

基于无监督网络框架的文物点云模型去噪

刘一萍, 周明全, 寇姣姣, 鱼跃华, 海琳琦, 李康, 张海波*

西北大学信息科学与技术学院, 陕西 西安 710127

摘要 数字化技术在文物保护工作中的应用极大促进了文化遗产领域的快速发展。三维激光扫描设备获得的文物点云数据不可避免包含大量噪声, 直接影响点云数据的后续处理。为有效去除无序点云中的噪声点, 较好恢复点云数据, 基于无监督网络提出了一种新型点云去噪算法。首先通过上层网络分类并去除离群点; 然后通过引入空间先验项引导待去噪点云中数据点收敛到流形上多模式中最接近真实点云的最优模式, 从去除离群噪声点的点云数据中得到干净点云的分布, 实现无监督精细点云去噪; 最后通过计算去噪后点云间的 chamfer distance 来进行定量评价。与一些经典算法的对比分析实验结果表明, 所提算法在去噪的同时, 能有效保持点云模型的几何特征, 对文物点云数据的去噪效果良好, 去噪后的点云模型极大程度复原了原始干净点云模型, 这对文物数字化保护的后续环节至关重要。

关键词 机器视觉; 点云去噪; 神经网络; 无监督; chamfer distance

中图分类号 TP391

文献标志码 A

DOI: 10.3788/LOP202259.1215014

Denoising of Cultural Relics Point Cloud Model Based on Unsupervised Network Framework

Liu Yiping, Zhou Mingquan, Kou Jiaojiao, Yu Yuehua, Hai Linqi, Li Kang, Zhang Haibo*

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

Abstract The cultural heritage field has developed rapidly based on the use of digital technologies for protecting cultural relics. The point cloud data of cultural relics obtained using three-dimensional laser scanning equipment inevitably contain considerable noise, which directly affects the subsequent processing of the point cloud data. To effectively remove noise points from the disordered point cloud and ensure enhanced recover of point cloud data, a new point cloud denoising algorithm based on the unsupervised network was proposed. First, the outliers are classified and removed from the upper network. Then, a spatial prior term was introduced to guide the data points in the noise cloud to converge to the optimal mode closest to the real point cloud in the multimode on the manifold, enabling the distribution of clean point cloud from the point cloud data of outlier noise points; moreover, the unsupervised denoising of the fine point cloud was realized. Finally, the chamfer distance between the denoised point clouds was estimated for quantitative evaluations. Compared with some classic algorithms, the proposed algorithm can effectively maintain the geometric characteristics of the point cloud model during denoising, and shows a good denoising effect on the point cloud data of cultural relics. The denoised point cloud model considerably restores the original clean point cloud model, which is crucial for the follow-up link of the digital protection of cultural relics.

Key words machine vision; point cloud denoising; neural network; unsupervision; chamfer distance

收稿日期: 2021-07-02; 修回日期: 2021-08-14; 录用日期: 2021-08-31

基金项目: 国家自然科学基金(61902317, 61731015)、国家重点研发计划(2019YFC1521102, 2019YFC1521103)陕西省重点产业链项目(2019ZDLSF07-02)、陕西省自然科学基金青年基金(2019JQ-166)、青海省重点研发计划(2020-SF-142)

通信作者: *zhanghb@nwu.edu.cn

1 引言

随着科技的发展,数字化技术被广泛应用到文物保护工作中,文物数字化不仅可以对文物数据进行永久保存,同时还可以供专家学者进行研究,是文化传承必不可少的手段。近几年,三维激光扫描设备被广泛应用于三维点云数据的获取。但受周遭物体反射、光照、环境变化、人为因素、甚至采集装备自身固有噪声等因素的影响,获得的初始点云数据总是存在噪声。点云中的大量噪声点不利于后期点云数据的配准、分割、重建等处理。因此必须先对初始点云进行去噪处理。

为解决该问题,近年来国内外学者相继提出了不同的算法。李鹏飞等^[1]提出了一种噪声尺度分类的去噪算法,该算法使用统计及半径滤波去除大尺度噪声,再用快速双边滤波来平滑小尺度噪声。翟金磊^[2]基于每个点及其邻域的均值对噪声点进行分类,并对平坦区域点使用平面投影进行去噪,对非平坦特征点使用双边滤波进行去噪。刘立恒等^[3]通过栅格划分去除点云中的大尺度噪声点,使用改进后的特征加权模糊 C 均值(FCM)算法去除小尺度噪声。杨洋等^[4]使用直通滤波与具有噪声的基于密度的聚类(DBSCAN)算法来进行点云去噪。柳赞等^[5]提出了一种在点云区域使用主成分分析的去噪算法,该算法在去噪的同时能较好地保持点云数据的几何特征。Zeng 等^[6]将二维的低维拉普拉斯流成功应用到三维点云,并且去噪效果较好。唐菓等^[7]提出了一种基于密度聚类的点云滤波算法,该算法能有效解决大型点云直接聚类的问题。针对一般点云滤波方法去除点云表面噪声时会破坏点云模型造成较大破坏的问题,韩浩宇等^[8]结合双张量投票和多尺度向量方法估计进行点云滤波,该算法能较好地保留三维模型的尖锐特征。曹雄等^[9]使用多光谱激光雷达的光谱信息,根据色差将点云聚类,并对噪声进行识别去除,该算法能有效去除噪声点,但只适用于多光谱激光雷达点云。上述传统点云去噪算法的普遍缺点是运算时间长、算法步骤复杂、不适用于含噪声的大规模点云。很多学者通过深度学习神经网络实现点云去噪^[10-11],如文献[12-14]使用卷积神经网络(CNN)进行去噪,但该类点云去噪网络架构均较为复杂。Duan 等^[15]提出了一种基于 PointNet^[16]架构的点云去噪算法,该算法首先从噪声点云中学习参考平面,然后将噪声点云投影到该平面实现点云去噪。Rakotosaona 等^[17]提出了一种基于 PointCleanNet 架

构的双层点云去噪算法,第 1 层用来去除噪声点云中的离群噪声点,将处理后的点云输入第 2 层,通过估计点云中数据点的位移矢量实现点云去噪,该网络在性能上优于其他去噪网络。Guerrero 等^[18]提出了第一个无监督点云去噪网络,该网络借鉴文献[19]在二维图像去噪中使用的基于邻域像素预测当前像素值的想法并将其成功扩展到非结构化三维点云中。因为现存的大多数文物模型并不存在成对的点云数据用以训练,即便公开数据集可以通过人为添加噪声的方式来获得成对点云数据,往往也需要手动完成大量前期处理工作,因此上述有监督点云去噪算法普遍存在网络结构复杂、需要成对的点云数据进行训练等缺点。无监督点云去噪算法则无法有效去除离群噪声点。

因此,针对传统去噪算法计算量大、运算时间久、去噪可能导致过度光滑,而无监督点云去噪算法不能有效去除离群点等问题,本文提出了一种基于点云特征的新型点云去噪算法。所提算法结合 PointNet 与无监督点云去噪网络框架,在无监督的基础上,仅需获得真实离群点标签即可实现更好的点云去噪效果。

2 所提算法基本原理

针对无监督网络不能很好去除噪声点云中离群噪声点的问题,本实验组提出了一个专门用于离群噪声点的分类并去除的网络层。整体网络结构分为两部分。首先对噪声点云进行离群噪声点的去除,然后使用无监督网络对其进行精细去噪,最终得到接近干净的点云数据。

2.1 网络结构

所提算法的网络结构如图 1 所示,其中 mlp 为多层感知机的缩写, P' 表示噪声点云, \hat{Q} 表示经过网络层得到的估计离群噪声点集, \hat{P} 为去除估计离群点集后的待进一步去噪的点云, \tilde{P} 为经过网络完全去噪后的点云。

所提算法由两层网络组成。第 1 层网络结构如图 2 所示,输入为含噪声点云 P' ,输出为去除离群噪声点后的待去噪点云 \hat{P} ,整个网络层用于预测并收集噪声点云中的所有离群噪声点,得到点集离群点集 \hat{Q} ,最终将该点集从 P' 中去除后,作为第 2 层网络的输入;第 2 层网络结构如图 3 所示,将第 1 层网络的输出 \hat{P} 作为输入,通过蒙特卡罗卷积实现的两级非结构化编码进行无监督的去噪处理,最终得到接近干净的点云数据。

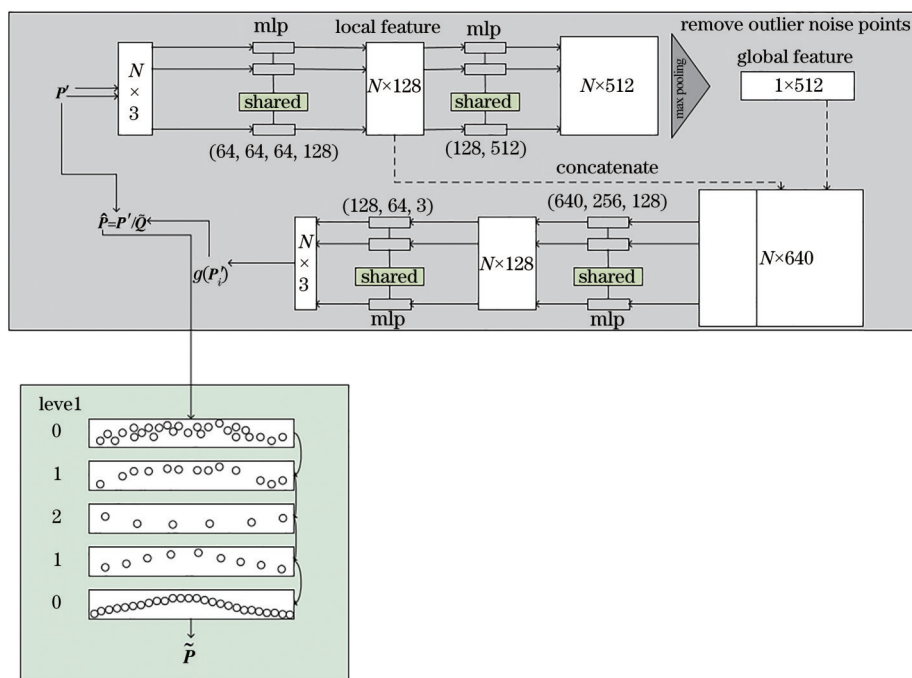


图 1 网络结构图

Fig. 1 Network structure diagram

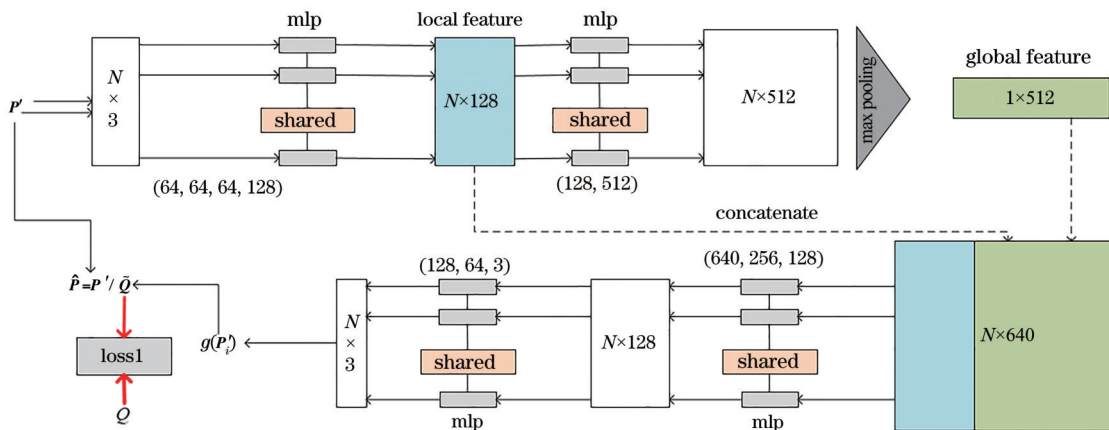


图 2 第 1 层网络结构

Fig. 2 Network structure of first layer

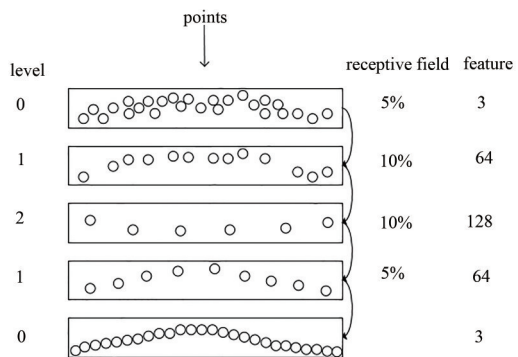


图 3 第 2 层网络结构

Fig. 3 Network structure of second layer

点云去噪需要全局信息,例如桌子和花瓶的边缘分布和曲率变化不同;同时点云去噪也需要知道每个点的局部信息,例如平面上的一个点和锐边上的一个点所包含的局部信息均不相同。通过 mlp 独立获取每个点的局部特征,全局特征则由 max pooling 捕获,最终得到表示整个点云的一维矢量。全局信息的连接使得所提算法对采样密度不太敏感,且能够自适应地学习相邻点的个数。

第 1 层网络将输入噪声点云表示为 $n \times 3$ 的点集,其中 n 代表点云数量,3 代表 xyz 坐标信息,经过一层 mlp 得到 $n \times 128$ 的局部特征,再经过一层 mlp

处理,特征升维到 512,接着进行 max pooling 得到全局特征,将全局特征与局部特征进行融合,再经过两层 mlp 提取特征,得到 $n \times 3$ 的点集,再将该点集经过函数 g ,得到估计离群点,最终将除去估计离群点后的点云作为输出,其中用真实的离群点标签约束经过第 1 层网络得到的估计离群点。

第 2 层网络结构^[20]通过周围点预测当前盲点实现无监督去噪,但由于点云数据受噪声影响容易产生坐标误差,一个观测往往存在多个收敛,因此引入空间先验项,引导其收敛到多个流形中最接近真实的一个。将第 1 层网络的最终输出作为输入,利用无监督网络进行再去噪。从输入的待处理点云开始,执行两级非结构化编码来减少感受野,随后使用转置的非结构化卷积的两级解码。该网络结构中的编码及解码均基于蒙特卡罗卷积实现。该网络为无监督网络结构,输入待处理点云后,输出即为去噪后的点云。

这样的网络结构将点云中的空间邻域转换到在编码器上定义的潜在代码,然后再将其上采样到解码器。执行两级编码,第 1 级的感受野为 5%,第 2 级的感受野为 10%,而第 1 级与第 2 级的池化泊松圆盘半径均为各自感受野的一半。

2.2 损失函数

所提算法网络的第 1 层为有监督网络,第 2 层为无监督网络。在第 1 层网络中,训练一个非线性函数 g ,用以从输入的噪声点云中得到离群噪声点。

$$\tilde{Q}_i = g(\mathbf{P}_i'), \quad (1)$$

式中: \mathbf{P}_i' 为噪声点云中第 i 个点; \tilde{Q}_i 为该点为离群噪声点的估计概率值。当 $\tilde{Q}_i > 0.5$ 时,则认定该点为离群噪声点,并将该点加入估计离群点集 \tilde{Q} ,当得到输入噪声点云中所有离群点后,将输入噪声点云剔除该离群点集即可得到去除离群点后待进一步处理的点云 $\tilde{\mathbf{P}}$, $\tilde{\mathbf{P}} = \mathbf{P}' / \tilde{Q}$ 。此时需要真实的离群点标签对估计离群点集进行约束,因此在真实离群点标签与估计离群点之间使用 L1 距离作为损失函数。

$$L_{L1}(\tilde{\mathbf{P}}, \mathbf{P}_i) = |\tilde{Q}_i - Q_i|, \quad (2)$$

式中: $\tilde{\mathbf{P}}$ 为去噪后点云; \mathbf{P}_i 为干净点云; Q_i 为真实离群点标签。

第 2 层网络为无监督网络,输入为第 1 层已经剔除过离群噪声点的点云 $\tilde{\mathbf{P}}$ 。因为三维点云容易受噪声的影响而产生坐标的偏差,没有可靠的像素网络,所以一个观测可能会存在多个收敛。为克服此难题,引入一个空间先验项,引导其收敛到流形上

许多模式中最接近的一个。先验项 $q(z|y)$ 用来计算观测到的点 y 为干净点 z 的可能性。

$$q(z|y) = p(z|S) \times k(z - y), \quad (3)$$

$$k(d) = \frac{1}{\sigma \sqrt{2\pi}} \cdot \exp\left(-\frac{\|\mathbf{W}d\|_2^2}{2\sigma^2}\right), \quad (4)$$

式中: S 为干净点云的表面; σ 为 k 的带宽; 对角权重矩阵 $\mathbf{W} = \text{diag}(w)$, 其中 $w = 1/\alpha r$, r 为模型直径的 5%, α 为比例因子。则使观测到的点收敛到最接近真实点云的问题可描述为

$$\arg \min_{\Theta} E_{y \sim p(z|S)} E_{q \sim q(z|y)} l[f_{\Theta}(y), q], \quad (5)$$

式中: f 是参数为 Θ 的可调函数,由网络训练得到; l 为 $f_{\Theta}(y)$ 与 q 之间采用的损失函数,使用文献[21]中的退火损失函数 $L_0 = (|f_{\Theta}(y) - q| + \epsilon)^{\gamma}$, 其中 $\epsilon = 10^{-8}$, γ 在训练期间从 2~0 取值。

3 分析与讨论

3.1 实验环境与数据采集

实验的硬件环境为 Intel i7 6800k CPU、64 GB 内存、2080 Ti 显卡的台式计算机;软件环境为 Ubuntu 18.04 操作系统、Pycharm、Microsoft Visual Studio 2017 及 MATLAB R2016a 开发环境。实验数据兵俑模型使用三维激光扫描仪进行采集; Bunny、Dragon、Drill 点云模型来自斯坦福公开数据集。实验所用点云数据模型如图 4 所示。




图 4 实验所用点云模型图。(a) Bunny; (b) Dragon; (c) Drill; (d) 兵俑模型正视图; (e) 兵俑模型侧视图; (f) 兵俑模型俯视图

Fig. 4 Point cloud model diagrams used in experiment. (a) Bunny; (b) Dragon; (c) Drill; (d) front view of terracotta model; (e) side view of terracotta model; (f) top view of terracotta model

3.2 训练方法

第 1 层网络采用包含 28 种不同形状的数据集进行有监督训练,其中 18 种形状用于训练,剩下 10 种用于测试。从每个开始的原始三角网格的表面随机采样 100000 个点以生成干净的点云。

对于去除离群点任务,为了产生异常值,本实验组将包围盒对角线百分比为 20% 的高斯噪声添加到随机点子集中。在训练集当中从 10% 开始到 90% 比例的点云,每间隔 10% 的点就将其转换成异常值,而且最终的真实离群噪声点标签只选择比噪声分布的标准偏差离表面更远的异常值。

实验中 epoch 设置为 2000, batch size 为 64, 初始学习率为 0.0001。训练结束时,在测试集中,离群点去除的准确率可以达到 89% 以上。

第 2 层网络进行无监督训练。为最小化式(5),在训练之前,需要首先根据先验来抽取样本。对于均匀随机 $\zeta \in (0, 1)$, 从 r 内的 Y 中选取一个随机点 \hat{q} , 并在 $k(\hat{q} - y) > \zeta$ 的条件下对其进行训练。以下的操作都是在具有点云大小的批处理上进行的。

数据集采用 ModelNet-40^[22] 中 15 个不同类别,其中每个类别都有 7 种不同形状模型,5 个用于训练,2 个用于测试。在简单噪声模型中,本实验组使用泊松圆盘^[23]对每个三维网格进行采样,获得 13000 和 190000 的干净点云,共 2200 万点用于训练,1000 万点用于测试。然后添加高斯三维噪声,其包围盒对角线百分比 0.5%, 1%, 1.5%。训练过程中,采用 Adam 优化器对损失函数进行优化,初始学习率设置为 0.005,随着训练的过程,学习率会慢慢自动下降。




图 5 干净的点云数据。(a) Bunny; (b) Dragon; (c) Drill

Fig. 5 Clean point cloud data. (a) Bunny; (b) Dragon; (c) Drill

观察上述图片可知,所提算法即使对含有最复杂特征的[图 6(b)],在龙尾、龙鳞、龙头部位的细节特征也依旧非常清晰,并未出现过度光滑的情况。总体上老看,相比文献[1]、[15]、[17]、[19]中算法,所提算

3.3 评价指标

采用 chamfer distance^[24]和均方误差(MSE)作为去噪后效果的客观衡量指标, chamfer distance 的表达式为

$$c(\tilde{\mathbf{P}}, \mathbf{P}) = \frac{1}{N} \sum_{p_i \in \tilde{\mathbf{P}}} \min_{p_j \in \mathbf{P}} \|p_i - p_j\|_2^2 + \frac{1}{M} \sum_{p_j \in \mathbf{P}} \min_{p_i \in \tilde{\mathbf{P}}} \|p_j - p_i\|_2^2, \quad (6)$$

式中: $\tilde{\mathbf{P}}$ 为经过网络去噪后的点云; \mathbf{P} 为干净点云; N 、 M 分别为两个点云的基数。式(6)计算的是 $\tilde{\mathbf{P}}$ 与 \mathbf{P} 之间的距离,其中第 1 项计算 $\tilde{\mathbf{P}}$ 中任意一点 p_i 到 \mathbf{P} 的最小距离之和,第 2 项计算 \mathbf{P} 中任意一点 p_j 到 $\tilde{\mathbf{P}}$ 的最小距离之和。计算得到的 $c(\tilde{\mathbf{P}}, \mathbf{P})$ 越小,说明 $\tilde{\mathbf{P}}$ 与 \mathbf{P} 有着越近似的分布,越接近真实表面,即去噪效果越好。

MSE 的表达式为

$$E_{\text{MSE}} = \frac{1}{m} \sum_{i=1}^m (\tilde{\mathbf{P}}_i - \mathbf{P}_i)^2, \quad (7)$$

式中: m 表示 \mathbf{P} 中所有点的个数。MSE 用于计算 $\tilde{\mathbf{P}}$ 中所有点到 \mathbf{P} 距离的平均值,该平均值越小时, $\tilde{\mathbf{P}}$ 与 \mathbf{P} 越接近。

3.4 实验结果

为客观对比所提算法与文献[1]、[15]、[17]、[19]中算法的性能,以三个斯坦福大学公开数据集的点云数据模型 Bunny、Dragon、Drill 为基础,并分别添加包围盒对角线百分比为 0.03%, 0.05%, 0.07% 的高斯噪声到干净点云上作为噪声点进行实验。添加 0.05% 的高斯噪声到干净点云上(图 5)作为噪声点云(图 6)时,不同算法的去噪结果分别如图 7~11 所示。

法去噪后的点云模型总是最接近干净点云数据模型,在去噪的同时,点云模型的细节处的几何特征也没有损失,去噪后的点云模型边缘更加清晰,表面噪声点明显减少,几何特征更加明显,表面更加光滑。




图 6 待去噪点云数据。(a) Bunny; (b) Dragon; (c) Drill

Fig. 6 Cloud data with noise to be removed. (a) Bunny; (b) Dragon; (c) Drill




图 7 文献[15]算法的去噪结果。(a) Bunny; (b) Dragon; (c) Drill

Fig. 7 Denoising results of algorithm in reference [15]. (a) Bunny; (b) Dragon; (c) Drill




图 8 文献[19]算法的去噪结果。(a) Bunny; (b) Dragon; (c) Drill

Fig. 8 Denoising results of algorithm in reference [19]. (a) Bunny; (b) Dragon; (c) Drill




图 9 文献[17]算法的去噪结果。(a) Bunny; (b) Dragon; (c) Drill

Fig. 9 Denoising results of algorithm in reference [17]. (a) Bunny; (b) Dragon; (c) Drill

表 1 和表 2 分别为以 chamfer distance 和 MSE 作为客观衡量指标时不同算法的去噪效果,其中加粗数据为最优结果。从表 1 和表 2 可知,对比文献 [1]、[15]、[17]、[19] 中算法,所提算法的 chamfer distance、MSE 相比其他算法更小,表明所提算法去噪后的平均误差最小,去噪后的点云数据与原始干净点云数据差别最小。因此,所提算法是一个去噪

效果良好,且能够在去噪的同时保持点云模型的细节几何特征的有效点云去噪算法。

对文物点云数据进行实验,以一个兵俑点云数据模型进行去噪效果展示,该点云模型共有 325728 个点。对该兵俑模型添加包围盒对角线百分比为 0.03 的高斯噪声后,所提算法的去噪效果如图 12~16 所示。




图 10 文献[1]算法的去噪结果。(a) Bunny; (b) Dragon; (c) Drill

Fig. 10 Denoising results of algorithm in reference [1]. (a) Bunny; (b) Dragon; (c) Drill




图 11 所提算法去噪结果。(a) Bunny; (b) Dragon; (c) Drill

Fig. 11 Denoising results of proposed algorithm. (a) Bunny; (b) Dragon; (c) Drill

表 1 在 chamfer distance 作为评估标准下不同算法的去噪效果对比

Table 1 Comparison of denoising effects of different algorithms under chamfer distance as evaluation standard

Model	Bounding box diagonal percentage /%	Chamfer distance / $\times 10^{-8}$				Proposed algorithm
		Algorithm in [15]	Algorithm in [17]	Algorithm in [19]	Algorithm in [1]	
Bunny	0.03	0.9988	0.9379	0.9554	1.0057	0.8869
	0.05	1.5348	1.5309	1.5271	1.5401	1.5216
	0.07	2.0376	2.0003	1.9957	2.1003	1.9942
Dragon	0.03	2.2079	2.1979	2.1693	2.2103	2.1359
	0.05	3.2265	3.2143	3.2231	3.2387	3.2192
	0.07	4.6976	4.6953	4.6895	4.7165	4.6584
Drill	0.03	0	0	0	0.0005	0
	0.05	0.6785	0.6739	0.6689	0.7032	0.6529
	0.07	2.3023	2.2984	2.2886	2.3109	2.1895

表 2 在 MSE 作为评估标准下不同算法的去噪效果对比

Table 2 Comparison of denoising effects of different algorithms under MSE as evaluation standard

Model	Bounding box diagonal percentage /%	MSE / $\times 10^{-8}$				Proposed algorithm
		Algorithm in [15]	Algorithm in [17]	Algorithm in [19]	Algorithm in [1]	
Bunny	0.03	1.0139	1.0127	1.0135	1.0291	1.0118
	0.05	1.9046	1.9045	1.9002	1.9108	1.8996
	0.07	2.5319	2.5304	2.5305	2.5422	2.5297
Dragon	0.03	0.7921	0.7918	0.7829	0.8034	0.7801
	0.05	1.21	1.1934	1.1885	1.24	1.1769
	0.07	1.6384	1.6379	1.6325	1.7031	1.6238
Drill	0.03	0	0	0	0.005	0
	0.05	0.25	0.2475	0.2496	0.2661	0.2427
	0.07	0.4096	0.3968	0.4002	0.4427	0.3954




图 12 手指去噪前后对比。(a)手指待去噪;(b)手指去噪结果
Fig. 12 Comparison of fingers before and after denoising.
(a) Fingers to be denoised; (b) finger denoising result




图 13 头部去噪前后对比。(a)头部待去噪;(b)头部去噪结果
Fig. 13 Comparison of head before and after denoising.
(a) Head to be denoised; (b) head denoising result




图 14 上半身去噪前后对比。(a)上半身待去噪;(b)上半身去噪结果
Fig. 14 Comparison of upper body before and after denoising.
(a) Upper body to be denoised; (b) upper body denoising result




图 15 领口去噪前后对比。(a)领口待去噪;(b)领口去噪结果
Fig. 15 Comparison of neckline before and after denoising.
(a) Neckline to be denoised; (b) neckline denoising result




图 16 手部去噪前后对比。(a)手部待去噪;(b)手部去噪结果
Fig. 16 Comparison of hands before and after denoising.
(a) Hands to be denoised; (b) hands denoising result

从上述图片可以明显观察到,兵俑身体的手部、头部、领口处等细节处,在添加噪声后,变得模糊不清,而使用所提算法去噪后,兵俑身体边缘更加清晰,身体部位的细节几何特征也更加明显,且并未出现过分光顺的情况。

同时,为验证所提算法的实用性,采用由三维激光扫描仪直接得到的兵俑点云模型作为去噪对象进行实验。实验结果如图 17~19 所示。




图 17 头部去噪前后对比。(a)头部待去噪;(b)头部去噪结果
Fig. 17 Comparison of head before and after denoising.
(a) Head to be denoised; (b) head denoising result




图 18 上半身去噪前后对比。(a)上半身待去噪;(b)上半身去噪局部;(c)上半身去噪结果;(d)上半身去噪结果局部
Fig. 18 Comparison of upper body before and after denoising.
(a) Upper body to be denoised; (b) local part of upper body to be denoised; (c) upper body denoising result; (d) local part of upper body denoising result



图 19 脚部去噪前后对比。(a)脚部待去噪;(b)脚部待去噪局部;(c)脚部去噪结果;(d)脚部去噪结果局部
Fig. 19 Comparison of feet before and after denoising. (a) Feet to be denoised; (b) local part of feet to be denoised; (c) feet denoising result; (d) local part of feet denoising result

由这些图片可以清晰地观察到,在对包含实际噪声的点云模型进行的去噪实验中,所提算法去噪后的兵俑模型,在头部、首部、服饰区依然可以很好地保持原有几何特征且并未出现过度光滑导致的模糊问题;同时去除了大量原兵俑模型脚部存在的离群噪声点。

兵俑点云模型含有大量复杂几何特征,数据量大,属于较大规模点云模型,实验结果表明所提算法对文物点云模型有良好的去噪效果且去噪效率较高。

4 结 论

针对文物点云模型的去噪问题,提出了一种新的去噪算法。首先对离群噪声点进行分类并去除,然后再通过扩展到三维非结构化的无监督网络进行精细去噪。实验结果表明,所提算法在仅获取对应离群噪声点标签的情况下,即可有效去噪。针对不同噪声强度及具有复杂特征的大规模噪声点云模型,所提算法都表现出优良去噪性能,具有较高有效性及鲁棒性,可对文物点云数据的简化、重建、分割等后期处理起到辅助作用。后续工作将考虑优化网络结构,提高网络训练效率,增强去噪性能。

参 考 文 献

- [1] 李鹏飞,吴海娥,景军锋,等.点云模型的噪声分类去噪算法[J].计算机工程与应用,2016,52(20):188-192.
Li P F, Wu H E, Jing J F, et al. Noise classification denoising algorithm for point cloud model[J]. Computer Engineering and Applications, 2016, 52(20): 188-192.
- [2] 翟金磊.空间散乱点云去噪精简重建算法研究[D].西安:西安科技大学,2015.
Zhai J L. Research on spatial scattered points cloud denoising, streamlining and surface reconstruction algorithm[D]. Xi'an: Xi'an University of Science and Technology, 2015.
- [3] 刘立恒,赵夫群,汤慧,等.几何特征保持的文物点云去噪算法[J].数据采集与处理,2020,35(2):373-380.
Liu L H, Zhao F Q, Tang H, et al. A denoising method for point cloud of cultural relics with geometric feature preservation[J]. Journal of Data Acquisition and Processing, 2020, 35(2): 373-380.
- [4] 杨洋,李明.基于混合滤波和DBSCAN的点云去噪算法[J].计量与测试技术,2020,47(4):24-27.
Yang Y, Li M. A point cloud denoising method based on a hybrid filtering and density clustering algorithm[J]. Metrology & Measurement Technique, 2020, 47(4): 24-27.
- [5] 柳赞,孙淑艳.基于主成分分析与曲面拟合的激光点云滤波去噪[J].激光技术,2020,44(4):497-502.
Liu Y, Sun S Y. Laser point cloud denoising based on principal component analysis and surface fitting[J]. Laser Technology, 2020, 44(4): 497-502.
- [6] Zeng J, Cheung G, Ng M, et al. 3D point cloud denoising using graph Laplacian regularization of a low dimensional manifold model[J]. IEEE Transactions on Image Processing, 2020, 29: 3474-3489.
- [7] 唐菓,邓兴升,王清阳.基于密度聚类的点云滤波算法研究[J/OL].激光与光电子学进展:1-17[2021-08-11].<http://kns.cnki.net/kcms/detail/31.1690.tn.20210716.1534.012.html>.
Tang G, Deng X S, Wang Q Y. Research on point cloud filtering algorithm based on density clustering [J/OL]. Progress in laser and optoelectronics: 1-17 [2021-08-11]. <http://kns.cnki.net/kcms/detail/31.1690.tn.20210716.1534.012.html>.
- [8] 韩浩宇,张元,韩燮.一种改进的激光点云滤波算法[J].激光与光电子学进展,2021,58(20):2010001.
Han H Y, Zhang Y, Han X. Improved laser point cloud filtering algorithm[J]. Laser & Optoelectronics Progress, 2021, 58(20): 2010001.
- [9] 曹雄,林兆祥,宋沙磊,等.基于颜色聚类的多光谱激光雷达点云去噪[J].激光与光电子学进展,2021,58(12):1228002.
Cao X, Lin Z X, Song S L, et al. Multispectral LiDAR point cloud denoising based on color clustering

- [J]. *Laser & Optoelectronics Progress*, 2021, 58(12): 1228002.
- [10] 乔俊飞, 韩红桂. RBF 神经网络的结构动态优化设计[J]. *自动化学报*, 2010, 36(6): 865-872.
Qiao J F, Han H G. Optimal structure design for RBFNN structure[J]. *Acta Automatica Sinica*, 2010, 36(6): 865-872.
- [11] 周志华, 陈世福. 神经网络集成[J]. *计算机学报*, 2002, 25(1): 1-8.
Zhou Z H, Chen S F. Neural network ensemble[J]. *Chinese Journal of Computers*, 2002, 25(1): 1-8.
- [12] Pistilli F, Fracastoro G, Valsesia D, et al. Learning graph-convolutional representations for point cloud denoising[M]//Vedaldi A, Bischof H, Brox T, et al. *Computer vision-ECCV 2020. Lecture notes in computer science*. Cham: Springer, 2020, 12365: 103-118.
- [13] Almonacid J, Cintas C, Derieux C, et al. Point cloud denoising using deep learning[C]//2018 Congreso Argentino de Ciencias de la Informática y Desarrollos de Investigación (CACIDI), November 28-30, 2018, Buenos Aires, Argentina. New York: IEEE Press, 2018: 18327532.
- [14] Heinzler R, Piewak F, Schindler P, et al. CNN-based lidar point cloud de-noising in adverse weather [J]. *IEEE Robotics and Automation Letters*, 2020, 5(2): 2514-2521.
- [15] Duan C J, Chen S H, Kovacevic J. 3D point cloud denoising via deep neural network based local surface estimation[C]//ICASSP 2019-2019 IEEE International Conference on Acoustics, Speech and Signal Processing, May 12-17, 2019, Brighton, UK. New York: IEEE Press, 2019: 8553-8557.
- [16] Charles R Q, Hao S, Mo K C, et al. PointNet: deep learning on point sets for 3D classification and segmentation[C]//2017 IEEE Conference on Computer Vision and Pattern Recognition, July 21-26, 2017, Honolulu, HI, USA. New York: IEEE Press, 2017: 77-85.
- [17] Rakotosaona M J, La Barbera V, Guerrero P, et al. PointCleanNet: learning to denoise and remove outliers from dense point clouds[J]. *Computer Graphics Forum*, 2020, 39(1): 185-203.
- [18] Guerrero P, Kleiman Y, Ovsjanikov M, et al. PCPNet learning local shape properties from raw point clouds[J]. *Computer Graphics Forum*, 2018, 37(2): 75-85.
- [19] Casajus P H, Ritschel T, Ropinski T. Total denoising: unsupervised learning of 3D point cloud cleaning[C]//2019 IEEE/CVF International Conference on Computer Vision (ICCV), October 27-November 2, 2019, Seoul, Korea (South). New York: IEEE Press, 2019: 52-60.
- [20] Boiko A A, Malashin R O. Single-frame Noise2 Noise: method of training a neural network without using reference data for video sequence image enhancement[J]. *Journal of Optical Technology*, 2020, 87(10): 567-573.
- [21] Lehtinen J, Munkberg J, Hasselgren J, et al. Noise2Noise: learning image restoration without clean data[EB/OL]. (2018-03-12)[2021-05-04]. <https://arxiv.org/abs/1803.04189>.
- [22] Wu Z R, Song S R, Khosla A, et al. 3D ShapeNets: a deep representation for volumetric shapes[C]//2015 IEEE Conference on Computer Vision and Pattern Recognition, June 7-12, 2015, Boston, MA, USA. New York: IEEE Press, 2015: 1912-1920.
- [23] Wei L Y. Parallel Poisson disk sampling[J]. *ACM Transactions on Graphics*, 2008, 27(3): 1-9.
- [24] Fan H Q, Su H, Guibas L. A point set generation network for 3D object reconstruction from a single image[C]//2017 IEEE Conference on Computer Vision and Pattern Recognition, July 21-26, 2017, Honolulu, HI, USA. New York: IEEE Press, 2017: 2463-2471.