

基于改进自适应 k 均值聚类的三维点云骨架提取的研究

鲁斌¹ 范晓明¹

摘要 针对三维点云中心骨架提取问题, 提出一种基于改进的自适应 k 均值聚类预分割引导的点云骨架提取算法. 首先, 将输入点云体素化, 利用八叉树算法覆盖输入点云并下采样实现点云化简; 其次, 在采样点中自适应选取初始聚类中心对点云进行区域划分, 并颜色标记; 最后, 在区域分割的引导下应用 L_1 -中值骨架提取算法实现点云骨架的提取. 该算法主要针对 L_1 -中值算法可重复性差、易丢失细节等缺点进行了改进, 并且对输入点云的质量以及形状的几何或拓扑信息, 都没有严格的先验要求, 可以直接应用到未经任何预处理、含有噪声或离群点的初始扫描点云上. 展示了从多种不规则点云提取的骨架结果, 包括矮小植物、人体动作等. 与传统算法相比, 该算法具有高准确率、强鲁棒性、强学习扩展能力等优点.

关键词 骨架提取, 自适应聚类, L_1 -中值算法, 八叉树采样, 区域引导

引用格式 鲁斌, 范晓明. 基于改进自适应 k 均值聚类的三维点云骨架提取的研究. 自动化学报, 2022, 48(8): 1994–2006

DOI 10.16383/j.aas.c200284

Research on 3D Point Cloud Skeleton Extraction Based on Improved Adaptive k -means Clustering

LU Bin¹ FAN Xiao-Ming¹

Abstract Aiming at the extraction problem of three-dimensional point cloud center skeleton, a point cloud skeleton extraction algorithm based on improved adaptive k -means clustering pre-segmentation guidance is proposed. Firstly, the input point cloud was voxelized and the octree algorithm was used to cover the input point cloud and to simplify the point cloud. Secondly, the initial clustering center is selected adaptively from the sampling points to divide the region of the point cloud, and the color is marked. At last, under the guidance of region segmentation, L_1 -medial skeleton extraction algorithm is applied to extract the point cloud skeleton. This algorithm is mainly aimed at the poor repeatability of L_1 -median algorithm, easy to lose details and other shortcomings, and there are no strict prior requirements for the quality and geometric or topological information of the input point cloud, which can be directly applied to the initial scanning point cloud without any preprocessing, containing noise or outliers. This paper presents the results of skeleton extracted from a variety of irregularly shaped point clouds, including dwarf plants and human movements. Compared with the traditional algorithm, this algorithm has the advantages of high accuracy, strong robustness and strong learning and expansion ability.

Key words Skeleton extraction, adaptive clustering, L_1 -median algorithm, octree sampling, region guided

Citation Lu Bin, Fan Xiao-Ming. Research on 3D point cloud skeleton extraction based on improved adaptive k -means clustering. *Acta Automatica Sinica*, 2022, 48(8): 1994–2006

随着三维扫描技术和建模技术的不断发展, 点云模型已经被广泛地应用于实际的生产生活和科学研究^[1], 相关的模型处理技术也在不断地深入. 骨架模型^[2]作为三维模型的概括型表现形式, 直观地显示了模型的拓扑连接性和几何结构, 目前已有许多三维处理技术如三维重建^[3]、模型分割^[4-5]、点云配准^[6-7]和模型形状检索^[8-10]等以此为基础实现. 因此, 三维点云技术的飞速发展及模型种类的不断增多对骨架

提取算法的准确性提出了更高的要求. L_1 -中值骨架提取算法^[11]因其快速高效的特点, 被广泛地应用于点云模型骨架提取中. 该算法基于全局中值的思想, 提出应用局部中值对点云提取初始骨架, 通过不断扩大邻域半径达到针对不同区域实现不同程度收缩的目的; 同时, 根据点分布情况引入了引力约束和斥力约束来实现规整化, 可以快速计算出较好的一维骨架. 但该算法也存在随机采样造成的可重复性差, 密度不均匀情况下采样很容易丢失细节, 以及基于阈值的骨架伸长导致的错误骨架连接等问题.

本文针对以上缺点, 提出了一种基于改进的自适应 k 均值 (k -means) 聚类引导的 L_1 -中值骨架提取算法, 主要的流程图如图 1 所示. 给定一个三维

收稿日期 2020-05-07 录用日期 2020-09-14

Manuscript received May 7, 2020; accepted September 14, 2020

本文责任编辑 吴毅红

Recommended by Associate Editor WU Yi-Hong

1. 华北电力大学计算机系 保定 071000

1. Department of Computer, North China Electric Power University, Baoding 071000

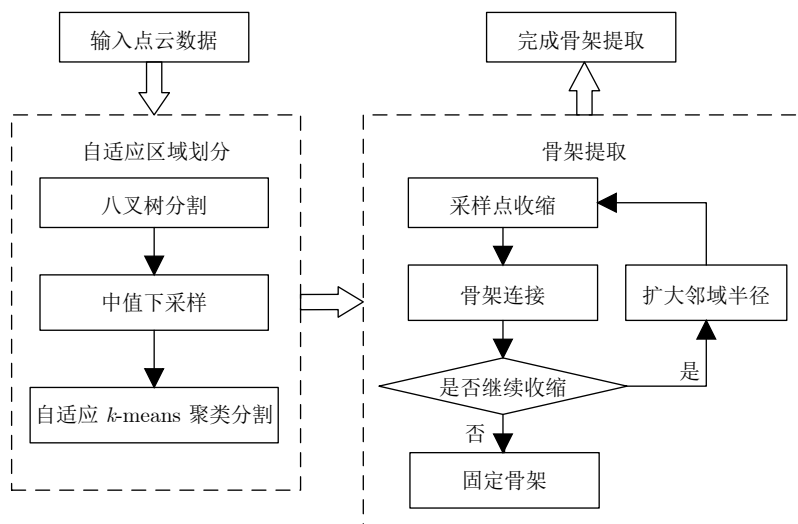


图 1 本文算法流程图

Fig.1 Flow chart of our proposed algorithm

点云模型, 首先采用八叉树对散乱点云进行组织, 每个体素基于当前密度包含的点数不一; 在此结构下完成中值采样, 并利用采样点集自适应确定初始聚类中心实现 k 均值区域划分, 应用局部中值迭代收缩得到各区域内的骨架分支; 最后通过对 L_1 局部分支拟合曲线完成骨架平滑及连接. 本算法将密度因素及野点的影响考虑到采样问题中, 保证模型的细节不会丢失, 同时减少了后续骨架提取的迭代次数; 区域划分约束下提取骨架, 解决了跨区域连接错误的问题. 实验结果表明, 本文算法与 L_1 -中值骨架提取算法相比, 有效地提升了点云骨架的准确性与可重复性, 可以达到更好的提取效果.

1 国内外研究现状

最经典的骨架提取技术是 Blum^[12] 在 1967 年提出的中轴变换, 该方法能够快速地提取二维形状内部的一维骨架 (中轴线), 但对形状表面的噪声十分敏感. Dey 等^[13] 首先定义了模型中轴面的子集为三维模型的一维曲线骨架. Cornea 等^[14] 对现有的一维曲线骨架提取技术做了很好的综述, 提出了理想骨架应该具有的属性. 虽然骨架并没有一个完全统一、标准的定义, 但大多数骨架提取的方法都运用了中轴的概念, 满足中心性; 同时, 骨架又不同于中轴, 中轴能够感知到模型的边界上比较微弱的扰乱, 而曲线骨架必须要具备较少的对模型边界上的声音的感知能力, 具有鲁棒性.

近年来, 国内外学者对于点云骨架提取问题做了大量的研究工作, 可以概括为以下几类: 1) 距离变换法: 基于几何三维结构的整体分析, 对节点进行距离变换计算, 形成距离场, 通过筛选出局部极

值点作为骨架点来达到构建整体骨架的目的. 此方法在解决整体性比较好、细节不多的模型时效果明显, 对于模型重构也有着很好的借鉴意义, 但在离散域中, 节点之间的关系无法准确定位, 得出的骨架大多不连续, 效果较差. 2) Laplace 收缩法: 由 Au 等^[15] 提出的基于网格的骨架提取代表方法之一, 运用 Laplace 算子的收敛特性, 通过反复平衡牵引将网格收缩到模型的中间位置, 可以处理少量点云缺失问题, 目前应用较为广泛. 因需要反复调整 Delaunay 三角网格, 故时间复杂度较高. 3) 广义旋转对称轴法: 利用平滑切割的迭代算法来计算点云的旋转对称轴, 然后对非圆柱形连接区域进行特殊处理以得到一维曲线骨架. 该方法利用旋转对称性可以实现有效地缺失弥补, 但其前提假定模型是圆柱形的, 并且过多的预处理操作极大地增加了时间复杂度. 4) 空间中轴法: Huang 等^[11] 提出的基于局部中值^[16] 迭代收缩实现骨架提取的算法, 可以有效抵御野点的影响, 避免了传统骨架提取方法中的预分割和人工编辑操作, 具有较好的应用前景.

表 1 列举了这 4 类方法最近几年的代表性文章, 并分析了各自的优缺点和适用范围. 随着研究的不断深入, 学者们也结合其他方法对 L_1 -中值算法进行了扩展, 在适用范围内都取得了不错的效果.

本文还整理了 2011 ~ 2019 年点云骨架提取方向的国内外论文共 158 篇, 基于年度论文发表数量及论文数量累计和绘制了图 2 所示的柱形-折线图. 总体上说, 研究该方向的论文并不是特别多, 但随着骨架提取作为前置工作与三维重建、点云分割、目标检测等领域技术的结合, 该方向关注度呈螺旋式上升的趋势.

表 1 三维点云骨架提取方法的比较

Table 1 Comparison of three-dimensional point cloud skeleton extraction methods

骨架提取方法	代表性文章	关键点	优点	缺点
距离变换法	Zhou 等 ^[17] 提出了一种基于距离场对三维模型体素化编码的方法	将连续的中间点连接为体素路径, 经过细化、平滑操作得到骨架	计算简单, 且对边界复杂性不敏感	离散域中得到的骨架往往不连续
	Song 等 ^[18] 提出了一种基于距离场引导的 L_1 -中值骨架提取算法	利用距离场多尺度参数细化方法提取初始骨架, 之后引入 L_1 -中值算法进行骨架优化	利用距离场得到的初始骨架可有效地引导 L_1 -中值算法采样点的移动, 且弥补了骨架不连续的缺点	对于大面积缺失的点云提取效果很差, 另外计算距离场时间复杂度高
	Hu 等 ^[19] 提出了一种通过距离场和曲率结合捕获特征点的三维点云曲线骨架提取算法	为 3D 点云模型提供距离场的替代, 通过特征点移动和聚类形成骨架	对于数据缺失严重的点云模型, 仍能很好的保持骨架的中心性, 不产生虚假分支	对于表面平坦的模型, 特征点容易被识别错误, 从而导致错误骨架
Laplace 收缩法	Cao 等 ^[20] 提出了一种基于 Laplace 算子的收缩提取曲线骨架的算法	通过局部 Delaunay 三角剖分和拓扑细化来处理点云, 从外向内迭代收缩从而提取骨架	具有强大的抗噪能力, 可以处理丢失少量数据的点云	易在局部点云上出现过收缩, 骨架准确性严重依赖于 Laplace 算子参数
	Erdal 等 ^[21] 提出了一种将 Laplace 收缩与 L_1 -中值收缩相结合的算法	在 Laplace 迭代收缩后的点云上应用 L_1 -中值骨架提取算法	两种方法的收缩过程都是基于点的邻域完成的, 实现了优势互补, 减少了迭代次数	参数设置不准确, 极易产生错误骨架
	Wu 等 ^[22] 提出了一种基于改进 Laplace 实现玉米植株点云骨架提取的算法	应用并改进了 Laplace 骨架提取方法, 并通过自适应采样选择骨架关键点, 相邻点连接形成植物骨架。	能够准确提取植物骨架, 能够逼近植株器官的几何中心, 如叶脉和茎的中轴	骨架结果严重依赖于扫描点云的质量
广义旋转对称轴法	Tagliasacchi 等 ^[23] 提出了 ROSA 法来实现模型骨架的提取	基于模型的旋转对称性, 利用邻域内点的法向量垂直环绕于中轴伸长方提取骨架	对于大面积缺失的多分支点云, 提取的骨架仍能正确的表示原始模型的拓扑结构	过多的预处理极大地增加了时间复杂度, 多用于圆柱形模型
	Jayadevan 等 ^[24] 提出了一种形状分解的方法对三维点云模型进行骨架提取	充分运用通用圆柱体的平移对称属性对三维点云模型进行形状分解, 分别提取骨架再进行连接	可以很好地处理平面点云, 得到直线骨架; 可通过可视化调整参数以得到更好的效果	骨架连接有时较为死板, 导致不自然的骨架
	Fu 等 ^[25] 提出了一种利用圆柱形先验约束优化提取骨架的算法	通过八叉树和水平集方法提取初始骨架点, 之后采用圆柱形先验约束优化来提高骨架的中心性	使用关于树枝半径的先验知识来改进关节的不正确定位, 有效的提高了拓扑正确性和树骨架的中心性	专门为树点云设计, 无法拓展到其他类型的点云
空间中轴法	Huang 等 ^[11] 提出了基于 L_1 -中值实现骨架提取的算法	对点云应用局部中值提取初始骨架, 通过不断扩大邻域半径达到针对不同区域实现不同程度收缩的目的	可以在原始扫描数据上进行操作, 即不需要任何预处理	采样敏感, 且参数的设置对骨架提取结果影响大
	Su 等 ^[26] 提出一种基于分类枝叶和枝干的树木骨架提取方法	通过分类和分割方法将叶子和木材成分分离, 之后采用 L_1 -中值算法精确提取树骨架点	充分利用了树木叶片和枝干在结构及几何特征上的差异, 提取的骨架在形态上与树的点云具有良好的一致性	由于树叶的遮挡作用, 提取的骨架是不连续的
	Mei 等 ^[27] 提出一种 L_1 -MST 算法优化提取树骨架	利用 L_1 -中值提取粗骨架, 基于点的主导方向和局部点密度的迭代优化过程实现数据补全, 结合最小生成树法细化骨架	L_1 -MST 算法弥补了 L_1 -中值算法中因无法准确描述点的局部空间分布导致错误骨架连接的缺点	数据补全只能用于可见区域, 因此不能提取被遮挡区域的骨架

2 基于八叉树分割的点云化简

2.1 八叉树分割

将输入点云体素化, 利用八叉树算法覆盖输入点云. 选择基于指针区域的八叉树进行实验, 可以达到以下 3 个目的: 1) 把散乱点云数据有序组织好, 起到索引的作用; 2) 实现有计划地数据简化; 3) 为特征点估计定义邻域点.

八叉树分割方法递归地将空间上的所有节点都

分解成 8 个一样的子节点, 即在这个空间上的所有体素的几何信息是一致的^[28]. 图 3 为八叉树分割的示意图, 从递归结构上可以看出, 该方法使用树遍历算法来查找节点, 并且可以在节点上递归生成新节点, 具有良好的拓扑结构.

本文对于给定点云模型, 首先计算输入点云数据的一个包围框如图 4(a), 对其进行八叉树分割, 图 4(b)、图 4(c) 给出了分割过程示意图; 若子立方体内包含点云数据则保留, 否则抛弃如图 4(d), 重复上述步骤直至满足判别条件, 分割结果如图 4(e)




图 2 2011 ~ 2019 年点云骨架提取方向论文发表年度趋势图
Fig.2 Annual trend chart of the paper published in the point cloud skeleton extraction field from 2011 to 2019




图 3 八叉树分割示意图

Fig.3 Schematic diagram of octree segmentation

所示. 基于后续点云下采样对八叉树的要求, 采用固定的最小体素值作为判别条件, 此时均匀排列的体素网格代表着输入点云的局部表面特征.

2.2 八叉树中值下采样

基于密度进行下采样把采样点收缩为骨架点, 从而生成骨架. 对于一些点云密度不均匀的数据, 随机采样会使得密度较高的区域采样点多, 而密度较低的区域采样点少, 收缩得到的骨架容易丢失细节, 甚至出现较多的小骨架.

针对这种现象, 本文提出基于八叉树的中值下采样方法, 即取每个体素中包含的所有点的中值点作为采样点. 在此, 中值点是基于体素中心进行求解的, 计算公式:

$$x^* = \sum_{j \in J} \frac{q_j \omega_j}{\sum_{j \in J} \omega_j} \quad (1)$$

式中, $\omega_j = 1/\|C_J - q_j\|$. 当前体素的点集为 $\{q_j\}_{j \in J}$, C_J 是该体素中心, 即点集的均值中心, ω_j 表示点 q_j

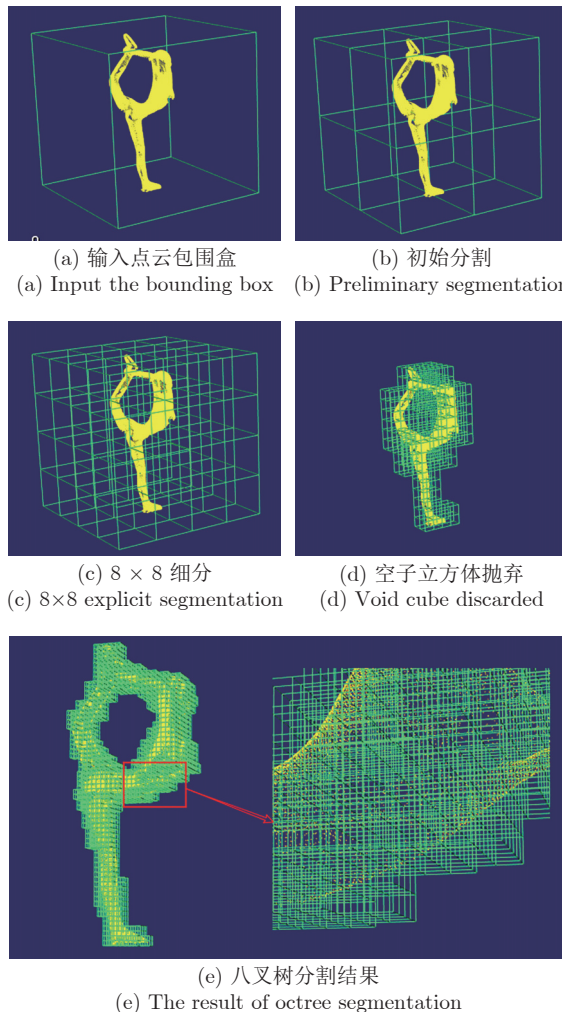


图 4 八叉树分割可视化结果图
Fig.4 Visualization result diagram of octree segmentation

的权重, 与该点到体素中心的距离成反比. 由式 (1) 可知, 距离越远的点权重越小, 对中值点的贡献率也就越小, 因此中值点更能抵御野点的影响.

具体实现如下: 首先通过八叉树进行点云数据组织并得到体素中心集合 (如图 5(a) 中心位置的点所示), 然后计算每个体素内的点到中心点的距离以赋予权重, 接着根据式 (1) 求得体素中值点, 最后作为采样点输出 (如图 5(b) 所示).

图 6 为植物模型点云中值下采样的过程及结果. 图 6(a) 为源点云; 图 6(b) 表示八叉树分割点云的可视化过程, 可以看出, 由于第 2.1 节中八叉树拆分的终止条件, 最终得到的体素大小都是一样的, 故可实现在点密集的区域和点稀疏的区域采样平衡, 达到消除质量差异的目的; 图 6(c) 中将基于体素中心的均值采样结果与本文采用的基于体素中值点的中值采样结果进行了对比, 左图均值采样得到




图 5 均值中心与中值中心对比图
Fig.5 The mean center versus the median center

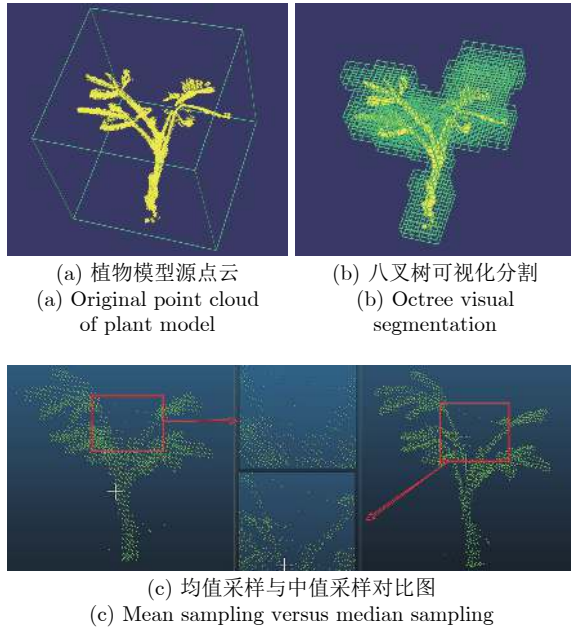


图 6 植物模型点云中值下采样
Fig.6 Median down-sampling of plant model point cloud

的采样点排列规整, 在保持源点云结构和尺度的基础上进行了简化, 右图中本文采样方法得到的采样点保留原有结构的同时对分支进行了细化, 如枝干部位, 这是因为取中值点作为采样点, 很好地利用了中值滤波, 起到弱化噪声点和离群点的作用。

因此, 基于八叉树的中值下采样方法, 不仅实现了基于密度的采样平衡, 而且基于中值思想得到的采样点集收敛于真实骨架, 大大减少了后续骨架提取的迭代次数。

3 自适应 k 均值聚类的区域划分

本文提出一种基于八叉树采样的自适应 k 均值聚类算法对点云模型进行划分, 主要考虑到以下三点: 1) 八叉树组织点云数据可以减少后续聚类的工作量; 2) 自适应聚类中心和类簇个数 k 可明显减少迭代次数, 同时降低人为误差; 3) 提前划分区域可

有效降低骨架错误连接的发生。

3.1 k 均值聚类算法

k 均值聚类算法^[29]的主要特征是随机确定 k 个初始聚类中心, 基于距离比较对源点进行归类划分并计算得到新的聚类中心, 进行下一轮迭代, 中心位置不变时结束归类. 归类的过程实际上也是最小化误差的过程, k 均值最小化, 是要最小化所有点与其关联的聚类中心点之间的距离之和, 即评估指标 (Sum of squared errors, SSE), 计算公式为:

$$SSE = \sum_{i=1}^k \sum_{p \in C_i} |p - m_i|^2 \quad (2)$$

式中, C_i 是第 i 个类簇, p 是 C_i 中的样本点, m_i 是 C_i 当前的聚类中心, k 值基于先验知识设定, 即类簇的个数, 也是点云区域的个数. SSE 是源点云中所有点的聚类误差平方和, 代表了聚类效果的好坏。

k 均值算法中, 选择最近的聚类中心归类, 是为了减小 p 引起的误差, 而重新定位聚类中心则是用于减小 m_i 引起的误差, 所以每一次迭代都会将误差最小化。

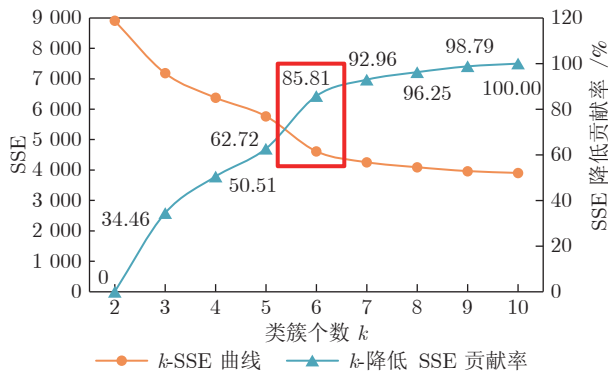
3.2 自适应 k 值

k 均值算法中涉及到类簇个数 k 的指定, 但在实际中 k 值的选择即给定点云划分的区域个数非常难以估计. 为降低因人为误差造成划分结果的不准确性以及最小化误差平方和 SSE, 本文采用肘部法则对 SSE 曲线图进行分析, 以自适应得到一个建议的 k 值。

肘部法则使用 SSE 作为性能度量, SSE 值越小则说明各个类簇越收敛. 但并不是 SSE 越小越好, 考虑极端情况下将采样点集内的每个点都视为一个类簇, 那么 SSE 的值降为 0, 显然达不到分类的效果. 肘部法则为本文提供的是在类簇数量与 SSE 之间寻求一个平衡点的方法。

应用肘部法则计算得到自适应 k 值的步骤如下: 1) 确定 k 值的上限 k_{\max} 和下限 k_{\min} , 即可能的最大类簇数和最小类簇数. 由于本文实验数据集均为结构清晰的实物点云模型, 且考虑到骨架提取对区域个数的约束, 本文设定 $k_{\max} = 10$, $k_{\min} = 2$; 2) 从 k_{\min} 递增至 k_{\max} , 计算出不同 k 值下的 SSE, 并绘制曲线图; 3) 曲线图下降途中的拐点所对应的 k 值, 则是相对最佳的类簇数量值. 此处以从 Fast-Scan 三维扫描仪采集的飞机模型为例, 得到如下 k -SSE 曲线图:

由图 7 可以看出, 当设定的类簇数不断接近最佳类簇数时, SSE 呈现快速下降态势, 而当设定类簇

图7 飞机模型点云的 k -SSE 关系曲线图Fig.7 k -SSE relation graph of aircraft model point cloud

数超过最佳类簇数时, SSE 仍会继续下降, 但下降态势趋于缓慢, 因此拐点处的 k 值已经达到了合适的分类效果, 即类簇数量与 SSE 之间的一个平衡点.

对于拐点的确定, 为避免目测法带来的人为误差且结合折线图的走势, 本文借鉴主成分分析中保留方差百分比的方法, 即 k 值的选取类似于主成分个数的选取, 可通过当前 k 值对误差平方和 SSE 的降低贡献率来判断, 计算公式:

$$\frac{SSE_{k_{\min}} - SSE_k}{SSE_{k_{\min}} - SSE_{k_{\max}}} \geq \mu \quad (3)$$

在图 7 所示的曲线图中, 拐点 $k = 6$ 处对 SSE 的降低贡献率已经达到了 85.81%, 拐点后的 k 值贡献率增加不大且接近 100%, 因此选取拐点为满足条件的最小 k 值. 经实验证明, μ 取 0.8 较为合适.

3.3 自适应 k 均值聚类中心

k 均值算法随机确定初始聚类中心, 很可能会收敛到局部最优. 实验证明, 初始聚类中心的好坏, 对聚类的效果以及算法的迭代次数都有着很明显的影

响. 最坏的情况如图 8(b) 所示, 两个初始点选在了同一个类簇中, 很有可能导致原本属于一个类簇的点被分成了两类. 另外, 初始中心最好选择数据中的点, 若中心在点云数据之外, 其移动到最终位置势必会增加迭代次数.

k -means++ 算法^[30] 的基本思想是, 初始聚类中心之间的相互距离要尽可能远. 结合以上分析, 并考虑到算法中距离计算的工作量, 本文在八叉树采样点集中使用 k -means++ 算法来确定初始聚类中心. 首先从采样点集中随机选择一个点作为第 1 个聚类中心, 之后对于每个采样点计算到最近的聚类中心的距离 $D(x)$, 轮盘赌法选出下一个点作为新的聚类中心, 直到得到 k 个中心点. 轮盘赌法中每个点被选择的概率与 $D(x)$ 成正比, $D(x)$ 越大, 被选

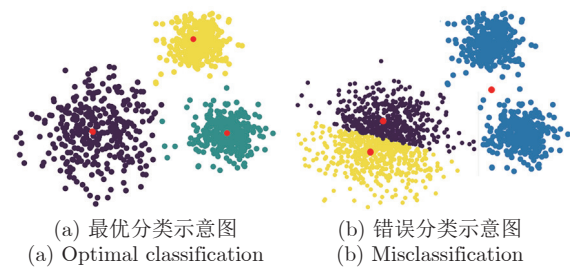


图8 初始中心位置导致分类结果不同

Fig.8 The initial center position results in different classification results

取作为聚类中心的概率也就越大.

图 9 给出了飞机模型点云自适应得到的 k 个初始聚类中心. 如图中圆点标注的位置, 初始聚类中心正好分散在最终得到的类簇中, 避免了因初始中心聚集而导致的迭代次数的大幅增加. 箭头上的数字表示自适应得到 k 个中心的先后顺序, 验证了 k -means++ 算法中相互距离尽可能的远的取点原则.

该方法可以实现初始聚类中心的分散选取, 从而减少聚类迭代次数, 大大改善了 k 均值算法的有效性. 算法流程如图 10 所示.

3.4 自适应 k 均值聚类的算法流程

基于八叉树采样的自适应 k 均值聚类算法流程如图 10 所示, 具体步骤如下:

步骤 1. 初始化 k 值的上下限参数 k_{\max} 、 k_{\min} 及贡献率阈值 μ , 并输入源点云及采样点云.

步骤 2. 令当前聚类个数为 k_{\min} , 在采样点云使用 k -means++ 算法自适应得到 k_{\min} 个初始聚类中心.

步骤 3. 基于初始聚类中心进行 k 均值聚类, 计算源点云所有点到每个聚类中心的距离, 选择最近的中心进行归类.

步骤 4. 更新 k 个聚类中心的位置, 取当前簇内所有点的平均值作为新的聚类中心. 计算先后中心的距离, 若存在中心点移动, 则返回步骤 3; 否则保存当前分类结果及误差平方和 SSE , k 的值加 1, 若 k 大于 k_{\max} , 进行下一步, 否则利用新 k 值返回步骤 2.

步骤 5. 在所有分类情况均完成后, 利用式 (3) 得到满足条件的最小 k 值, 即自适应类簇个数. 该 k 值下的分类结果即为所求.

步骤 6. 进行类簇染色, 使用不同颜色对类簇加以区分.

步骤 7. 停止算法, 输出点云.

图 11 给出了飞机模型点云完成自适应 k 均值聚类得到的分类结果. 可见, 该点云自适应区域个数 k 为 6, 箭头指向的点为最终的聚类中心, 数字表示当前类簇的索引值, 图中的线段标注, 表示初始聚类中心到最终聚类中心的直线距离, 因自适应初始聚类中心确定的好, 所以中心位置移动不大, 且

不存在跨区域移动, 大大减少了聚类的迭代次数.

图 12 分别给出了含羞草模型点云和瑜伽动作模型点云完成自适应 k 均值聚类得到的分类结果. 其中, 含羞草模型点云自适应区域个数 k 为 7, 瑜伽模型点云自适应区域个数 k 为 6.

4 骨架提取

4.1 骨架分支的生成

通过八叉树分割得到一系列采样点后利用 L_1 -中值骨架算法进行区域内骨架收缩提取. 骨架收缩

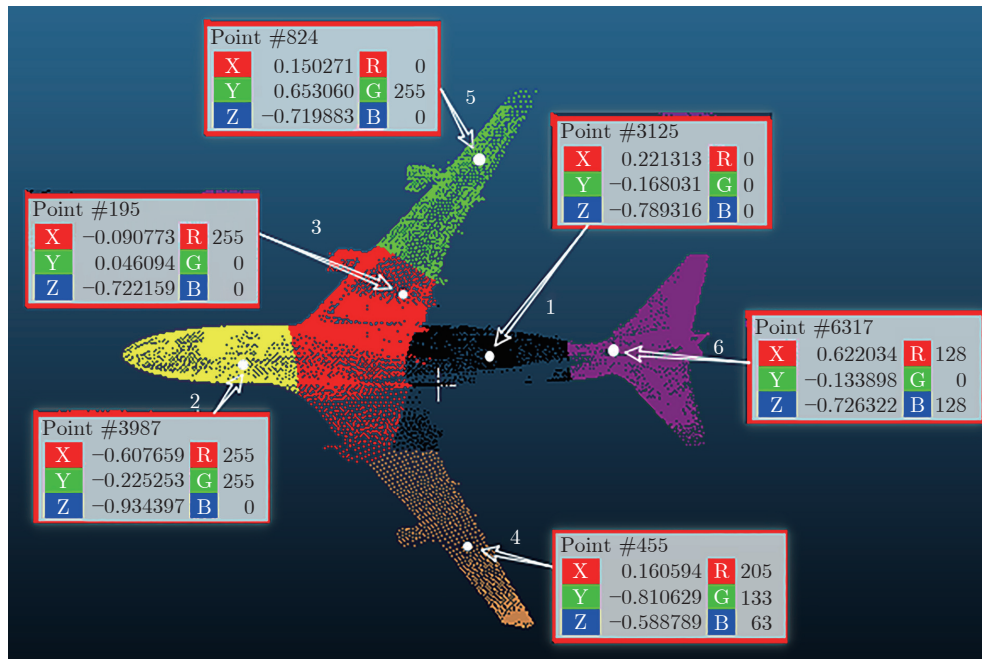


图 9 飞机模型点云的初始聚类中心

Fig.9 Initial cluster center of aircraft model point cloud

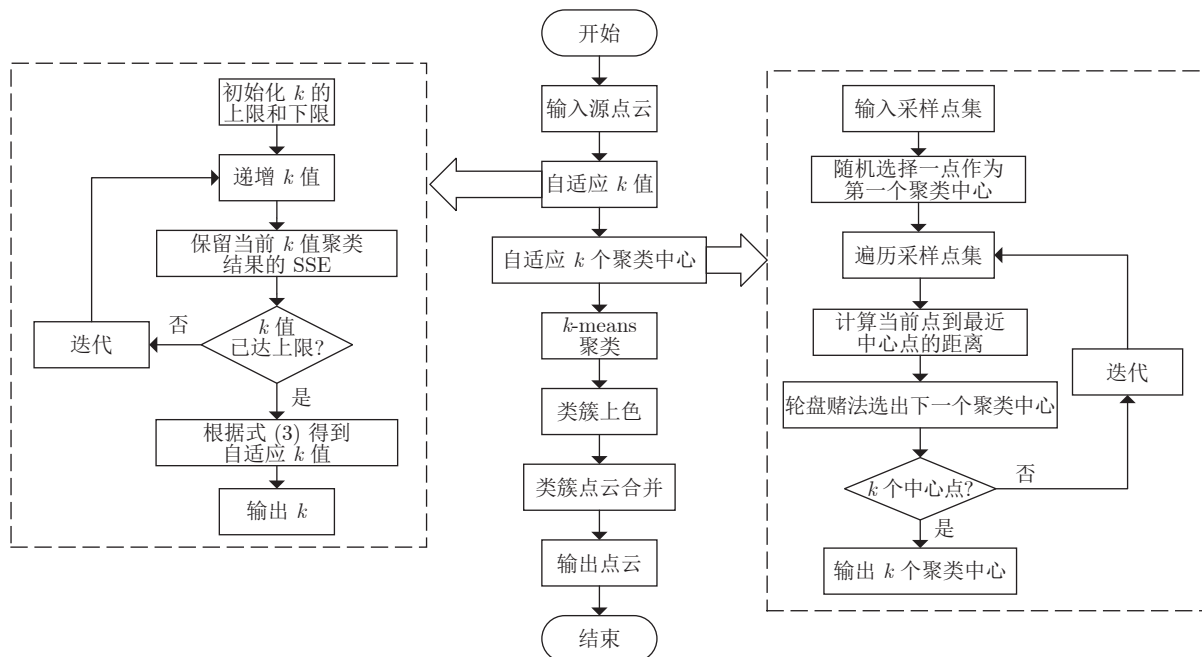
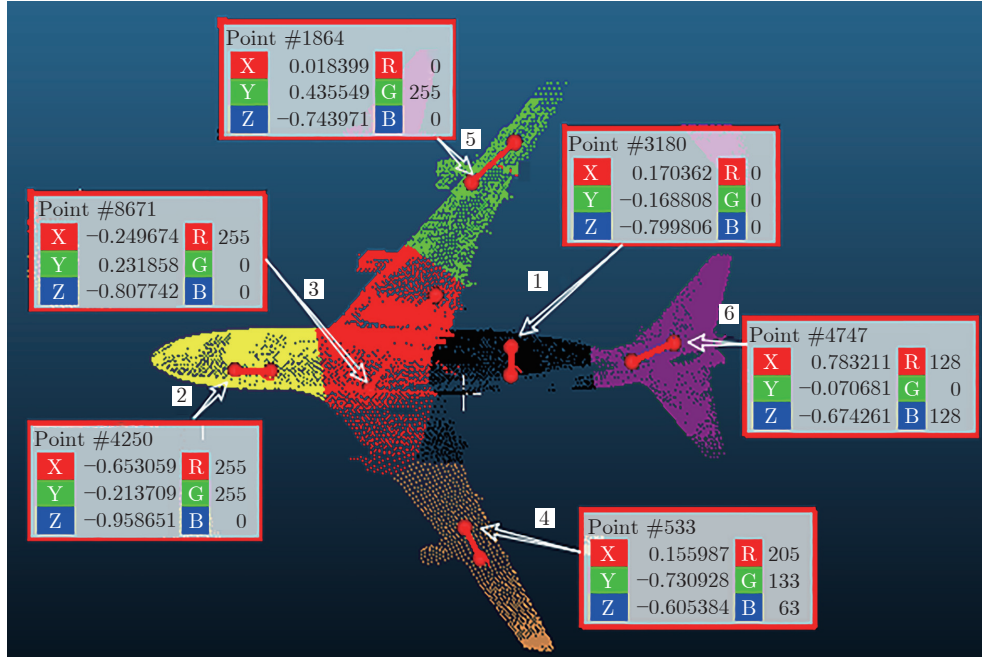



图 10 自适应 k 均值聚类算法流程图

Fig.10 Flowchart of adaptive k -means clustering algorithm

图 11 飞机点云自适应 k 均值聚类的分割结果Fig. 11 Adaptive k -means segmentation results of aircraft point cloud

(a) 含羞草模型分割结果
(a) Segmentation results of mimosa model

(b) 瑜伽模型分割结果
(b) Segmentation results of yoga model

图 12 自适应 k 均值聚类的分割结果Fig. 12 Adaptive segmentation results of k -means clustering

提取的基本思想是通过选取采样点邻域内的中值而不是平均值进行收缩, 产生新的骨架点, 不停地迭代并重新将其分配至所在区域的源点的中心. 直接应用 L_1 -中值算法往往会产生稀疏分布, 造成结果中的一些中心点过度收缩产生一团点簇. 为此使用了一个调整函数在局部空间中轴形成一种排斥力, 完成规整排布.

给定散乱采样点 $Q = \{q_j\}$, $j \in J \subset \Omega^3$, 以及对应邻域点 $X = \{x_i\}$, $i \in I \subset \Omega^3$, 利用最优式 (4) 可得到一系列骨架点:

$$\arg \min_X \sum_{i \in I} \sum_{j \in J} \|x_i - q_j\| \theta(\|x_i - q_j\|) + R(X) \quad (4)$$

$$R(X) = \sum_{i \in I} \gamma_i \sum_{i' \in I \setminus \{i\}} \frac{\theta(\|x_i - x_{i'}\|)}{\sigma_i \|x_i - x_{i'}\|} \quad (5)$$

$$\theta(r) = \exp \left[-4 \left(\frac{r}{h} \right)^2 \right] \quad (6)$$

式 (4) 中第 1 项确定局部 L_1 -中值收缩骨架点, 基于采样点在输入点集中的邻域点的引力作用向局部中值移动; 第 2 项规整项, 基于采样点集内的邻域点形成斥力, 避免收缩过近, 根据点分布情况^[31] 见式 (5), 其中 γ_i 是平衡引力和斥力的参数. $\theta(r)$ 是高斯权重函数, 由式 (6) 可知, 固定邻域半径下, 距离采样点越远, 所贡献权重也就越小, 从而起到了中值滤波的作用. 把式 (5) 代入 L_1 -中值求解项中得出:

$$x_i^{k+1} = \frac{\sum_{j \in J} \alpha_{ij} q_j}{\sum_{j \in J} \alpha_{ij}} + \mu \sigma_i^k \frac{\sum_{i' \in I \setminus \{i\}} (x_i^k - x_{i'}^k) \beta_{ii'}^k}{\sum_{i' \in I \setminus \{i\}} \beta_{ii'}^k} \quad (7)$$

式中, $\alpha_{ij}^k = \theta(\|x_i^k - q_j\|) / \|x_i^k - q_j\|$, $j \in J$; $\beta_{ii'}^k = \theta(\|x_i^k - x_{i'}^k\|) / \|x_i^k - x_{i'}^k\|^2$, $i' \in I \setminus \{i\}$; $\sigma_i^k = \sigma(x_i^k)$. 通过实验, μ 取值 0.35 较为合适.

实际情况中, 对于形状不规则的模型, 区域点集粗细不一, 给定一个邻域半径难免出现过收缩和欠收缩的情况. 为减少迭代次数, 本文提出一种基于区域划分的自适应半径骨架提取的算法, 针对不同区域设定不同的初始邻域半径, 避免由于初始半

径设定的太小导致迭代次数增加;以相同的增长率扩大半径,寻找新的分支并进行骨架连接,对于已经收缩到位的分支进行固定。

基于区域大小以及包含的源点数计算不同的邻域半径 h_0 , 实验发现,对于点数小于五万的点云收缩成骨架的最大邻域半径为 $3h_0$, 默认值 $h_0 = d_{bb}/\sqrt[3]{|J|}$, d_{bb} 是指该区域点云包围盒对角线长度, J 指该区域内源点云集合的点数。

4.2 基于区域的骨架连接

使用上述公式计算收缩得到的粗骨架,在连续性和平滑性这两点上还存在不足,甚至会影响到骨架的准确性,所以本文在原有最优化公式上添加了一个正则项,用于局部分支的曲线拟合,以形成密切联系骨架。定义以下平滑函数:

$$P(X) = \sum_{x_i, v(x_i) > 1} \left\| x_i - \frac{1}{v(x_i)} \sum_{x_j \in N(x_i)} x_j \right\|^2 \quad (8)$$

$N(x_i)$ 是该点的邻域点集, $v(x_i)$ 是邻域中点的个数。平滑函数 $P(X)$ 通过将邻域点的距离最小化,来优化骨架点的位置,得到局部拟合的曲线骨架。图 13(a) 中第 3 个点与它的相邻点不呈曲线分布,从数学角度来讲,即在空间坐标轴主方向贡献了方差。应用式 (8) 的平滑函数最小化方差,则得到了图 13(b) 中骨架点的平滑分布。





图 13 局部曲线拟合示意图


Fig. 13 Schematic diagram of local curve fitting

基于区域划分的骨架连接,由于本身是一个整体,每个区域一般都会存在跨区域连接。基于骨架分支拟合曲线,分支两个端点沿伸长方向加值延长至当前邻域半径的 2 倍,若与其他区域骨架点相交,则以相交点为端点固定该伸长分支,并进行标记,否则偏转角度进行连接;若与本区域内骨架点相交,则遍历该区域所有骨架是否已存在跨区域连接,若不存在,待本区域分支均连接完毕后,再伸长一个半径长度的活动段进行寻找,找到则连接,否则结束骨架连接,示意图见图 14。最后采用四边形细分的方法^[32]对骨架平滑化和椭圆拟合方法^[33]进行骨架中心化。



(a) 跨区域连接示意图 1

(a) Diagram 1 of cross-region connections



(b) 跨区域连接示意图 2
(b) Diagram 2 of cross-region connections

(c) 区域内连接示意图
(c) Schematic diagram of regional connection

图 14 骨架连接示意图

Fig. 14 Skeleton connection diagram

5 实验与分析

为验证算法的提取效果,本文选用点云由 FastScan 三维扫描仪采集,是没有经过任何预处理、包含噪声或离群点的非均匀密度的点云数据。该数据集^[1]包括植物、动物、静物和人体动作等 15 类三维模型,部分采用本文算法的骨架提取结果数据如表 2 所示。

图 15 是在情侣雕塑的点云模型上做骨架提取的结果,该模型由自适应 k 均值聚类算法大体对称地分为了 7 个区域,涉及多处跨区域环状连接。实验结果表明,本文算法可以很好地处理对称环状连接问题,得到平滑骨架。同时,点云模型中含有部分噪声和离群点,并且扫描出的点云密度并不均匀,在这种情况下,能够提取出较为理想的骨架,显示了算法的强鲁棒性。

图 16 是在瑜伽动作的点云模型上做骨架提取的结果,该模型属于四肢型动作模型的一种,身躯和四肢在区域大小、点数和形状上存在差异,且骨架提取在扁平区域很容易出现过度收缩的现象。实验表明,在采样点和区域分割约束下,提取的骨架具有较高的准确度,保留了骨架的连续性。

图 17(a) 含羞草模型中存在叶子点云密度不均匀及数据缺失的现象。提取的骨架结果表明,本文算法对原始点云的质量并没有严格的先验要求,仍

表 2 不同模型的实验结果对比
Table 2 Comparison table of experimental results of different models

模型	模型点数目	分割区域数	采样点数	本文算法迭代次数	L_1 -骨架提取算法迭代次数	本文算法运行时间(秒)	L_1 -骨架提取算法运行时间(秒)
鹿模型	22 568	7	6 128	180	275	16	21
情侣模型	43 545	7	9 222	241	301	39	58
人像模型	44 230	5	3 625	161	198	38	44
瑜伽模型	70 457	6	8 909	193	243	26	39
灯罩模型	30 065	9	15 986	186	267	31	43
树木模型	22 698	6	7 849	169	290	19	23




(a) 情侣模型
(a) Couple model



(b) 情侣模型骨架结果
(b) Skeleton result of couple model

图 15 情侣模型的点云骨架提取

Fig. 15 Point cloud skeleton extraction of couple model



(a) 瑜伽模型
(a) Yoga model



(b) 瑜伽模型骨架结果
(b) Skeleton result of yoga model


图 16 瑜伽模型的点云骨架提取

Fig. 16 Point cloud skeleton extraction of yoga model

可以提取出较为准确的骨架线, 具有强鲁棒性.

为进一步说明本文算法的优越性, 将其与 2 种最先进的骨架提取算法 L_1 -中值算法^[11] 和基于距离场引导的 L_1 -中值算法^[18] 进行了比较. 以下是分别在鹿模型、珊瑚模型和较复杂的树木模型上进行骨架提取的实验结果.

图 18 是鹿雕塑的点云模型做骨架提取的结果, 该模型上半部分包含细小分叉, 同时底部较分支部分尺度和点数都相差较大; 在图 18(b) 展示的 L_1 -中值骨架提取结果中, 丢失了很多骨架分支, 且存



(a) 含羞草模型
(a) Mimosa model



(b) 含羞草模型骨架结果
(b) Skeleton results of mimosa model

图 17 含羞草模型的点云骨架提取

Fig. 17 Point cloud skeleton extraction of mimosa model

在多处骨架连接错误, 造成这些现象的原因主要有 2 个: 1) L_1 -中值算法采用随机下采样使得原本点稀疏的分支点数减少以致无法形成骨架; 2) 骨架分支距离过近导致错误连接; 图 18(d) 方法^[18] 的结果除以上问题外, 还出现了错误的骨架闭环, 且该算法本身易受点云缺失的影响, 导致模型底部的骨架连续性较差; 然而这些在图 18(c) 本文算法得到的结果中有相当明显的改善, 本文通过八叉树中值采样保证分支的密度平衡, 以减少骨架的丢失, 另外区域划分对骨架连接进行了约束, 提高了骨架准确率.

图 19 是珊瑚雕塑的点云模型做骨架提取的结果, 该模型形状可看似骨骼明显的树形结构, 在图 19(b) 展示的 L_1 -中值骨架提取结果中, 多处出现骨架不连续, 提取效果较差; 图 19(d) 方法^[18] 相较于 L_1 -中值算法, 虽然在连续性上有所改善, 但仍然丢失了大量的骨架分支; 而图 19(c) 本文算法通过区域约束使得提取结果很好地保持了同一区域内骨架的连通, 且尽可能多的保留细节, 极少丢失骨架.

图 20 是树木点云模型做骨架提取的结果, 树木模型相对复杂, 含有较多错综连接的树杈及细小无形的枝叶, 且较为集中. 图 20(b) 展示的 L_1 -中值骨架提取结果中, 树木丢失了接近一半的骨架, 且枝叶部分几乎无骨架分支形成; 图 20(d) 方法^[18] 的结果中不仅丢失了较多关键骨架, 而且提取出的骨

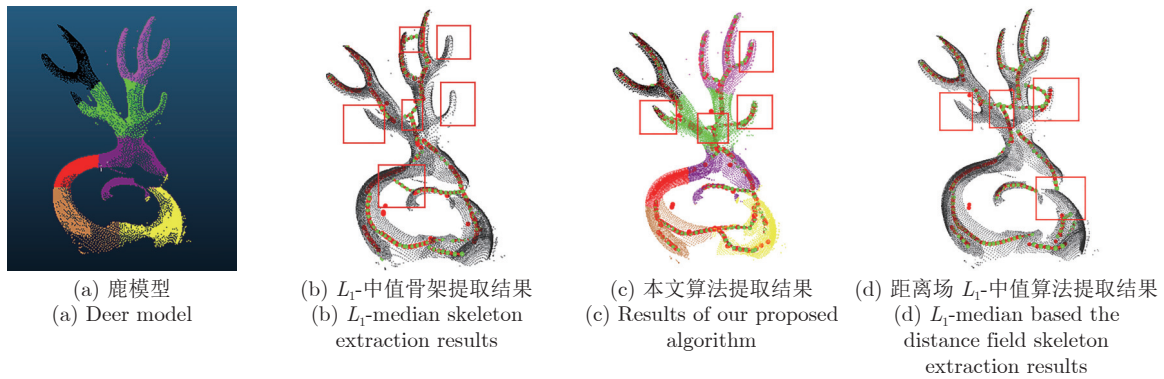


图 18 鹿模型的点云骨架提取对比结果

Fig. 18 Comparison results of point cloud skeleton extraction of deer model




图 19 珊瑚模型的点云骨架提取对比结果

Fig. 19 Comparison results of point cloud skeleton extraction of coral model

架离散不连通,效果较差;图 20(c)中本文算法通过区域划分首先将枝叶和树干分类隔开,分别提取骨架再进行连接,避免发生枝叶分离或提取不出骨架的情况,很好地保持了树干的拓扑结构,并且具有很好的连通性。

由以上对比实验可以看出,该算法提取的骨架比其他方法更准确,可有效地识别更多的分支。同时,实验部分所涉及模型的形状和拓扑结构各异,点云的密度也不尽相同,本文算法仍能得到很好地骨架提取结果,具有较好的适应性,未来可更好地应用于其他相关领域,具有较强的学习扩展能力。

但同时该算法也存在一些缺陷,均匀子空间采样在保留细节的同时偶尔会导致产生多余的小骨架,如图 21(b)标注,因恐龙脚部点云呈平面分布且离散而收缩成了两个骨架分支;另外,局部点云内部缺失严重时,易形成局部骨架闭环,如图 22(b)。

6 结束语

本文针对传统骨架提取算法中提取结果可重复

性差、易丢失细节及连接错误等问题,提出了一种基于改进的自适应 k 均值区域划分的骨架提取算法,对骨架提取和连接进行约束。该算法利用八叉树中值采样,起到抵御野点和平衡点云分布密度的作用;基于采样点进行自适应 k 均值区域划分,实现保留局部细节;基于区域自适应半径进行 L_1 -中值骨架收缩,有效地减少了工作量。实验结果表明,该算法大大减少了迭代次数,有效避免了细节的丢失及错误骨架的连接,具有强鲁棒性、高准确率等优点。

需要注意的是,本文算法尽管在 k 均值聚类时实现了自适应确定参数,可客观地进行合理的区域划分,但在 L_1 -中值算法中的参数仍使用了实验观察法,这些参数对骨架提取结果有着一定的影响;同时提取的骨架结果保留细节的同时偶尔会有多余的小骨架产生,且在局部点云内部缺失严重时易形成局部骨架闭环,因此如何更加便捷准确地确定参数及完善骨架,这将是下一步重点解决的问题。

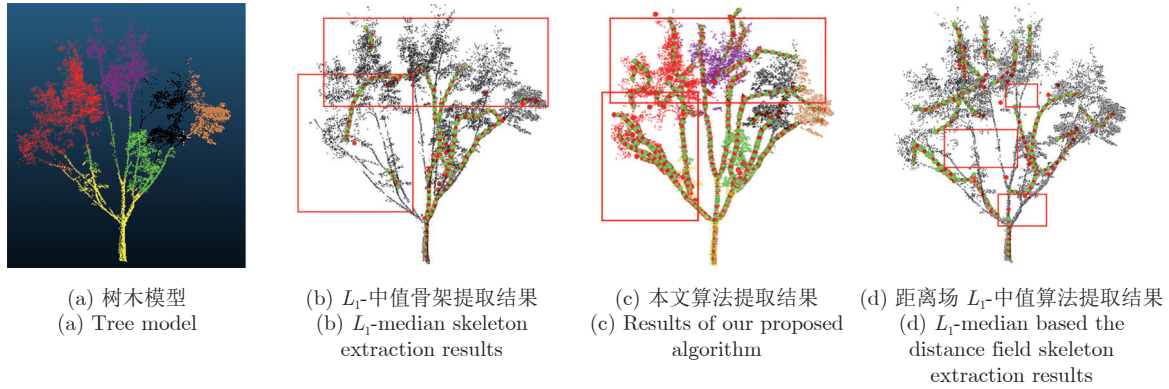


图 20 树木模型的点云骨架提取对比结果

Fig.20 Comparison results of point cloud skeleton extraction of tree model

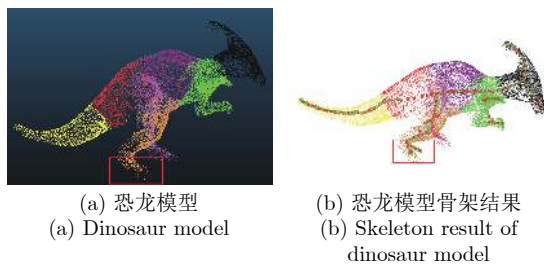


图 21 恐龙模型的点云骨架提取

Fig.21 Point cloud skeleton extraction of dinosaur model

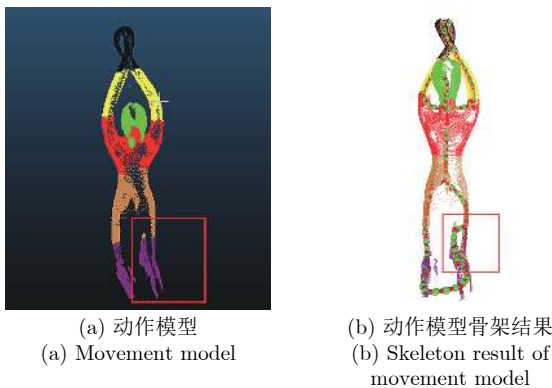


图 22 动作模型的点云骨架提取

Fig.22 Point cloud skeleton extraction of movement model

References

- Jin Chao-Yong, Geng Guo-Hua, Li Ji-Jun-Nan, Zhou Ming-Quan, Zhu Xin-Yi. A New Automatic navigation path generation approach to virtual angiography. *Acta Automatica Sinica*, 2015, **41**(8): 1412-1418
(金朝勇, 耿国华, 李姬俊男, 周明全, 朱新懿. 一种新的虚拟血管镜自动导航路径生成方法. *自动化学报*, 2015, **41**(8): 1412-1418)
- Zhang Yi-Kuan, Zhang Xiao-Peng, Zha Hong-Bin, Zhang Jiang-She. A survey of topologically structural representation and computation of 3D point cloud data. *Journal of Image and Graphics*, 2008, **13**(8): 1576-1587
(张义宽, 张晓鹏, 查红彬, 张讲社. 三维点云的拓扑结构表征与计
- 算技术. *中国图象图形学报*, 2008, **13**(8): 1576-1587)
- Gagnier P Y, Maschner H, Gaillieue A, Norgeot L, Abourachid A. Automatic reconstruction of polygon triangulation for mounted skeleton point cloud. In: *Proceedings of the IEEE International Conference on E-science*. Auckland, New Zealand: 2017. 528-532
- Li Ren-Zhong, Liu Zhe-Wen, Liu Yang-Yang. Segmentation algorithm based on point cloud skeleton. *Laser & Optoelectronics Progress*, 2019, **56**(22): 8
(李仁忠, 刘哲闻, 刘阳阳. 基于点云内骨架的分割算法. *激光与光电子学进展*, 2019, **56**(22): 8)
- Jiang W, Xu K, Cheng Z Q, Martin R R, Dang G. Curve skeleton extraction by coupled graph contraction and surface clustering. *Graphical Models*, 2013, **75**(3): 137-148
- Shen W, Zhao K, Jiang Y, Wang Y, Zhang Z Z, Bai X. Object skeleton extraction in natural 3D point cloud by fusing scale-associated deep side outputs. In: *Proceedings of the Computer Vision and Pattern Recognition*. Las Vegas, NV, USA: 2016. 222-230
- Xu Si-Yu, Zhu Ji-Hua, Tian Zhi-Qiang, Li Yao-Chen, Pang Shan-Min. Stepwise refinement approach for registration of multi-view point sets. *Acta Automatica Sinica*, 2019, **45**(8): 1486-1494
(徐思雨, 祝继华, 田智强, 李垚辰, 庞善民. 逐步求精的多视角点云配准方法. *自动化学报*, 2019, **45**(8): 1486-1494)
- Noh S T, Takahashi K, Adachi M, Igarashi T. Shape refinement and rigging of raw-scanned 3D volume by a user-specified skeleton. *Computers & Graphics*, 2020, **87**: 80-88
- Alwaely B, Abhayaratne C. Adaptive graph formulation for 3D shape representation. In: *Proceedings of the International Conference on Acoustics Speech and Signal Processing*. Brighton, UK: IEEE, 2019. 1947-1951
- Lu W, Zhang X, Liu Y. L_1 -medial skeleton-based 3D point cloud model retrieval. *Multi-media Tools and Applications*, 2019, **78**(1): 479-488
- Huang H, Wu S H, Cohen-Or D, Gong M L, Zhang H, Li G Q, Chen B Q. L_1 -medial skeleton of point cloud. *ACM Transactions on Graphics*, 2013, **32**(4): 96
- Blum H. A transformation for extracting new descriptors of shape. *Models for the Perception of Speech and Visual Form*, 1967: 362-380
- Dey T K, Sun J. Defining and computing curve-skeletons with medial geodesic function. *Symposium on Geometry Processing*, 2006: 143-152
- Cornea N D, Silver D, Min P. Curve-skeleton properties, applications, and algorithms. *IEEE Transactions On Visualization and Computer Graphics*, 2007, **13**(3): 530-548
- Au O K C, Tai C L, Chu H K, Cohen-Or D, Lee T Y. Skeleton

- extraction by mesh contraction. *ACM Transactions on Graphics*, 2008, **27**(3): 44
- 16 Small C G. A survey of multidimensional medians. *International Statistical Review*, 1990, **58**(3): 263–277
- 17 Zhou Y, Toga A W. Efficient Skeletonization of volumetric objects. *IEEE Transactions on Visualization and Computer Graphics*, 1999, **5**(3): 196–209
- 18 Song C, Pang Z, Jing X, Xiao C. Distance field guided L_1 -median skeleton extraction. *The Visual Computer*, 2018, **34**(2): 243–255
- 19 Hu H, Li Z, Jin X, Deng Z, Shen Y. Curve skeleton extraction from 3D point clouds through hybrid feature point shifting and clustering. *Computer Graphics Forum*, 2020, **39**(6): 111–132
- 20 Cao J, Tagliasacchi A, Olson M, Zhang H, Su Z. Point cloud skeletons via laplacian based contraction. In: Proceedings of the 2010 Shape Modeling International Conference. Provence, France: 2010. 187–197
- 21 Erdal O, Ahmet C, Zafer G. A hybrid method for skeleton extraction on kinect sensor data: Combination of L_1 -median and laplacian shrinking algorithms. *Measurement*, 2018: 535–544
- 22 Wu S, Wen W, Xiao B, Guo X, Du J, Wang C, et al. An accurate skeleton extraction approach from 3D point clouds of maize plants. *Frontiers in Plant Science*, 2019, **10**: 248
- 23 Tagliasacchi A, Zhang H, Cohen-Or D. Curve skeleton extraction from incomplete point cloud. *ACM Transactions on Graphics*, 2009, **28**(3): 71
- 24 Jayadevan V, Delp E J, Pizlo Z. Skeleton extraction from 3D point clouds by decomposing the object into parts. arXiv preprint, 2019, arXiv:1912.11932
- 25 Fu L, Liu J, Zhou J, Zhang M, Lin Y. Tree skeletonization for raw point cloud exploiting cylindrical shape prior. *IEEE Access*, 2020: 27327–27341
- 26 Su Z, Li S, Liu H, He Z. Tree skeleton extraction from laser scanned points. In: Proceedings of the 2019 International Geoscience and Remote Sensing Symposium. Yokohama, Japan: IEEE, 2019. 6091–6094
- 27 Mei J, Zhang L, Wu S, Wang Z, Zhang L. 3D tree modeling from incomplete point clouds via optimization and L_1 -MST. *International Journal of Geographical Information Science*, 2017, **31**(5): 999–1021
- 28 Liang Zhou-Yan, Zhao Fu-Yan, Sun Wen-Xiao, Shao Wei-Zhen. The research of surface deformation monitoring method using 3D laser scanning technique. *Geomatics and Spatial Information Technology*, 2017, **40**(6): 213–216, 219
(梁周雁, 赵富燕, 孙文潇, 邵为真. 基于三维激光扫描技术的地表变形监测方法研究. 测绘与空间地理信息, 2017, **40**(6): 213–216, 219)
- 29 Ji S, Shi H. K -means clustering optimization algorithm for massive data. *Computer Engineering and Application*, 2014, **14**: 143–147
- 30 Arthur D, Vassilvitskii S. K -means++: The advantages of careful seeding. In: Proceedings of the 18th Annual ACM-SIAM Symposium on Discrete Algorithms. New Orleans, Louisiana, USA: ACM, 2007. 1027–1035
- 31 Pang Xu-Fang, Pang Ming-Yong, Xiao Chun-Xia. An algorithm for extracting and enhancing valley-ridge features from point sets. *Acta Automatica Sinica*, 2010, **36**(8): 1073–1083
(庞旭芳, 庞明勇, 肖春霞. 点云模型谷脊特征的提取与增强算法. 自动化学报, 2010, **36**(8): 1073–1083)
- 32 Li G, Ma W, Bao H. A new interpolatory subdivision for quadrilateral meshes. *Computer Graphics Forum*, 2005, **24**(1): 3–16
- 33 Gander W, Golub G H, Strebel R. Least-squares fitting of circles and ellipses. *BIT Numerical Mathematics*, 1994, **34**(4): 558–578



鲁 斌 华北电力大学(保定)计算机系副教授. 分别于2001年和2003年获西北工业大学硕士学位和博士学位. 主要研究方向为计算智能, 计算机视觉和综合能源系统.

E-mail: lubin@ncepu.edu.cn

(**LU Bin** Associate professor in the Department of Computer, North China Electric Power University, Baoding. He received his master and Ph.D. degrees from Northwestern Polytechnical University in 2001 and 2003, respectively. His research interest covers intelligent computing, computer vision and comprehensive energy system.)



范晓明 华北电力大学(保定)计算机系硕士研究生. 主要研究方向为计算智能, 计算机视觉和综合能源系统. 本文通信作者.

E-mail: xmingF@163.com

(**FAN Xiao-Ming** Master student in the Department of Computer, North China Electric Power University, Baoding. Her research interest covers intelligent computing, computer vision and comprehensive energy system. Corresponding author of this paper.)