

多粒度的特征融合点云简化方案

喻萍¹ 郭晔¹
YU Ping GUO Ye

摘要

针对现有基于关键点的点云简化算法存在光滑表面过度简化的问题,提出一种多粒度、层级化的特征融合的点云简化方案。为平衡尖锐几何曲面和光滑曲面的简化程度,同时减少特征损失,依据特征分布将简化方案拆分成粗细粒度两大模块。在粗粒度模块中,设计了一种自适应体素网格边长的方法,以提高简化过程中算法灵活性,并结合主成分分析法获取点云特征值,避免非关键点的干扰;在细粒度模块中,通过融合改进灰狼优化算法与 k 均值聚类,构建点云计算聚类模型,实现了点云聚类和二次精细化处理。最后,在公开数据集上对所设计的方案进行验证与分析,实验结果表明所提出的方案在误差性能方面明显好于随机采样法和曲率简化法。

关键词

多粒度;点云简化;自适应增长因子;灰狼优化;聚类

doi: 10.3969/j.issn.1672-9528.2024.08.017

0 引言

三维激光扫描技术具有高效、快捷、精确、简便等特点,被广泛应用于机器人视觉、文化遗产修复、考古、医学图像处理等各个领域。随着技术的不断进步和用户需求的提高,扫描获取的点云数据集变得越来越庞大。大量的点云数据给数据的实时存储和处理带来了巨大的负担,这对于需要高可用性的点云数据处理业务来说是难以接受的。因此,在保持点云的显著几何特征的前提下,对点云进行简化是非常必要的。

在常见的无特征点云简化算法和基于特征的简化算法中,无特征的简化算法可以迅速精简大量点云。例如,李仁忠等人^[1]提出一种基于体素栅格的均匀精简算法,通过确定每个小立方体栅格的重心来实现点云精简;王成福等人^[2]使用 Hausdorff 距离进行点云精简,在保留尖锐特征的同时显示了模型整体轮廓。虽然该类型的简化算法使精简后的点云分布均匀,但同时也忽略了点云局部细节信息的保留情况。基于特征的特征点云简化算法可以弥补特征丢失的缺点。例如,张雨禾等人^[3]利用单位距离上的法向变化提取特征点,并采用不同简化策略对其进行点云简化;赵夫群等人^[4]先预处理点云简化数据,后采用曲率分级的策略实现点云精简。该类算法通过提取点云中的重要参数保留点云特征信息,能够较

好保持原始点云细节特征。然而,由于对特征保留的要求较高,这种算法往往会导致非特征区域的过度简化。虽然上述简化算法在一定程度上能满足点云简化的需求,但将两类算法结合并进行改进,能达到更优的简化效果。

基于此,本文提出一种多粒度、层级化的特征融合点云简化方案,该方案分为粗细粒度两个模块。粗粒度阶段,在快速均匀简化点云的同时保留局部几何特征;细粒度阶段,通过基于改进的灰狼优化算法设计实现点云聚类,根据聚类结果完成二次简化,最后利用线性关系调整两次简化程度,得到最终的简化结果。

1 基于自适应下采样的点云粗粒度简化

1.1 自适应体素网格边长计算

在散乱点云 $P = \{p_1, p_2, \dots, p_N\}$ 中,首先获取点云数据在坐标轴三个方向的最小和最大坐标值。设初始体素网格边长 L_0 ,那么可将点云数据 P 分割成 $X \times Y \times Z$ 个体素网格,对应坐标为:

$$\begin{cases} X = \left\lceil \frac{x_{\max} - x_{\min}}{L_0} \right\rceil \\ Y = \left\lceil \frac{y_{\max} - y_{\min}}{L_0} \right\rceil \\ Z = \left\lceil \frac{z_{\max} - z_{\min}}{L_0} \right\rceil \end{cases} \quad (1)$$

式中: x_{\max} 、 x_{\min} 、 y_{\max} 、 y_{\min} 、 z_{\max} 、 z_{\min} 分别代表点云 P 在 X 、 Y 、 Z 三个坐标轴上的最大值和最小值, $\lceil \cdot \rceil$ 表示向上取整。

现利用一种自适应下采样方法^[5],在子立方体体素网格边长 L_s 中引入双曲正切函数,提升实验的可操作性,设 L_s 为:

1. 西安财经大学信息学院 陕西西安 710100

[基金项目] 陕西省自然科学基金基础研究计划项目 (2021JQ-765); 西安财经大学重点科学研究 (22FCZD05); 西安财经大学科学研究计划扶持项目 (22FCJH008)

$$L_s = k(s)\mu + L_0 \quad (2)$$

式中: L_0 为初始体素网格边长; μ 为网格的单位增长步长;
 $k(s)$ 为自适应步长系数。

$$k = 1 / (1 + \sqrt{\frac{e^{\sqrt{\frac{1}{N_i - N}} - e^{-\sqrt{\frac{1}{N_i - N}}}}}{e^{\sqrt{\frac{1}{N_i - N}}} + e^{-\sqrt{\frac{1}{N_i - N}}}}}) \quad (3)$$

式中: N_i 为当前点云数量; N 为粗粒度简化目标点云数量。

当点云数量和目标点云数量相差较大时, s 越小, $k(s)$ 则越大, 网格边长和点云下采样的速度均会随之加快。

1.2 体素网格法向均值计算

按照上述方法分割目标点云, 采用主成分分析法 (principal component analysis, PCA) 计算每个体素网格内数据点法向量。设近邻点均值为 \bar{p} , 以其构建协方差矩阵 M , 计算式为:

$$M = \frac{1}{k} \sum_{i=1}^k [p_i - \bar{p}][p_i - \bar{p}]^T \quad (4)$$

式中: k 为近邻点个数。

利用矩阵奇异值分解方法 (singular value decomposition, SVD) 求解 M 的特征值由大到小排序为 $\lambda_0, \lambda_1, \lambda_2$, 对应特征向量为 e_0, e_1, e_2 , 则 e_0 为点 p_i 及邻域点所构曲面的法向量, 为消除法向量指向二义性, 设置视点对该向量进行重定向。

计算点云中任意一点 p_i 与其邻域点法向量夹角的算术平均值为 w_i , 设置适当阈值 γ , 当该值大于 γ 时, 认定为特征点; 反之, 则为非特征点。

遍历所有体素网格的空间索引, 查找距离每个体素重心最近的特征点, 并用该特征点代替体素网格中的所有点, 从而得到初简化后的点云数据集 P' , 如式 (5) 所示。

$$d = \arg \min \|p_i - p_{center}\|_2 \quad (5)$$

总体而言, 粗粒度简化结果受到立体网格边长 L_s 的影响, L_s 越大, 几何细节信息越模糊; L_s 越小, 局部几何信息越详细。

2 基于灰狼优化的 k 均值聚类的点云细粒度简化

2.1 灰狼优化算法

灰狼优化算法 (grey wolf optimizer, GWO) 是一种新的群体智能优化算法^[6]。灰狼在狩猎过程中逐渐接近并包围猎物, 且根据猎物的位置更新自己的位置。将最优解定义为 α , 第二、第三次优解定义为 β 和 δ , 其余候选解定义为 ω 。定义狼群中候选灰狼个体 $X_{\omega}(t)$ 由 α 狼、 β 狼和 δ 狼的位置 $X_{\alpha}(t)$ 、 $X_{\beta}(t)$ 、 $X_{\delta}(t)$ 来确定, 其数学表达式为:

$$\begin{cases} D_{\alpha} = |C_1 \cdot X_{\alpha}(t) - X_{\omega}(t)| \\ D_{\beta} = |C_2 \cdot X_{\beta}(t) - X_{\omega}(t)| \\ D_{\delta} = |C_3 \cdot X_{\delta}(t) - X_{\omega}(t)| \end{cases} \quad (6)$$

$$\begin{cases} X_{\alpha}(t+1) = X_{\alpha}(t) - A_1 \cdot (D_{\alpha}) \\ X_{\beta}(t+1) = X_{\beta}(t) - A_2 \cdot (D_{\beta}) \\ X_{\delta}(t+1) = X_{\delta}(t) - A_3 \cdot (D_{\delta}) \end{cases} \quad (7)$$

$$X_{\omega}(t+1) = \frac{X_{\alpha}(t) + X_{\beta}(t) + X_{\delta}(t)}{3} \quad (8)$$

式中: t 表示迭代次数; A 和 C 均为系数向量; D 表示位置变换信息; $X(t)$ 表示当前迭代次数下灰狼的位置向量。

系数 A 和 C 分别定义为

$$A = r_0(2r_1 - 1) \quad (9)$$

$$C = 2 \times r_2 \quad (10)$$

式中: r_0 的分量在迭代过程中从 2 线性减小到 0, r_1 和 r_2 是 [0,1] 之间的随机向量。

随机向量 r_1 和 r_2 允许狼到达空间内的任何位置。系数 A 是区间 $[-r_0, r_0]$ 中的随机值, 控制灰狼向猎物方向收敛和发散; 系数 C 是区间 [0,2] 的随机值, 可以视为灰狼狩猎路径上的障碍。为提升基本灰狼优化算法的性能, 使用改进步长欧式距离的比例权重^[7], 其表达式为:

$$W_1 = \frac{|X_{\alpha}(t)|}{|X_{\alpha}(t)| + |X_{\beta}(t)| + |X_{\delta}(t)|} \quad (11)$$

$$W_2 = \frac{|X_{\beta}(t)|}{|X_{\alpha}(t)| + |X_{\beta}(t)| + |X_{\delta}(t)|} \quad (12)$$

$$W_3 = \frac{|X_{\delta}(t)|}{|X_{\alpha}(t)| + |X_{\beta}(t)| + |X_{\delta}(t)|} \quad (13)$$

最终的灰狼位置更新方式可表示为:

$$X_{\omega}(t+1) = \frac{W_1 X_{\alpha}(t) + W_2 X_{\beta}(t) + W_3 X_{\delta}(t)}{3} \quad (14)$$

不断更新候选解 ω 狼, 若每一层级有优于当前值的更优解, 则替换该层级的值, 否则保持不变。当候选解 ω 狼不再更新, 或者当前迭代次数是达到最大值 t_{\max} 时, 则结束迭代, 得到的第一层级 α 狼的值, 即为所求的最优解。

2.2 基于灰狼优化的 k 均值聚类算法

传统均值聚类算法对聚类中心的选取采用算术平均值的方式, 因此聚类结果容易陷入局部最优解的情况。改进的均值聚类算法是在使用灰狼优化算法的基础上提出的, 在一定程度上解决了聚类中心选择不当的问题^[8]。详细算法步骤见表 1 所示。

表 1 基于灰狼优化的均值聚类算法步骤

输入: 点云数据 $P' = \{p'_1, p'_2, \dots, p'_N\}$; 聚类簇数 K ; 最大迭代次数 t_{\max}
输出: 簇划分为 $\{M_1, M_2, \dots, M_K\}$

算法步骤:

- 1: 从 P' 中随机选择 K 个点作为初始聚类中心 $O = \{o_1, o_2, \dots, o_K\}$
- 2: repeat
- 3: 令 $M_i = \emptyset (1 \leq i \leq K)$
- 4: for $j = 1, 2, \dots, N'$: do
- 5: 计算点 p'_j 与各聚类中心 o_i 的距离: $d_{ji} = \|p'_j - o_i\|_2$;
- 6: 根据距离最近的聚类中心确定的 p'_j 簇标记: $\lambda_j = \arg \min_{i \in \{1, 2, \dots, K\}} d_{ji}$;
- 7: 将样本 p'_j 划入相应的簇: $M_{\lambda_j} = M_{\lambda_j} \cup \{p'_j\}$
- 8: end for
- 9: for $i = 1, 2, \dots, K$: do
- 10: 使用灰狼优化替换新的聚类中心: $O = \{o'_1, o'_2, \dots, o'_K\}$
- 11: if $o_i \neq o'_i$ then
- 12: 将当前聚类中心 o_i 替换为 o'_i
- 13: else
- 14: 保持当前聚类中心不变
- 15: end if
- 16: end for
- until 聚类中心不再更新

2.3 点云细粒度简化

首先基于上述算法获取到的 K 个类簇, 分别计算每一类簇中点的均方根曲率 C_j^i , 其中 j 表示所在类簇数, i 表示对应类簇数的点, 使用抛物面估算曲率^[9], 计算过程如下:

设抛物面方程为

$$z = ax^2 + bxy + cy^2 \quad (15)$$

式中: p'_i 的邻域内有 k 个点。

采用 Householder 变换法求解 p'_i 及其邻域的最小二乘抛物面拟合系数 a 、 b 、 c , 得到点 p'_i 的均方根曲率 C_j^i 为:

$$C_j^i = \sqrt{\frac{(a+c)^2 + b^2}{2}} \quad (16)$$

若 $C_j^i < \bar{C}_j^i$, 则视为该点的特征信息较少, 因此去掉该点; 否则视为该点特征信息丰富, 保留该点。其中 \bar{C}_j^i 为该点所在类簇的平均均方根曲率。

3 自适应调整点云简化程度

自适应调整点云简化程度, 用来满足不同应用场景下的简化要求, 例如数据量大的点云需要在粗粒度简化过程中过滤掉大量冗余点, 为细粒度阶段减少计算负担; 数据量小的点云无需在粗粒度阶段耗费大量时间, 但是需要在细粒度简化过程中强化特征保持。文中使用信息熵^[10]描述点云特征信息, 其具体实现公式如下:

$$P_s = \xi \left[\frac{f(P) - f(P')}{f(P)} \right] + (1 - \xi) \left[\frac{f(P') - f(P'')}{f(P')} \right] \quad (17)$$

式中: ξ 为比例因子, $f()$ 为点云信息熵, 其具体表达式为:

$$f(P) = -\frac{1}{N} \sum_{i=1}^N (v_i \log_2 v_i + \sum_{j=1}^k v_j \log_2 v_j) \quad (18)$$

$$v_i = \frac{H_i}{\left(H_i + \sum_{j=1}^k H_j \right)} \quad (19)$$

式中: v_i 和 v_j 分别为 i 和 j 点的曲率概率分布, 点 j 是点 i 邻域内的点; H_i 为 i 点的平均曲率; k 为点 i 邻域内点的个数。

4 本方案实现步骤


基于以上的粗细粒度两大模块, 本方案的具体实现步骤如表 2 所示。

表 2 本方案的实现步骤


输入: 原始点云数据 $P = \{p_1, p_2, \dots, p_N\}$ 输出: 简化点云数据 P_s
<p>算法步骤:</p> <ol style="list-style-type: none"> 1: 根据式 (2) 和式 (3) 计算体素化网格边长 L_s, 分割原始点云 P 2: for $i = 1, 2, \dots, N$: do 3: 计算点 p_i 与其邻域点法向量夹角的算术平均值 w_i 4: 保留 $w_i > \varepsilon$ 且 d 最小的点作为特征点 5: end for 6: for $i = 1, 2, \dots, N'$: do 7: 使用灰狼聚类得到 K 个聚类结果: $\{M_1, M_2, \dots, M_K\}$ 7: for $j = 1, 2, \dots, K$: do 8: 计算每一类簇每一个点的均方根曲率 C_j^i 和各类簇平均均方根曲率 \bar{C}_j^i 9: 保留 $C_j^i > \bar{C}_j^i$ 的点 10: end for 11: end for 12: 根据式 (17) 进行特征融合

5 实验结果与分析

实验环境配置为 Intel(R) Core(TM) i5-7200U CPU @ 2.50 GHz 的处理器、8 GB 的内存, 采用的编程软件为 MATLAB 2022。实验采用公共点云数据模型 Bunny、Dragon 和 Horse^[11] 验证本文方案, 且分别设置 $\xi = 0.55, 0.35, 0.6$, 同时使用简化率、最大误差、平均误差评估点云简化质量。在尽量保证简化率一致的情况下, 采用随机采样法、曲率简化法以及所提简化方案对各模型进行简化处理, 其简化对比结果如图 1、图 2、图 3 和表 3 所示。




(a) 待简化的 Bunny 模型



(b) 随机采样法



(c) 曲率简化法



(d) 本方案

图 1 不同算法下 Bunny 模型点云简化效果



(a) 待简化的 Dragon 模型



(b) 随机采样法




(c) 曲率简化法




(d) 本方案


图 2 不同算法下 Dragon 模型点云简化效果




(a) 待简化的 Horse 模型



(b) 随机采样法



(c) 曲率简化法



(d) 本方案

图 3 不同算法下 Horse 模型点云简化效果

表 3 三种算法对公共点云的简化结果对比

公共点云	原始点数目	简化算法	简化率 %	最大误差 /mm	平均误差 /mm	简化时间 /s
Bunny	35 947	随机采样法	60.4	0.674 3	0.155 7	0.47
		曲率简化法	58.8	0.293 3	0.074 3	8.49
		本文简化方案	59.3	0.179 6	0.021 4	10.25
Dragon	437 645	随机采样法	81.5	0.967 8	0.370 5	0.87
		曲率简化法	78.5	0.874 2	0.279 9	15.53
		本文简化方案	79.1	0.423 7	0.132 4	18.48
Horse	48 484	随机采样法	71.5	0.852 8	0.271 7	0.45
		曲率简化法	62.9	0.701 4	0.178 8	7.56
		本文简化方案	65.8	0.367 9	0.086 5	9.79

从图 1、图 2、图 3 和表 3 的简化结果可见, 本文提出的简化方案具有最低的简化误差, 能够较好地保留公共点云模型的几何特征, 没有出现过度简化或简化不足的情况, 是一种有效的点云简化方案。具体分析如下: 使用随机采样法对公共点云模型进行简化时, 各模型均出现不同程度的孔洞现象, 这是由于随机采样法通过随机采样函数对原始点云数据进行采样, 简化结果随机, 不利于后期模型重建处理; 从可视化结果上来看, 曲率简化法在保留显著几何特征方面优于随机采样法, 但仍存在简化结果出现孔洞的情况, 这是因为曲率简化法通过计算数据点的曲率特征来实现点云的简化, 虽然能够有效地提取点云的细节几何特征, 但容易对曲率变化较小的区域造成过度简化的结果。与曲率简化法相比, 本方案在相似的简化率下既保留了模型的显著几何特征, 又适度精简了曲率变化不明显的区域。这是因为多粒度抽取特征训练的模型性能明显优于仅使用单一粒度抽取特征的模型。另外, 虽然曲率简化法和本方案与随机采样法相比, 都涉及特征值的计算, 从而增加了时间成本, 但前两者在时间运行结果上相差不多。

6 结论

本文基于单粒度抽取特征的简化算法存在点云模型表面光滑部分处理性能较差的问题, 提出一种多粒度的特征融合点云简化方案, 使用粗细两种粒度对点云进行分步简化, 以结合两种粒度的特征信息, 保证算法在简化过程中不仅能减少特征损失, 还能提高光滑曲面处理性能。简化过程中引入自适应增长因子, 使体素网格边长根据期望点云数量实现自适应调节, 同时结合主成分分析法获取点云特征值, 其主要目的是在减少数据冗余的同时保留显著几何特征, 最后采用基于灰狼优化的 k 均值聚类算法, 通过不断优化迭代得到全局最优的聚类结果, 并根据聚类结果完成二次简化。此方案简化出的点云在误差性能方面明显优于文中的对比算法。另外, 从算法的时间复杂度上来看, 本方案虽然使用多粒度进行简化, 但并没有增加过多的时间成本。但是, 该方案仍存

(下转第 82 页)

2008: 10-14.

- [7]LIANG L, LIN L, et al.SCUT-FBP5500: a diverse benchmark dataset for multi-paradigm facial beauty prediction[C]//2018 24th International conference on pattern recognition (ICPR). Piscataway: IEEE, 2018:1598-1603.
- [8]ZHANG Y, YIN Z F, LI Y, et al.Celeba-spoof: large-scale face anti-spoofing dataset with rich annotations[C]//Computer Vision-ECCV 2020: 16th European Conference.Berlin:Springer, 2020: 70-85.
- [9]ZHANG K, ZHANG Z, LI Z, et al.Joint face detection and alignment using multitask cascaded convolutional networks[J].IEEE signal processing letters, 2016,23(10): 1499-1503.
- [10]LIANG L, LIN L, JIN L, et al.SCUT-FBP5500: a diverse benchmark dataset for multi-paradigm facial beauty prediction[C]//2018 24th International conference on pattern recognition (ICPR). Piscataway: IEEE, 2018:1598-1603.
- [11]ZHANG N, PALURI M, RANZATO M A, et al.Panda: pose aligned networks for deep attribute modeling[C]//Proceedings of the IEEE conference on computer vision and pattern recognition. Piscataway: IEEE, 2014:1637-1644.
- [12]LIU Z, LUO P, WANG X, et al.Deep learning face attributes in the wild[C]//Proceedings of the IEEE international confer-

ence on computer vision.Piscataway:IEEE,2015:3730-3738.

- [13]RUDD E M, GÜNTHER M, BOULT T E. Moon: a mixed objective optimization network for the recognition of facial attributes[C]//Computer Vision-ECCV 2016: 14th European Conference.Berlin:Springer,2016:19-35.
- [14]DING H, ZHOU H, ZHOU S, et al.A deep cascade network for unaligned face attribute classification[C]//Proceedings of the AAAI Conference on Artificial Intelligence. Menlo Park: AAAI, 2017: 6789-6796.
- [15]CAO J, LI Y, ZHANG Z. Partially shared multi-task convolutional neural network with local constraint for face attribute learning[C]//Proceedings of the IEEE Conference on computer vision and pattern recognition.Piscataway: IEEE, 2018: 4290-4299.

【作者简介】

孟宣彤(1993—),女,江苏徐州人,硕士,助教,研究方向:计算视觉。

修杨(1991—),女,江苏徐州人,硕士,讲师,研究方向:信息系统安全。

陈慧(2003—),女,江苏盐城人,本科,研究方向:计算视觉。

(收稿日期:2024-05-29)

(上接第76页)

在一些不足之处。首先,实验数据均采用噪声处理后的点云模型,并未考虑大量噪声对简化结果的影响;其次,该方案可能对于某些特定的点云数据结构不够鲁棒。为了进一步提高算法的鲁棒性,后续研究将基于这些问题做出改进。

参考文献:

- [1]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):89-97.
- [2]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):130-137.
- [3]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.
- [4]赵夫群,汤慧.层次化的散乱点云简化算法[J].激光与光电子学进展,2022,59(18):213-219.
- [5]胡志新,曹刘洋,裴东芳,等.自适应精简点云改进预处理优化三维重建算法[J].激光与光电子学进展,2023,60(20):227-232.
- [6]MIRJALILI S, MIRJALILI S M, LEWIS A. Grey wolf optimizer[J].Advances in engineering software, 2014, 69: 46-61.

[7]张阳,周溪召.求解全局优化问题的改进灰狼算法[J].上海理工大学学报,2021,43(1):73-82.

[8]刘佳鸣.基于灰狼优化的均值聚类三维点云数据简化算法研究[D].太原:中北大学,2020.

[9]周绿,林亨,钟约先,等.曲面重构中测量点云精简方法的研究[J].中国制造业信息化,2004(5):102-104.

[10]DONG L, LI X. Evolution of urban construction land structure based on information entropy and shift-share model: an empirical study on Beijing-Tianjin-Hebei urban agglomeration in China[J].Sustainability,2022,14:14031244.

[11]The stanford 3D scanning repository[EB/OL].(1996-09-10)[2024-05-20].<http://graphics.stanford.edu/data/3Dscanrep>.

【作者简介】

喻萍(1999—),女,重庆奉节人,硕士研究生,研究方向:三维点云数据处理。

郭晔(1961—),女,陕西泾阳人,硕士研究生,教授,硕士生导师,研究方向:知识管理与Web数据挖掘、信息化教育研究。

(收稿日期:2024-05-20)