx \varphi_i$ 。图 2(彩图见期刊电子版)为天鹅模型,其中(a)为原始模型,(b)为对应的曲率模型。所对应曲率按点的颜色从绿、黄、蓝到红的顺序依次增大,从结果图上可以直观看出曲率与特征点的关系。

2.2.4 特征提取

局部平均距离和曲率是点云形貌特征的重要参数。如果一点的局部平均距离越小,曲率越大,则认为其更有可能是特征点。定义点云特征参数 $\delta = \alpha \cdot cur_i / d(q)$,其中 α 是特征系数。点云模型的数据密度和尺寸是影响特征判断的参数,因此特征阈值就可以根据二者的大小来设置。其中数据密度可以由模型的空间深度来衡量。利用八叉树对点云空间进行划分,其叶子节点的平均对

角线长度 τ 作为点云模型的空间平均深度。而点云尺寸可以通过模型中的点到中心点的最大距离 d_{mc} 来表示,于是定义特征阈值 $\gamma = \tau/d_{mc}$ 。这样根据特征参数与阈值的关系就能判断点云中的一点是否处于特征区域。也就是说一点的特征参数大于阈值,则认为该点是特征点,反之就是非特征点。

用本文的方法提取椅子点云模型特征,如图 3 所示。原始点云中有 249 974 个点,这里各参数设置为 $\alpha = 15$, $d_{mc} = 0.286\ 604$, 阈值 $\gamma = 1.841\ 902$,提取的特征点个数为 14 968。特征点云如图 3(b)所示,其中模型中弯曲程度变化部位以及有棱角的部分都作为特征区域被保留下来。

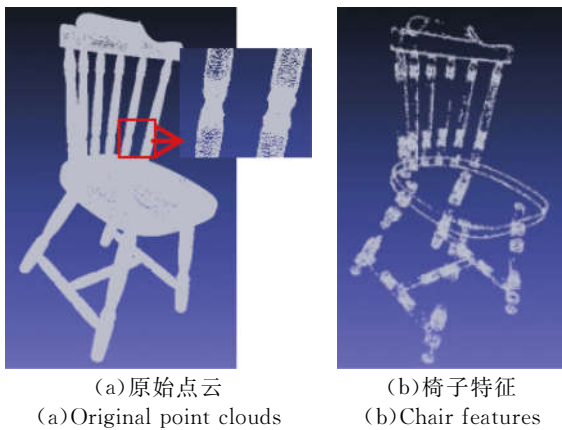


图 3 椅子模型
Fig. 3 Chair model

2.3 点云精简

一个点云数据各处的分布效果是不一样的。有的部分比较平滑而有的部分的变化则比较剧烈,曲率大小反映了分布效果的不同。如果采用同一个标准对整个点云数据进行精简,则很有可能造成特征点的缺失,很多细节点也会被精简掉。而且对曲率大的部分做大程度精简也会产生局部空洞现象。这样精简既不利于物体形貌的充分展示,又会丧失细节及精度。针对此类问题,本文提出点云曲率自适应精简算法。

精简之前首先对点云数据进行曲率计算。按照 2.2 节的方法先对点云进行法向估算进而得到各点的曲率值,这样便得到带曲率数据的点云。精简原则是对待处理点云进行包围盒划分。大盒分成尺寸不同的小盒,每个小盒中的所有点用其重心点代替。算法的重点有两个,一是设置不同

尺寸的盒,二是重心点的获取。尺寸的设置,根据曲率不同,小盒的尺寸相应变化。在曲率较大的区域,盒的尺寸较小;在曲率较小的区域,盒的尺寸较大。重心点是距离中心点最近的那个点。只要找到中心点的位置,通过计算就能确定重心点。

假设任一小盒中包围了 n 个点,用点集表示为 $Q(q_i)$ ($i=1, 2, \dots, n$), 一点的坐标记为 $(q_{i,x}, q_{i,y}, q_{i,z})$, 中心点 q_{mid} 坐标记为 $(Q_{mid,x}, Q_{mid,y}, Q_{mid,z})$, 可用式(5)表示:

$$\begin{cases} Q_{mid,x} = \sum_{i=1}^n q_{i,x}/n \\ Q_{mid,y} = \sum_{i=1}^n q_{i,y}/n \\ Q_{mid,z} = \sum_{i=1}^n q_{i,z}/n \end{cases} \quad (5)$$

盒中每个点到中心点的距离 d_{q_i} 由式(6)得到:

$$d_{q_i} = \sqrt{(q_{i,x} - Q_{mid,x})^2 + (q_{i,y} - Q_{mid,y})^2 + (q_{i,z} - Q_{mid,z})^2} \quad (6)$$

通过计算比较便得到离中心点最近的那个点 Q_g , 也就是每个小盒的重心点。

在这里把曲率分为多个等级,平面处的数据是一类,非平面处是另一类。在非平面处划分多个曲率区间。利用上述精简原则,曲率越高的区间,点云部分的精简程度越小,反之亦然。为了更好地展现物体形貌,保留更多的特征信息。在以上提出的点云曲率自适应精简算法的基础上,对算法进行了改进,即点云特征提取的自适应精简算法。该算法能够弥补经典算法中的某些不足,例如边界信息的保留和特征点的识别及提取等。这种方法在满足精简度的情况下,能够更有效地体现出目标物的形貌特征。

三维点云特征提取的自适应精简算法思路如下:首先将三维模型分割成不同的区域,包括平面点云和非平面点云;依据曲率信息又将非平面点云分成几个不同的等级;之后对各平面区域进行边界提取,对非平面点云提取特征点;保存所有的边界信息以及特征点,对提取边界或特征点后剩余的点云进行不同程度的精简;最后通过数据拼接把边界信息、特征信息和精简后的点云保存为最终精简的点云模型。精简算法的整体流程见图 4,具体分为两个模块:平面点云处理部分和非平面点云处理部分。它们的处理流程分别如图 5 和 6 所示。

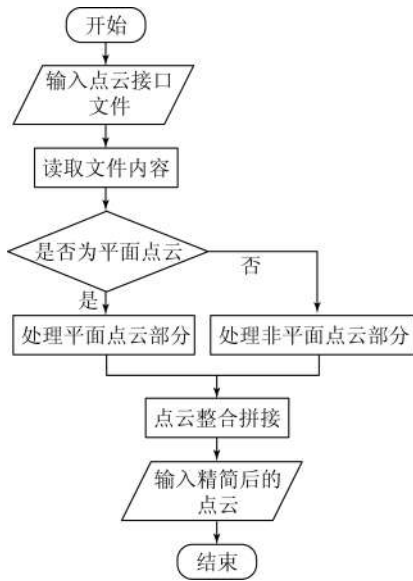


图 4 点云特征提取的自适应精简算法流程图

Fig. 4 Flowchart of adaptive simplification algorithm for feature extraction

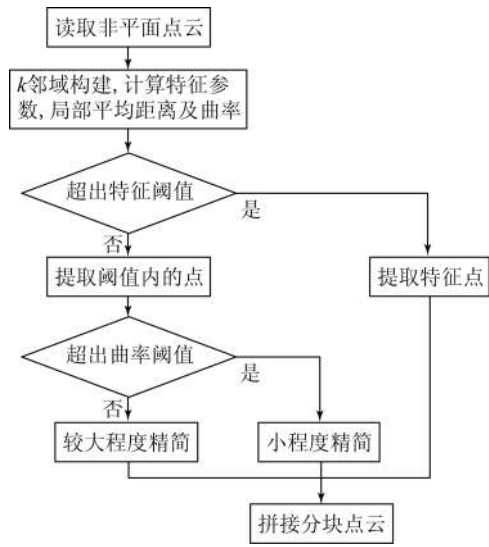


图 6 处理非平面点云流程

Fig. 6 Processing for nonplanar point cloud

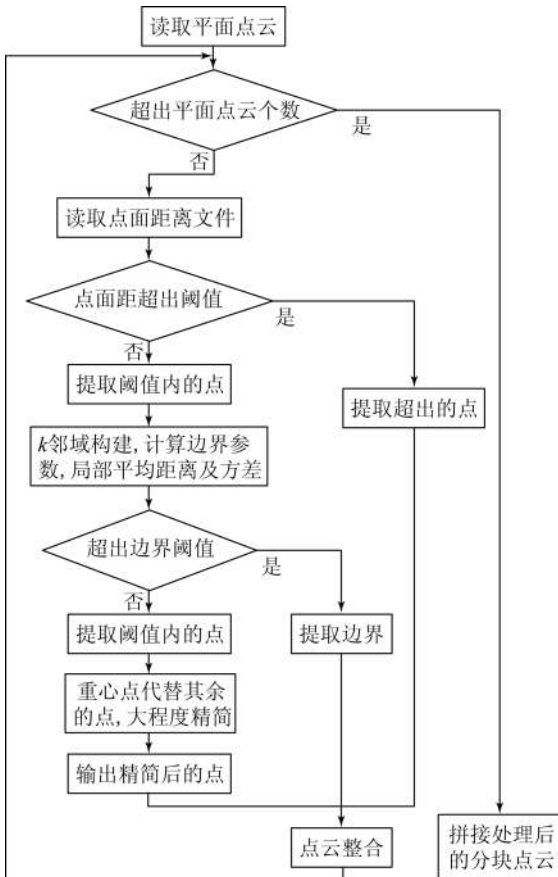


图 5 处理平面点云流程

Fig. 5 Processing for plane point cloud

3 实验及结果分析

3.1 自适应算法精简


通过一台 Kinect^[18] 设备对一间办公室形貌进行扫描。图 7(a)是办公室一角,其点云形貌信息如图 7(b)所示。在此角度看到的是办公室的外貌,由于点云太过密集,导致很多细节信息看不到,这也是要对点云数据进行精简的一个重要原因。



(a)办公室一角
(a) A corner of office



(b)精简前
(b) Before simplification



(c)精简后
(c) After simplification

图 7 办公室点云数据

Fig. 7 Office point cloud data

办公室三维形貌数据的原始点数为 687 万。数据精简是在一台 2.80 GHz 处理器、2.00 GB 内存、32 位操作系统的台式机上进行的。整个精简过程用时大约 1 min。精简后的点云个数变为 14 万,大大减少了数据的冗余度,提高了视图的可视性。图 7(c)为通过本文方法得到的精简结果图。

为了看的比较清楚,截取了一个角落(带有窗户、桌子和凳子的视图)。不妨将凳子放大,如图 8(彩图见期刊电子版)所示,其中图 8(a)为精简前原始数据,图 8(b)为精简后的形貌。可以看到,精简后凳子表面等平滑区域的点数明显减少,而变化剧烈的区域如凳子腿处点数保留的则相对多些。

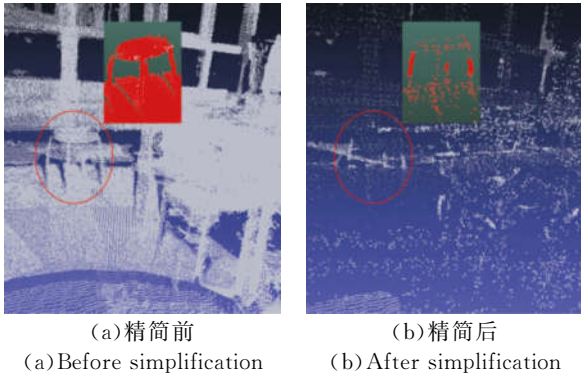


图 8 特征提取的自适应精简结果

Fig. 8 Results of adaptive simplification for feature extraction

为了更好地体现本文算法的精简效果,对几组点云模型进行精简处理,结果如图 9~11 所示。从结果图来看,几个点云模型经本文算法处理后,精简效果都很好,在很大程度上简化了原始数据,并保持了较多的特征细节。




图 9 兔子点云

Fig. 9 Rabbit point cloud




图 10 天鹅点云

Fig. 10 Swan point cloud



图 11 椅子点云

Fig. 11 Chair point cloud

3.2 几种算法的精简对比

为了更进一步说明本文算法的处理效果,对两个不同的点云模型(一间办公室点云和椅子点云)分别采用多种方法处理,包括经典的和近几年较流行的方法。

(1) 一间办公室点云

对上一小节中的办公室模型分别采用区域重心法、平均点距法、曲率自适应法和特征提取的自适应精简法进行处理。把对办公室点云的几个处理结果中的一个凳子提出来对比。为了从视觉上看起来更明显,将其用红色渲染,如图 12(彩图见期刊电子版)所示,其中图 12(a)是精简前的原始模型。

从结果图中可以看出,几种不同精简算法的处理结果有很大差异。区域重心法精简后各区域精简比较均匀,特征点缺失比较多,特征保留的不够明显,如图 12(b)所示;平均点距法的精简结果

中特征点缺失比较集中,容易造成局部区域的空洞现象,对后续三维重建不利,如图 12(c)所示;而曲率自适应精简算法则可以呈现出不同程度的精简效果,曲率大的地方点云比较密集,曲率小的区域点云比较稀疏,如图 12(d)所示;特征提取的自适应精简算法既保留了曲率自适应法的优势,而且还保留了特征信息,使物体的形貌信息展示的更为全面,如图 12(e)所示。

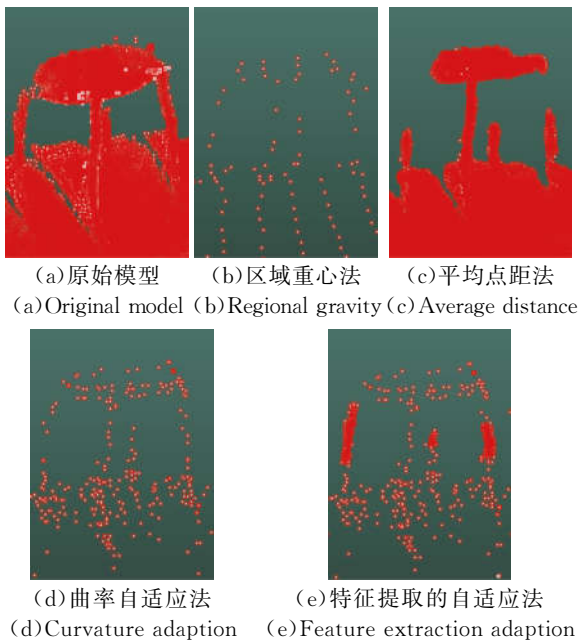


图 12 几种精简方法的精简结果

Fig. 12 Several kinds of simplification experiment results

(2)椅子点云模型

椅子模型的原点云数据共有 249 974 个点,通过几种不同的精简算法对其处理,包括聚类法、包围盒法、区域重心法、随机采样法、曲率自适应法、特征提取的自适应精简法。定义精简比为精简掉的点数与原始点数的比值,将其保持在 95%左右,图 13 为实验结果,图 13(a)为原始模型。

从对椅子模型的精简结果来看,各算法处理后,都可以保持模型的整体样貌。但有的丧失了一些重要的细节,尤其在精简比较大的时候,很难保证点云的数据特征。随机采样的结果没有很强的规律性,如图 13(b)所示。包围盒法与区域重心法的结果都比较均匀,如图 13(c)和(d)所示,在比较平坦的区域还是存在很多的冗余信息。聚类法呈现出一定的层次性,椅子突变处的特征部分丢失,如图 13(e)所示。本文两种方法的处

理结果如图 13(f)和(g)所示,两种方法均能更大程度地去冗余并有效保留点云特征。

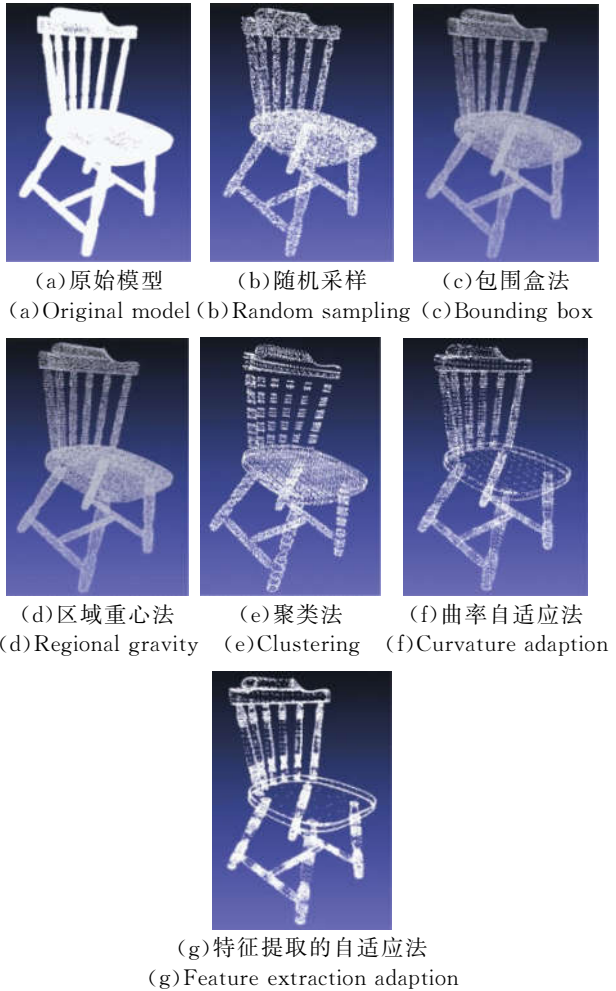


图 13 不同算法实验精简结果

Fig. 13 Experiment results of different algorithms

一种精简算法性能好坏通常要从 3 个维度进行判定,即速度、简度和精度^[19]。为了验证本文精简算法的有效性,首先在精简速度和简度两方面进行验证,评估数据结果见表 1 和表 2。平面上的点云数据精简精度可以通过判断精简前后的平面误差来实现,如计算点云与其拟合平面的点距,对比它们之间的几何偏差;对于非平面区域的点云数据,采用球体拟合法进行精度验证,即分别拟合精简前后的球面三维点云数据,对比点云到其拟合球体的几何偏差。评估数据如表 3 和表 4。

综合表 1 和表 2,可以看出点云模型越庞大精简耗时越长,处理百万以内点的模型本文算法可以在几秒内完成,且其与几种常见算法的处理

速度也在同一等级,能够满足点云处理的一般要求。

表 1 本文算法对不同模型的精简速度和简度数据

Tab. 1 Simplification speed and simplified degree data of proposed algorithm on different models

| 模型 | 房屋 | 椅子 | 兔子 | 天鹅 |
|-------|-----------|---------|--------|--------|
| 原始点数 | 6 877 509 | 249 974 | 31 607 | 18 603 |
| 精简后 | 141 385 | 15 798 | 5 816 | 7 823 |
| 精简比/% | 97.9 | 93.7 | 81.6 | 57.9 |
| 时间/s | 60 | 5 | <1 | <1 |

表 2 不同算法对同一模型的精简速度和简度数据

Tab. 2 Speed and simplified degree data of different algorithms on the same model

| 算法 | 对象 | 点数 | 精简比/% | 时间/s |
|-----------------|------|---------|-------|------|
| 聚类法 | 椅子模型 | 249 974 | 96.3 | 5 |
| 包围盒法 | 椅子模型 | 249 974 | 97.0 | <1 |
| 区域重心法 | 椅子模型 | 249 974 | 97.0 | <1 |
| 随机采样法 | 椅子模型 | 249 974 | 94.0 | <1 |
| 曲率自适应法 | 椅子模型 | 249 974 | 97.3 | 2 |
| 特征提取的 自适应精简法 | 椅子模型 | 249 974 | 93.7 | 5 |

表 3 平面点云模型精简精度数据

Tab. 3 Simplified precision data on plane point cloud model

| 平面点云 | 点云点数 | 最大 偏差/mm | 平均 偏差/mm | 标准 偏差/mm |
|------|--------|-------------|-------------|-------------|
| 精简前 | 13 265 | 0.110 1 | 0.013 1 | 0.010 7 |
| 精简后 | 686 | 0.103 1 | 0.018 8 | 0.015 1 |
| 精简掉 | 12 579 | 0.089 8 | 0.012 7 | 0.010 3 |
| 差值 | 12 579 | 0.007 0 | -0.005 7 | -0.004 4 |

通过表 3 的评估数据可以看出,精简前后的平面点云数据偏差都不大,均在 0.12 mm 以内,平均偏差低于 0.02 mm,标准偏差在 0.01 mm 左右。精简掉的点的各项偏差均较小,这意味着在平面内的点为冗余点的可能性大。精简掉的点与精简后的点在偏差水平上有明显区别,二者在平均偏差及标准偏差上比值均约为 2:3,可见在精

简过程中将点云数据分为特征点和冗余点是有效的。另外,精简后最大偏差由原来的 0.110 1 mm 减少到 0.103 1 mm,而精简掉的点的最大偏差仅为 0.089 8 mm,表明精简过程没有去掉细节点或特征点,精简后点云对物体形貌的描述不受影响,说明利用本文精简算法处理后的点云数据比较可靠。

表 4 球面点云模型精简精度数据

Tab. 4 Simplified precision data on sphere point cloud model

| 球体点云 | 精简前 | 精简后 | 差值 |
|-----------------------------|---------------------------------------|---------------------------------------|-----------------------------------|
| 点云点数 | 13 160 | 1 732 | 11 428 |
| 球心坐标 (x_0, y_0, z_0) | (23.018 7, 99.277 6, 450.651 7) | (23.019 3, 99.281 1, 450.641 6) | (-0.000 6, -0.003, 0.010 1) |
| 半径/mm | 19.784 7 | 19.779 9 | 0.004 8 |
| 最大偏差/mm | 0.728 4 | 0.386 0 | 0.342 4 |
| 平均偏差/mm | 0.082 0 | 0.081 7 | 0.000 3 |
| 标准偏差/mm | 0.003 2 | 0.003 1 | 0.000 1 |

通过表 4 的评估数据可以看出,精简前后的点云数据偏差都不大,均在 0.8 mm 以内,平均偏差在 0.08 mm 左右,标准偏差在 0.003 mm 左右,精简前后球心位置变化很小,球体半径误差仅为 0.004 8 mm,精简后最大偏差由原来的 0.728 4 mm 减少到 0.386 0 mm,降低了噪声的干扰,保证了数据的精确性。

4 结 论

本文提出了一种新的点云特征提取的自适应精简算法。首先对原始点云进行空间划分,识别不同区域的信息和数据。然后对平面数据进行边界检测和提取,对非平面部分先提取特征,再根据曲率的不同进行不同程度的精简。最终实验表明处理大小为百万以内点的点云模型可以在几秒之内完成,精简比能够达到 90% 以上,与原始数据间的误差较小。平面部分在精简前后平均偏差均在 0.02 mm 以内,波动很小,为 0.005 7 mm;非平面区域精简前后的平均偏差均在 0.08 mm 左右,差值仅为 0.000 3 mm,保证了精简精度。相比其他方法,本文的精简算法能够更好地体现物体形貌。同时从两个维度进行了实验和结果分析:一

是利用本文算法对几组点云模型进行精简处理;二是通过几种不同算法分别对同一模型进行处

理。最后从时间、精简比、精度3方面对本文算法进行了评价。结果显示本文算法满足实际需求。

参考文献:

- [1] 田庆国,葛宝臻,杜朴,等. 基于激光三维扫描的人体特征尺寸测量[J]. 光学精密工程, 2007, 15(1):84-88.
TIAN Q G, GE B ZH, DU P, *et al.*. Measurement of human figure size based on laser 3D scanning [J]. *Opt. Precision Eng.*, 2007, 15(1):84-88. (in Chinese)
- [2] 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.
YUAN X C, WU L SH, CHEN H W. Feature preserving point cloud simplification [J]. *Opt. Precision Eng.*, 2015, 23(9):2666-2676. (in Chinese)
- [3] WEIR D J, MILROY M J, BRADIEY C, *et al.*. Reverse engineering physical models employing wrap-around B-spline surfaces and quadrics [J]. *Proceedings of the Institution of Mechanical Engineering*, 1996, 210(22):147-157.
- [5] SUN W, BRADLEY C, ZHANG Y F, *et al.*. Cloud data modelling employing a unified, non-redundant triangular mesh [J]. *Computer-Aided Design*, 2001, 33(2):183-193.
- [6] 王欣,张明明,于晓,等. 应用改进迭代最近点方法的点云数据配准[J]. 光学精密工程, 2012, 20(9):2068-2077.
WANG X, ZHANG M M, YU X, *et al.*. Point cloud registration based on improved iterative closest point method [J]. *Opt. Precision Eng.*, 2012, 20(9):2068-2077. (in Chinese)
- [7] 喜文飞,方源敏,李帅,等. 一种新的激光点云数据精简方法[J]. 测绘工程, 2012, 21(4):38-40.
XI W F, FANG Y M, LI SH, *et al.*. A new research on data compression and simplify technology based on laser scanning point cloud [J]. *Engineering of Surveying and Mapping*, 2012, 21(4):38-40. (in Chinese)
- [8] 万军,鞠鲁粤. 逆向工程中数据点云精简方法研究[J]. 上海大学学报:自然科学版, 2004, 10(1):26-29.
WAN J, JU L Y. Data reduction for reverse engineering [J]. *Journal of Shanghai University(Natural Science)*, 2004, 10(1):26-29. (in Chinese)
- [9] 黄承亮,吴侃,向娟. 三维激光扫描点云数据压缩方法[J]. 测绘科学, 2009, 34(2):142-144.
HUANG CH L, WU K, XIANG J. 3D laser scanning point cloud data compression method [J]. *Science of Surveying and Mapping*, 2009, 34(2):142-144. (in Chinese)
- [10] 徐广州,阮萍. 光机集成仿真前处理中点云边界检测技术[J]. 红外与激光工程, 2016, 45(4):252-257.
XU G ZH, RUAN P. Point cloud boundary detection in preprocessor of optical-mechanical integrated simulation [J]. *Infrared & Laser Engineering*, 2016, 45(4):252-257. (in Chinese)
- [11] 葛源坤,黎荣,李海伦. 空间分割与曲率相融合的点云精简算法研究[J]. 计算机应用研究, 2012, 29(5):1997-2000.
GE Y K, LI R, LI H L. Study of point cloud data reduction algorithm integrating space partition and curvature [J]. *Application Research of Computers*, 2012, 29(5):1997-2000. (in Chinese)
- [12] 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]. *Transaction of Beijing Institute of Technology*, 2010, 30(7):785-789. (in Chinese)
- [13] 张雨禾,耿国华,魏潇然. 散乱点云谷脊特征提取[J]. 光学精密工程, 2015, 23(1):310-318.
ZHANG Y H, GENG G H, WEI X R. Valley-ridge feature extraction from point clouds [J]. *Opt. Precision Eng.*, 2015, 23(1):310-318. (in Chinese)
- [14] AMENTA N, BERN M, KAMVYSSELIS M. A new voronoi-based surface reconstruction algorithm [C]. *Proceedings of the 25th Annual Conference on Computer Graphics and Interactive Techniques*, 1998:415-421.
- [15] ANDERSSON M, GIESEN J, PAULY M, *et al.*. Bounds on the k-neighborhood for locally uniformly sampled surfaces [C]. *Proc. of Symp on Point-Based Graphics*, 2004:167-171.
- [16] 王兆丰,闫镡,童莉,等. 自适应邻域尺寸选择的点云法向量估计算法[J]. 红外与激光工程, 2014, 43(4):1322-1326.
WANG ZH F, YAN B, TONG L, *et al.*. Normal

- estimate method of point clouds based on adaptive neighbor size [J]. *Infrared & Laser Engineering*, 2014, 43(4):1322-1326. (in Chinese)
- [17] 李宝,程志全,党岗,等. 三维点云法向量估计综述 [J]. *计算机工程与应用*, 2010, 46(23):1-7.
LI B, CHENG ZH Q, DANG G, *et al.*. Survey on normal estimation for 3D point clouds [J]. *Computer Engineering & Applications*, 2010, 46(23):1-7. (in Chinese)
- [18] HOPPE H. Surface reconstruction from unorganized points [J]. *Acm Siggraph Computer Graphics*, 1992, 26(2):71-78.
- [19] 刘志强,尹建芹,张玲,等. 基于 Kinect 数据主成分分析的人体动作识别 [J]. *光学精密工程*, 2015, 23(10S):702-711.
LIU ZH Q, YIN J Q, ZHANG L, *et al.*. Human action recognition based on Kinect data principal component analysis [J]. *Opt. Precision Eng.*, 2015, 23(10S):702-711. (in Chinese)
- [20] 解则晓,徐尚. 三维点云数据拼接中 ICP 及其改进算法综述 [J]. *中国海洋大学学报*, 2010, 40(1):99-103.
XIE Z X, XU SH. A survey on the ICP algorithm and its variants in registration of 3D point clouds [J]. *Periodical of Ocean University of China*, 2010, 40(1):99-103. (in Chinese)

作者简介:



刘 迎(1990—),女,河北石家庄人,硕士,2013年、2016年于河北工业大学分别获得学士、硕士学位,主要从事三维形貌测量与点云数据处理方面的研究。
E-mail:2798710661@qq.com



张宗华(1974—),男,江苏徐州人,教授,1996年、1998年、2001年于天津大学分别获得学士、硕士和博士学位,主要从事光学检测、三维数字成像和造型、条纹自动分析和三维生物测定等方面的研究。E-mail: zhzhangtju@hotmail.com, zhzhang@hebut.edu.cn