

基于多参数 k -means 聚类的自适应点云精简

王建强¹, 樊彦国¹, 李国胜¹, 禹定峰^{2*}

¹ 中国石油大学(华东)海洋与空间信息学院, 山东 青岛 266580;

² 齐鲁工业大学(山东省科学院)山东省科学院海洋仪器仪表研究所, 山东 青岛 266061

摘要 点云数据量十分庞大,合理地精简点云数据是点云数据处理的重要研究内容。针对传统点云精简算法存在的细节缺失、空洞等问题,提出一种基于多参数 k -means 聚类的自适应点云精简算法。该方法基于 KD-Tree 创建点云 k 邻域,结合曲面拟合对点云数据进行曲率和法向特征计算,运用多参数混合特征提取方法对点云特征及边界进行检测并保留;并由 KD-Tree 索引确定初始化聚类簇心,进行 k -means 聚类,聚类结果根据最大曲率偏差作细分精简。将本文算法、曲率采样法、均匀网格法与随机精简法分别应用于不同类型的点云模型中进行实验,结果表明,本文算法在复杂模型下的标准偏差均优于后三者,且可以较好地保留点云的细节特征信息,精简效果与模型完整性优于均匀网格法与曲率采样法。

关键词 图像处理; 点云精简; KD-Tree; k -means 聚类; 特征点

中图分类号 O436

文献标志码 A

doi: 10.3788/LOP202158.0610008

Adaptive Point Cloud Reduction Based on Multi Parameter k -Means Clustering

Wang Jianqiang¹, Fan Yanguo¹, Li Guosheng¹, Yu Dingfeng^{2*}

¹ College of Ocean and Space Information, China University of Petroleum, Qingdao, Shandong 266580, China;

² Institute of Marine Instrumentation, Shandong Academy of Sciences, Qilu University of Technology, Qingdao, Shandong 266061, China

Abstract The amount of point cloud data is very large, so it is an important research content to reduce the point cloud data reasonably. Aiming at the problems of missing details and containing holes in traditional point cloud reduction algorithm, this paper proposes an adaptive point cloud reduction algorithm based on multi parameter k -means clustering. In this method, k -neighborhood of point cloud is created based on KD tree, curvature and normal features of point cloud data are calculated by surface fitting, and point cloud features and boundaries are detected and preserved by multi parameter mixed feature extraction method; initial cluster center is determined by KD tree index, k -means clustering is conducted, and clustering results are refined according to maximum curvature deviation. This algorithm, curvature sampling method, uniform grid method and random reduction method are applied to different types of point cloud models for experiments. The results show that the proposed algorithm has the lower standard deviation than the latter three methods in complex model, and can retain the detailed feature information of point cloud. In addition, the reduction effect and model integrity of the proposed algorithm are better than those of uniform grid method and curvature sampling method.

Key words image processing; point cloud reduction; KD-tree; k -means clustering; feature points

OCIS codes 100.2000; 140.3430; 280.3640

收稿日期: 2020-07-22; 修回日期: 2020-08-13; 录用日期: 2020-08-27

基金项目: 山东省重点研发计划(2019GHY112017)

* E-mail: z18010014@s.upc.edu.cn

1 引言

相比传统的测量技术,三维激光扫描技术在数据采集方面,具有快捷、精确、简便等特点,被广泛应用于各个领域^[1]。随着三维激光扫描技术的快速发展,设备采集数据精度的要求大幅提高,数据量变得十分巨大,导致后续的模式复原等工作效率变低^[2-3]。如何合理地进行点云精简,减少大量的无效点云,并保证扫描物体的表面细节等特征不受破坏,成为了点云数据处理中的一个重要研究内容。

国内外学者针对点云数据精简的问题进行了大量的研究,根据精简思路主要分为三种:包围盒法、随机采样法和曲率采样法^[4]。史宝全等^[5]提出了基于聚类的点云简化方法,精简后的点云分布均匀,但是由栅格法提供的初始聚类中心将导致迭代次数增加。Sun 等^[6]使用 k 均值(k -means)聚类方法对三维点云数据进行分割处理,该方法对点云模型形状有特定要求,具有局限性。Miao 等^[7]提出一种曲率算法,并利用这一算法对点云进行精简,该算法通过对不同区域设置不同的精简阈值进行精简,故在进行目标区域选择时较为麻烦。唐泽宇等^[8]提出了一种基于加权最小二乘法曲率计算的点云精简算法,该算法在局部邻域中使用加权最小二乘法拟合曲面,然后结合 k -means 聚类算法和基于泊松分布特征点检测算法对点云进行精简,因其特征点检测算法仅适用于相对平坦地区的检测,故该算法对特征的保留效果较差。

因此,本文针对传统方法中点云类型单一、精简区域设置繁琐、表面空洞和特征保留差等问题,提出一种基于多参数 k -means 聚类的自适应点云精简方法,该算法保留点云边界与特征信息,利用聚类方法将点云模型划分为不同区域,并根据区域特点进行精简,实现了适应不同类型点云数据、降低阈值设置次数和保留完好特征的目的。

2 材料与方法

2.1 k -means 聚类

k -means 聚类算法是典型的基于距离的聚类算法。在点云聚类过程中, k -means 聚类算法能够保持稳定和快速的优点。该算法是将原始 n 维数据集 P 的数据划分到 k 个指定的簇中。首先寻找 k 个簇中心,通过迭代计算数据到 k 个簇中心的距离来度量并不断移动 k 个簇中心位置,使得目标函数 D 最小。

$$D = \min \sum_{i=1}^k \sum_{j=1}^u d^2(\mathbf{P}_{ij}, \mathbf{C}_i), \quad (1)$$

式中: k 为聚类数; u 为第 i 簇中的点数; \mathbf{C}_i 为第 i 簇的簇中心; \mathbf{P}_{ij} 为第 i 簇中的第 j 个数据点; $d^2(\mathbf{P}_{ij}, \mathbf{C}_i)$ 为该点到该簇中心距离的平方。

2.2 加权最小二乘拟合曲率计算

根据 KD-Tree 邻域搜索建立点云 k 邻域,在 k 邻域上建立曲面拟合方程,即

$$z = f(x, y) = a_0 x^2 + a_1 y^2 + a_2 xy + a_3 x + a_4 y + a_5, \quad (2)$$

式中: $a_0, a_1, a_2, a_3, a_4, a_5$ 为待求系数; x, y 为点云数据的横、纵坐标, z 为拟合出来的高度坐标, $z = f(x, y)$ 。方程可表示为 $\mathbf{Z} = \mathbf{A}\mathbf{P}^T$ 的矩阵形式,其中, \mathbf{A} 为待求系数矩阵, $\mathbf{P} = (\mathbf{x}^2 \quad \mathbf{y}^2 \quad \mathbf{xy} \quad \mathbf{x} \quad \mathbf{y} \quad 1)$, \mathbf{P}^T 为 \mathbf{P} 的转置。根据最小二乘准则,可求得系数矩阵 $\mathbf{A} = (\mathbf{P}^T \mathbf{P})^{-1} \mathbf{P}^T \mathbf{Z}$ 。

在传统最小二乘法的基础上,采用离群率^[9]与拟合坐标偏差作为定权标准,计算权值矩阵 \mathbf{W} ,计算方法为

$$W_i = \alpha \times \frac{d(\mathbf{P}_{\max}, \mathbf{P}_i) - d(\mathbf{P}_j, \mathbf{P}_i)}{d(\mathbf{P}_{\max}, \mathbf{P}_i) - d(\mathbf{P}_{\min}, \mathbf{P}_i)} + \beta \times \frac{\tan d(\mathbf{P}_j, \mathbf{P}_{j'})}{d(\mathbf{P}_j, \mathbf{P}_{j'})}, \quad (3)$$

式中: W_i 为当前点的权值; \mathbf{P}_i 为当前点; \mathbf{P}_j 为当前点所在邻域的邻域点; \mathbf{P}_{\max} 为邻域内与当前点距离最远的点; \mathbf{P}_{\min} 为邻域内与当前点距离最近的点; $d(\mathbf{P}_j, \mathbf{P}_i)$ 为邻域点到当前点的距离; $d(\mathbf{P}_j, \mathbf{P}_{j'})$ 表示邻域点 \mathbf{P}_j 到拟合曲面投影坐标点 $\mathbf{P}_{j'}$ 的距离; $d(\mathbf{P}_{\max}, \mathbf{P}_i)$ 为邻域点到当前点的最远距离; $d(\mathbf{P}_{\min}, \mathbf{P}_i)$ 为邻域点到当前点的最近距离; α 与 β 为离群率与拟合坐标偏差的比例系数。

将权值矩阵 \mathbf{W} 代入最小二乘准则中,即可求得加权后的系数矩阵 $\mathbf{A}_w = (\mathbf{P}^T \mathbf{W} \mathbf{P})^{-1} \mathbf{P}^T \mathbf{W} \mathbf{Z}$ 。

通过加权最小二乘法计算出拟合曲面之后,根据曲面方程可求得曲面一阶偏导 f_x, f_y ,二阶偏导 f_{xx}, f_{yy}, f_{xy} ,根据曲面法向量定义,可求得曲面点的单位法向量

$$\mathbf{n} = \frac{\mathbf{f}_x \times \mathbf{f}_y}{|\mathbf{f}_x \times \mathbf{f}_y|}, \quad (4)$$

同时,根据文献[10],可分别求出高斯曲率、平均曲率和均方根曲率。

2.3 基于多参数 k -means 聚类的自适应点云精简

本文方法首先对输入点云创建 KD-Tree 索引,根据最近邻搜索建立 k 邻域,计算几何特征信息,

检测点云数据中可能存在的特征与边界;然后选择 KD-Tree 索引的深度节点作为初始化聚类中心进行 k -means 聚类;最后,将聚类结果根据簇内最大曲率偏差阈值将聚类分为平坦区域与变化区域,在平坦区域采用均匀网格精简,在变化区域保留曲率特征变化明显的的数据。

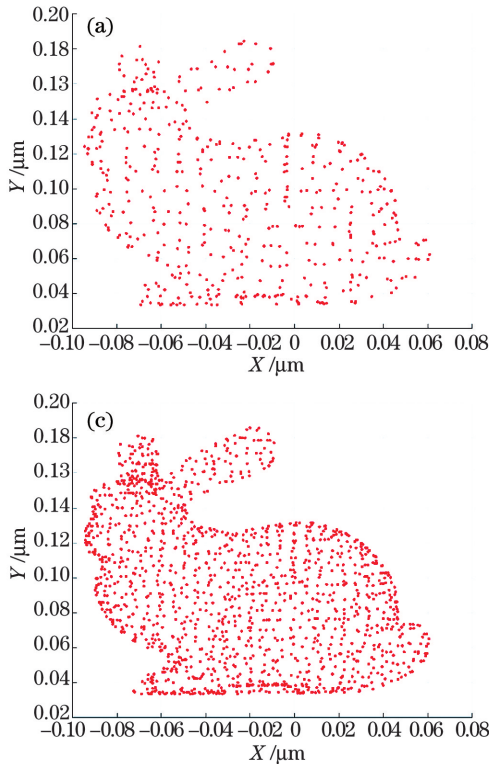
2.3.1 点云特征及边界检测

由于传统点云精简方法缺少对点云模型特征的保留,因此本研究利用点云及其邻域几何特征^[11],采用混合多参数的点云特征检测方法^[12-13]对点云特征进行检测。

首先根据数据点所在邻域进行二次曲面拟合,计算点曲率 c 与点法向夹角 θ ,然后根据邻域内信息,计算出邻域中心与数据点的偏移距离 D_1 和邻域边界平均距离 D_2 。

结合 4 种几何特征,构建检测参数 t 为

$$t = \frac{\alpha \times c + \beta \times \theta + \gamma \times D_1}{D_2}, \quad (5)$$



式中: α 、 β 和 γ 分别为各个几何特征的控制系数,他们可根据点云类型进行调整。

检测阈值 T 为

$$T = \frac{1}{N} \sum_{n=1}^N \frac{(c_n + \theta_n + D_{1,n})}{D_{2,n}}, \quad (6)$$

式中: N 为数据点个数; c_n 为第 n 点的曲率; θ_n 为第 n 点的法向夹角; $D_{1,n}$ 为第 n 点的邻域中心偏移距离; $D_{2,n}$ 为第 n 点的邻域边界平均距离;当 $t > T$ 时,判定为模型特征,不再参与后续精简。

2.3.2 基于 KD-tree 的 k -means 聚类

传统 k -means 聚类结果与初始簇心的质量存在密切关系,使用不同的初始簇心,聚类效果不同。本文采用 KD-Tree 深度节点作为初始聚类簇心,可以保证初始簇心的空间分布相对均匀,减少聚类迭代,稳定聚类结果,实现了精简快速、结果准确的目的。将 KD-Tree 应用于 bunny 点云模型,生成不同 k 值的初始聚类中心结果,如图 1 所示,在不同 k 值下的初始聚类中心分布均较为均匀。


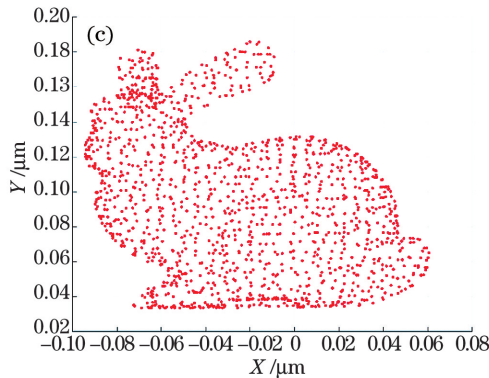
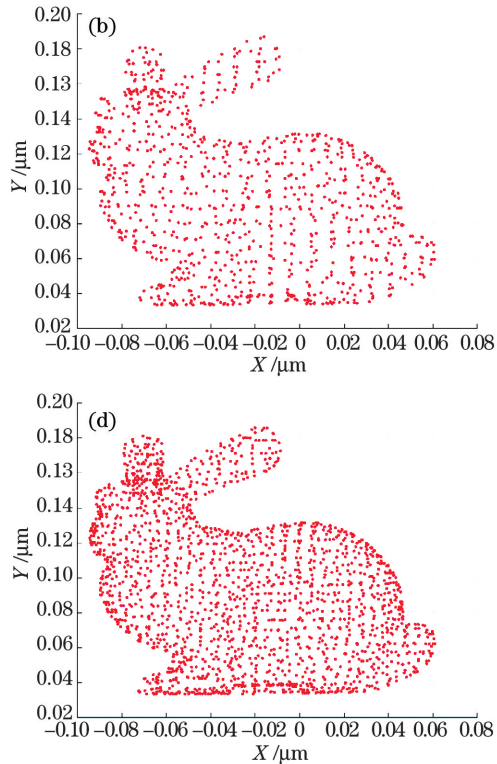


图 1 不同 k 值下的 bunny 模型初始化聚类中心结果。(a) $k=500$; (b) $k=1000$; (c) $k=1500$; (d) $k=2000$

Fig. 1 Initial clustering results of bunny models with different k values. (a) $k=500$; (b) $k=1000$; (c) $k=1500$; (d) $k=2000$

将传统 k -means 与基于 KD-Tree 的 k -means 的聚类结果进行对比。本研究采用戴维森堡丁指数 (Davies Bouldin Index, DBI) 评价类内与类间的差异, DBI 越小意味着聚类结果的类内距离越小,类间

距离越大,聚类效果越好,其计算方式为

$$D_{DBI} = \frac{1}{k} \sum_{i=1}^k \max_{j \neq i} \left(\frac{\bar{D}_{CP_j} - \bar{D}_{CP_i}}{d(\mathbf{C}_j, \mathbf{C}_i)} \right), \quad (7)$$

式中: \bar{D}_{CP_i} 为第 i 类中各点到聚类中心 \mathbf{C}_i 的平均距

离; $d(C_j, C_i)$ 表示聚类中心 C_j 与 C_i 的距离; k 表示聚类的簇数。

为减少初始簇心对传统 k -means 方法效果的影响, 采用多次运行的方式, 两种方法在不同 k 值

下分别运行 5 次并记录其在对应 k 值下的迭代次数、目标函数平均值、戴维森堡丁指数与运行时间上的差异。结果如表 1 所示。

表 1 Bunny 模型不同初始化聚类中心选择法比较结果

Table 1 Comparison results of different initialization cluster center selection methods in bunny model

Method	k value	Number of iterations			Mean value of objective function	DBI	Run time /s
		Max	Mean	Min			
Our method	500	52	52	52	0.622311	0.872	3.986
	1000	31	31	31	0.318098	0.883	4.333
	1500	31	31	31	0.214407	0.908	5.325
	2000	20	20	20	0.161110	0.895	5.451
Traditional k -means clustering method	500	74	62	52	0.624288	0.864	5.952
	1000	61	43	29	0.319547	0.918	12.449
	1500	39	33	26	0.215288	0.939	19.842
	2000	34	25	19	0.162071	0.933	30.369

由表 1 数据对比可知, k -means 聚类采用本文方法选取的初始化聚类中心时, 本文方法的迭代次数比传统 k -means 方法更稳定, 在 $k = 500$ 时的戴维森堡丁指数较传统 k -means 略小, 但其迭代次数、目标函数与运行时间均优于传统 k -means 方法; 在高 k 值下, 其评价指标均优于传统的方法。因此本文方法的聚类效果明显优于传统 k -means 方法, 适用于点云精简。

2.3.3 基于曲率偏差的聚类精简

在点云特征及边界信息得以保留的情况下, 传统精简方法中主要特征缺失现象可以得到一定的改善, 因此在聚类精简的过程中, 可着重考虑对点云非特征区域进行均匀化精简, 以保证点云模型表面的完整性, 同时尽可能地保留未被检测出的微小细节特征。聚类精简的流程如图 2 所示。采用簇类平均曲率对聚类区域类型进行划分, 将聚类分为平坦区域和变化区域。对于平坦区域, 采用均匀网格策略对数据进行保留, 保证精简后的数据不会出现空洞等失真现象。而对于曲面变化区域, 因该区域通常会包含模型的许多细微特征, 如果同样采用均匀网格策略, 则会使得部分细节特征丢失, 所以在该类区域需采用曲率特征保留策略。接着计算区域内部的最大曲率偏差并与设定的阈值进行比较。如果大于阈值, 则对区域点根据偏差值设定细分数, 将数据点进行细分, 针对每个小类的数据曲率计算其最大曲率偏差, 并与设定的阈值进行比较, 大于阈值的聚类

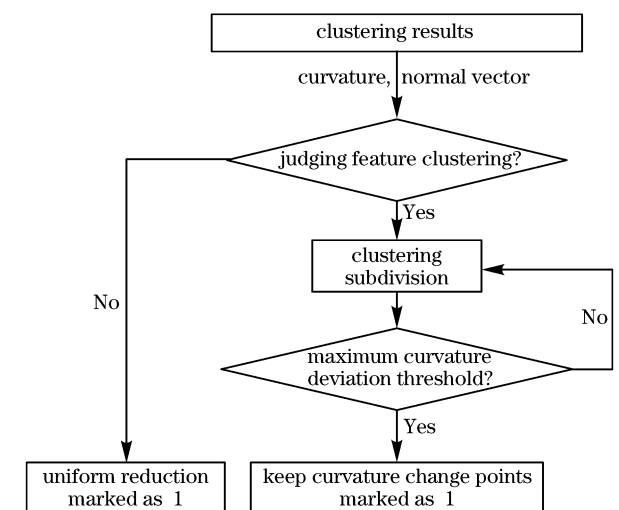


图 2 基于曲率偏差的聚类精简流程图

Fig. 2 Flowchart of clustering simplification based on curvature deviation

则继续迭代, 细分为多个子聚类, 重复细分直至最大曲率偏差小于阈值或只剩下单个数据点; 如果小于阈值, 则对该区域点进行曲率变化的比较, 保留变化部分的数据。

3 结果与讨论

由于点云数据获取形式多种多样, 点云模型也存在诸多不同, 本研究选取三种不同类型的模型进行实验, 以验证所提方法的适用性和可行性。在实验中, 设定参数 $\alpha, \beta, \gamma, \eta, \varphi$, 其中 α, β, γ 用于检测

点云特征及边界, η 用于控制特征点个数, φ 为精简度。各模型介绍及其参数设定如下:

第一种为 bunny 模型, 点云总数为 35947, 该模型数据分布均匀, 实际尺寸较小, 特征复杂且数据量庞大, 参数设置为 $\alpha=0.1, \beta=0.2, \gamma=0.5, \eta=1, \varphi \in (0.1, 0.2, 0.5)$ 。

第二种为 hippo 模型, 点云总数为 23105, 该模型为非均匀点云模型, 存在许多数据稀疏区域, 参数设置为 $\alpha=0.15, \beta=0.1, \gamma=1, \eta=1, \varphi \in (0.1, 0.2, 0.5)$ 。

第三种为 golden bucket 模型, 该模型为非封闭

片状点云模型, 存在诸多复杂区域, 点云总数为 66045, 参数设置为 $\alpha=0.6, \beta=1, \gamma=0.5, \eta=1, \varphi \in (0.1, 0.2, 0.5)$ 。

本文方法利用几何特征融合的多参数特征点检测方式, 对以上三种不同类型模型进行特征点检测, 检测结果如图 3 所示, 其中, bunny 模型检测特征点个数为 996, hippo 模型检测特征点个数为 5053, golden bucket 模型检测特征点个数为 4735。由图 3 可以看出, 特征点大多分布在模型边界及其变化部分, 如 bunny 模型中耳朵部分, hippo 的头部、眼睛鼻孔等, golden bucket 片状模型中文字、边界部分。




图 3 各模型在相应参数下的特征点检测结果图。(a) Bunny 模型特征图; (b) hippo 模型特征图; (c) golden bucket 模型特征图

Fig. 3 Feature point detection results of each model under corresponding parameters. (a) Bunny model feature; (b) hippo model feature; (c) golden bucket model feature

3.1 不同精简率的精简结果分析

在 0.1、0.2 和 0.5 的精简率下使用本文方法对上述三种模型进行精简, 采用标准偏差和曲面面积变化率两种指标对精简效果及性能进行评价。标准偏差表达式为

$$\Delta_{ave}(S, S') = \frac{1}{N} \sum_{(g \in S, g' \in S')} d(g, g'), \quad (8)$$

式中: N 为曲面点个数; $d(g, g')$ 为原始曲面 S 上采样点 g 到精简点云曲面 S' 上投影点 g' 的欧氏距离; 由 g 的单位法向量 N_p 可知, $d(g, g') = |N_p \cdot (g' - g)|$ 。

表面积变化率表达式为

$$\rho = \frac{(s_m - s'_m)}{s_m} \times 100\%, \quad (9)$$

式中: s_m 为原始模型的曲面表面积; s'_m 为精简模型的曲面表面积。

精简效果结果分别如图 4~6 所示。

从本文算法得到的精简模型中可以发现, 本文方法对不同类型的点云数据进行精简时, 可以根据数据点云特征进行精简。在 0.5 的精简率下, 各模型均能较好地保持原有的细节信息; 在 0.2 的精简




图 4 bunny 模型在各精简比例下的模型图。(a) 精简比例为 0.1 时; (b) 精简比例为 0.2 时; (c) 精简比例为 0.5 时
Fig. 4 Reduced model diagram of bunny model under various reduction ratios. (a) Reduction ratio is 0.1; (b) reduction ratio is 0.2; (c) reduction ratio is 0.5




图 5 hippo 模型在各精简比例下的模型图。(a) 精简比例为 0.1 时; (b) 精简比例为 0.2 时; (c) 精简比例为 0.5 时
Fig. 5 Reduced model diagram of hippo model under various reduction ratios. (a) Reduction ratio is 0.1; (b) reduction ratio is 0.2; (c) reduction ratio is 0.5



图 6 golden bucket 模型在各精简比例下的模型图。
(a) 精简比例为 0.1 时; (b) 精简比例为 0.2 时;
(c) 精简比例为 0.5 时

Fig. 6 Reduced model diagram of golden bucket model under various reduction ratios. (a) Reduction ratio is 0.1; (b) reduction ratio is 0.2; (c) reduction ratio is 0.5

率下,模型中小部分的细小纹理丢失,但部分明显特征和纹理仍能保留,可较好地体现模型的外表细节;在 0.1 的精简率下,在顾及模型完整性的情况下,仍

能完好地保留诸如 bunny 耳朵、hippo 头部、golden bucket 文字等较复杂部位的特征,实现了模型数据的精简。结合标准偏差和模型表面积变化率进行分析,结果如表 2 所示,由于非均匀模型 hippo 的躯干部分进行了一部分精简,同时躯干所占模型比例较大,导致躯干微小的边界收缩现象被放大,因此该模型的体积变化率与原始模型的表面积差距较大,但比较精简后模型可以看出,hippo 模型的表面积变化较小,说明本文方法保留了 hippo 模型平坦区域数据,没有进一步加剧模型边界收缩现象。总体上,在特征区域精简后的点云保留了大量的数据点,在平坦区域数据点相对较少但分布均匀,没有空洞现象发生,且较好地保留了片状点云模型的边界数据。

表 2 不同精简率下的标准偏差与表面积变化率比较

Table 2 Comparison of standard deviation and surface area change rate under different reduction rates

Model	Simplification	Number of data	Standard deviation	Change rate of surface area / %
Bunny	0.1	3733	0.000465	2.0601
	0.2	7140	0.000396	1.3272
	0.5	18278	0.000351	0.6114
Hippo	0.1	3722	0.230015	16.7310
	0.2	6583	0.155388	15.7344
	0.5	11569	0.110577	14.6062
Golden bucket	0.1	6735	4.463796	5.1303
	0.2	13662	2.998224	3.5730
	0.5	33325	1.935787	3.1996

3.2 不同算法的精简结果对比分析

分别对上述三种模型在 0.2 的精简比例下应用随机精简法、曲率采样法、均匀网格法以及本文算法对精简效果和标准偏差进行分析,精简效果及标准偏差结果分别如图 7~9 和表 3

所示。

比较不同方法下的不同类型模型精简结果,可以发现,随机精简法通过随机删除数据点的方法进行数据精简,精简效果时好时坏,具有不确定性,标准偏差也存在很大的波动;曲率采样法仅适用于特

表 3 不同精简方法下的标准偏差和表面积变化率比较

Table 3 Comparison of standard deviation and surface area change rate under different simplification methods

Method	Bunny		Hippo		Golden bucket	
	Standard deviation	Change rate of surface area / %	Standard deviation	Change rate of surface area / %	Standard deviation	Change rate of surface area / %
Random	0.000415	1.6097	0.265509	16.3719	3.684469	4.8828
Curvature	0.001101	1.9231	2.365784	28.1071	3.590388	12.6053
Grids	0.000379	1.2535	1.158725	16.1662	4.299177	5.8593
Our method	0.000396	1.3272	0.155388	15.7344	2.998224	3.5730

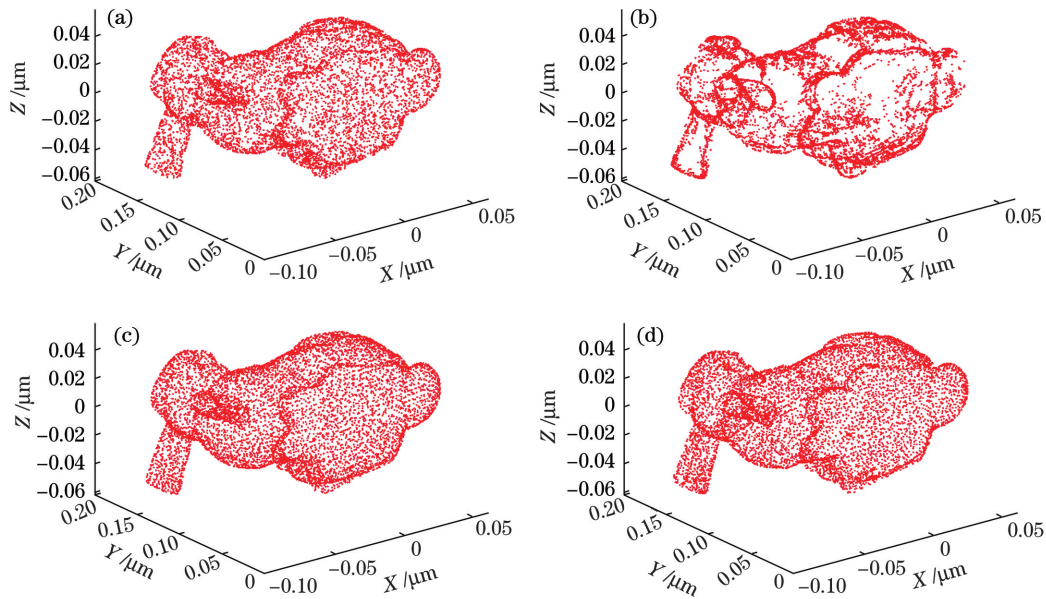


图 7 不同方法的 bunny 模型精简结果图。(a) 随机精简法;(b) 曲率采样法;(c) 均匀网格法;(d) 本文方法
Fig. 7 Results of bunny model reduction by different methods. (a) Random reduction; (b) curvature sampling;
(c) uniform grid; (d) our method




图 8 不同方法的 hippo 模型精简结果图。(a) 随机精简法;(b) 曲率采样法;(c) 均匀网格法;(d) 本文方法
Fig. 8 Results of hippo model reduction by different methods. (a) Random reduction; (b) curvature sampling;
(c) uniform grid; (d) our method

征变化明显的区域,在 hippo 模型的头部、golden bucket 文字部分精简效果较好,但是在其他区域、其他类型模型中,精简效果并不佳,会在平坦区域造成大面积的数据丢失,例如 hippo 模型的躯干部分,这也导致曲率采样法的标准偏差和表面积变化率显著高于其他三种方法;均匀网格法则普遍适用于大部分类型的点云数据,但在片状点云类型的精简方面效果不是很好,均匀精简的策略使得数据分布均

匀,但会弱化片状点云的纵向特征表现,导致特征衰弱,例如 golden bucket 模型的文字特征经过均匀网格法之后变得模糊不清。结合标准偏差和模型表面积变化率进行分析,结果如表 3 所示,由本文方法精简的模型数据在总体上处于均匀分布的状态,且明显地保留了特征区域,保持了模型细节的完整性,并且针对复杂模型的标准偏差与表面积变化率均小于其他方法。

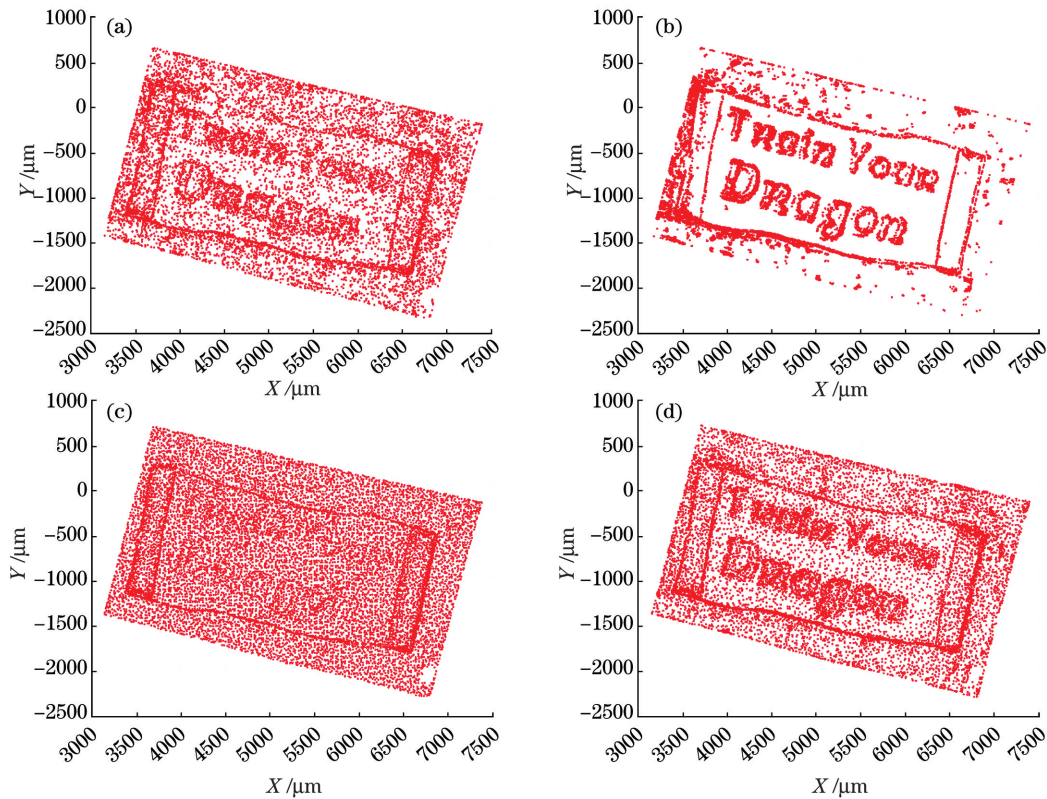


图 9 不同方法的 golden bucket 模型精简结果图。(a) 随机精简法;(b) 曲率采样法;(c) 均匀网格法;(d) 本文方法
Fig. 9 Results of golden bucket model reduction by different methods. (a) Random reduction; (b) curvature sampling;
(c) uniform grid; (d) our method

4 结 论

提出一种基于多参数 k -means 聚类的自适应点云精简算法。针对不同类型数据,将本文方法与随机法、曲率法、网格法进行对比,结果表明,该方法在不同类型的点云数据中均有较好的精简效果,同时利用聚类邻域的曲率特征划分精简区域,减少了阈值设置的次数,在保证模型表面完整无空洞的同时,尽可能地保留了点云特征信息,在高精度度下仍能保证点云特征信息不被删减。本文方法应用于复杂的非均匀封闭模型时拥有良好的精简效果,但由于方法前面部分采用拟合曲面的方式计算特征参数,故还存在运算复杂的问题,有待改进,同时,如何保证非均匀区域的数据量也是下一步工作中可以改进的方面。

参 考 文 献

- [1] He Y B, Chen R L, Wu K, et al. Point cloud simplification method based on k -means clustering [J]. Laser & Optoelectronics Progress, 2019, 56 (9): 091002.
贺一波, 陈冉丽, 吴侃, 等. 基于 k -means 聚类的点

云精简方法 [J]. 激光与光电子学进展, 2019, 56 (9): 091002.

- [2] Yang Q X, Yang X Q, Du J. Point cloud simplification algorithm based on Hausdorff distance and segmentation [J]. Computer Engineering and Design, 2016, 37(8): 2105-2109.
杨秋翔, 杨小青, 杜健. 基于 Hausdorff 距离的点云分片精简算法 [J]. 计算机工程与设计, 2016, 37 (8): 2105-2109.
- [3] Chang J F, Zhao L M, Wang H B. Research on k -means clustering point cloud reduction algorithm based on boundary reservation [J]. Engineering of Surveying and Mapping, 2018, 27(7): 60-65.
常俊飞, 赵利民, 王瀚斌. 基于边界保留的 k -means 聚类点云精简算法研究 [J]. 测绘工程, 2018, 27 (7): 60-65.
- [4] Sun P F. Streamlined compression analysis and practice of point cloud data based on coordinate increment [D]. Xi'an: Xi'an University of Science and Technology, 2014.
孙鹏飞. 基于坐标增量的点云数据精简压缩分析与实践 [D]. 西安: 西安科技大学, 2014.
- [5] Shi B Q, Liang J, Zhang X Q, et al. Research on point cloud simplification with preserved features [J]. Journal of Xi'an Jiaotong University, 2010, 44(11):

- 37-40.
史宝全, 梁晋, 张晓强, 等. 特征保持的点云精简技术研究[J]. 西安交通大学学报, 2010, 44(11): 37-40.
- [6] 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.
- [7] Miao Y W, Pajarola R, Feng J Q. Curvature-aware adaptive re-sampling for point-sampled geometry[J]. *Computer-Aided Design*, 2009, 41(6): 395-403.
- [8] Tang Z Y, Gao B L, Dou M L. Point clouds simplification algorithm based on weighted least squares surface fitting for curvature computation[J]. *Computer Engineering and Design*, 2019, 40(6): 1606-1610, 1659.
唐泽宇, 高保禄, 窦明亮. 基于加权最小二乘法曲率计算的点云精简算法[J]. *计算机工程与设计*, 2019, 40(6): 1606-1610, 1659.
- [9] Tang Z Y. Point cloud reduction algorithm based on Poisson distribution and K -means clustering [D]. Taiyuan: Taiyuan University of Technology, 2019.
唐泽宇. 基于泊松分布 K -means 聚类的点云精简算法[D]. 太原: 太原理工大学, 2019.
- [10] Wang J F, Qin H. Octal tree-based mean clustering point cloud simplification method [J]. *Automation Application*, 2019(4): 81-82, 99.
王甲福, 秦昊. 基于八叉树的均值聚类点云精简方法[J]. *自动化应用*, 2019(4): 81-82, 99.
- [11] Yan P. Feature extraction and clustering simplification algorithm for 3D laser point cloud[D]. Xi'an: Xi'an University of Science and Technology, 2018.
晏沛. 三维激光点云的特征提取及聚类精简算法研究[D]. 西安: 西安科技大学, 2018.
- [12] Chen L, Cai Y, Zhang J S. Adaptive K -means clustering simplification of scattered point cloud[J]. *Journal of Image and Graphics*, 2017, 22(8): 1089-1097.
陈龙, 蔡勇, 张建生. 自适应 K -means 聚类的散乱点云精简[J]. *中国图象图形学报*, 2017, 22(8): 1089-1097.
- [13] Chen L, Cai Y, Zhang J S, et al. Feature point extraction of scattered point cloud based on multiple parameters hybridization method [J]. *Application Research of Computers*, 2017, 34(9): 2867-2870.
陈龙, 蔡勇, 张建生, 等. 基于多判别参数混合方法的散乱点云特征提取[J]. *计算机应用研究*, 2017, 34(9): 2867-2870.
- [14] Wang C F, Geng G H, Hu J B, et al. Feature-aware three-dimensional point cloud simplification algorithm [J]. *Laser & Optoelectronics Progress*, 2019, 56(11): 111004.
王成福, 耿国华, 胡佳贝, 等. 一种特征感知的三维点云简化算法[J]. *激光与光电子学进展*, 2019, 56(11): 111004.
- [15] Hu J B, Liu Z, Zhang P F, et al. Feature extraction of scattered point clouds based on discrete Morse theory [J]. *Acta Optica Sinica*, 2019, 39(6): 0615002.
胡佳贝, 刘喆, 张鹏飞, 等. 基于离散 Morse 理论的散乱点云特征提取[J]. *光学学报*, 2019, 39(6): 0615002.
- [16] Wang X H, Wu L S, Chen H W, et al. Featureline extraction from a point cloud based on region clustering segmentation [J]. *Acta Optica Sinica*, 2018, 38(11): 1110001.
王晓辉, 吴禄慎, 陈华伟, 等. 基于区域聚类分割的点云特征线提取[J]. *光学学报*, 2018, 38(11): 1110001.
- [17] Fan X H, Xu G L, Li W L, et al. Target segmentation method for three-dimensional LiDAR point cloud based on depth image[J]. *Chinese Journal of Lasers*, 2019, 46(7): 0710002.
范小辉, 许国良, 李万林, 等. 基于深度图的三维激光雷达点云目标分割方法[J]. *中国激光*, 2019, 46(7): 0710002.