

中图法分类号: TP391 文献标识码: A 文章编号: 1006-8961(2025)07-2364-14

论文引用格式: Guan Y C, Hu Y, Zhang X Y, Li Y Z and Yu Q. 2025. External iterative score model point cloud denoising method. Journal of Image and Graphics, 30(7):2364-2377(管雨辰, 胡宇, 张肖莹, 李昱卓, 郁钱. 2025. 外部迭代分数模型点云去噪方法. 中国图象图形学报, 30(7): 2364-2377)[DOI:10.11834/jig.240636]

外部迭代分数模型点云去噪方法

管雨辰¹, 胡宇¹, 张肖莹¹, 李昱卓¹, 郁钱^{2*}

1. 江苏理工学院机械工程学院, 常州 213001; 2. 江苏理工学院计算机工程学院, 常州 213001

摘要: 目的 由于传感器质量和环境因素的影响, 点云数据可能受到噪声的干扰。而这些噪声会对后续的点云应用产生不利影响。因此, 去除噪声成为一项基本的3D视觉任务。目前, 基于深度学习的方法通常是通过训练神经网络来预测点的位移, 然后将有噪声的点移到下面的干净表面上。然而这类算法或者迭代时间较长, 或者在将点位移到干净表面上时会出现收敛过度或位移较大偏差的问题, 影响了去噪的性能。为了提高去噪精度和去噪速度, 本文提出基于外部迭代分数模型的去噪方法。方法 首先将输入的噪声点云进行切块, 然后输入到特征提取模块。之后, 通过分数估计单元计算点的分数(即预测点云去噪过程中的梯度), 在这里加入动量梯度上升动态修正梯度, 减少更新步长, 加快去噪速度。最后, 将去噪好的部分拼接在一起, 组成一个完整点云, 再将去噪一次后的点云重新作为噪声点云进行输入, 重复上述操作构成外部迭代。结果 在实验中, 将所提模型与先进的7种方法在3个数据集上进行对比。在PU(point cloud upsampling)数据集(10 K和50 K点云)中, 针对1%、2%、3%噪声, 所提模型在CD(chamfer distance)和P2M(point-to-mesh distance)指标上均优于性能排名第2的模型, 表现为指标值的降低。在PC(PCNet)数据集(10 K和50 K点云)中, 针对3%噪声的实验表明, 所提模型在泛化性上表现突出, 与性能排名第2的模型相比, CD和P2M指标值显著降低。在RueMadame数据集中进行场景去噪对比实验, 从视觉效果可以直观观察到所提方法具有较强的去噪性能。此外, 比较了去噪时间, 与性能排名第3的模型相比, 去噪时间减少了近30%, 与性能排名第2的模型接近。结论 本文所提出的点云去噪模型, 相比于其他方法有更好的去噪精度和更快的去噪速度。

关键词: 点云去噪; 外部迭代; 分数模型; 动量梯度上升; 深度学习

External iterative score model point cloud denoising method

Guan Yuchen¹, Hu Yu¹, Zhang Xiaoying¹, Li Yuzhuo¹, Yu Qian^{2*}

1. School of Mechanical Engineering, Jiangsu University of Technology, Changzhou 213001, China;

2. School of Computer Engineering, Jiangsu University of Technology, Changzhou 213001, China

Abstract: Objective Point cloud data play an irreplaceable role as important means of environmental sensing and spatial representation in a variety of fields, such as autonomous driving, robotics, and 3D reconstruction. A point cloud is a form of data that represents a discrete set of points on the surface of an object in space by means of 3D coordinates. It is typically captured using 3D imaging sensors, such as LiDAR and depth cameras. These sensors can efficiently acquire spatial infor-

收稿日期: 2024-10-25; 修回日期: 2024-12-05; 预印本日期: 2024-12-12

* 通信作者: 郁钱 yuqian@jsut.edu.cn

基金项目: 国家自然科学基金项目(61902159); 江苏省双创博士项目(KYQ19006); 江苏省青蓝工程优秀青年骨干教师项目(KYQ23004); 江苏理工学院研究生实践创新计划项目(XSJXC23_50)

Supported by: National Natural Science Foundation of China(61902159); Program of Dual Creative Doctors of Jiangsu Province(KYQ19006); Blue Program of Jiangsu Province(KYQ23004); Postgraduate Practice Innovation Program of Jiangsu University of Technology(XSJXC23_50)

mation in the environment, providing critical data support for applications, such as environment sensing for self-driving vehicles, autonomous navigation for robots, and 3D reconstruction of complex scenes. However, the process of acquiring point cloud data is frequently subject to multiple influences from the sensor's performance, environmental conditions, and external disturbances. In such case, the acquired point cloud data may contain a large amount of noise, which is manifested as a deviation of discrete point positions, redundant points, or missing point information. This condition negatively affects subsequent tasks. Therefore, the effective denoising of noisy point cloud data has become a fundamental and extremely important research problem in the field of point clouds. Traditional denoising methods typically rely on geometric processing techniques to identify and remove noisy points by analyzing the geometric properties of the local neighborhood. However, in complex real-world scenarios, traditional methods frequently experience difficulty in achieving satisfactory results when dealing with large-scale data, nonuniformly distributed noise, and fast denoising in dynamic scenarios. For this reason, an increasing number of studies have begun to combine deep learning methods with design denoising algorithms that can efficiently deal with large-scale noisy point cloud data by taking advantage of the 3D structural properties of point clouds. These methods cannot only significantly improve denoising accuracy but also handle multiple types of noise and retain important structural information in a point cloud. At present, deep learning-based methods typically train neural networks to predict point displacements and then move noisy points to a clean surface below. However, such algorithms either have a long iteration time or suffer from over-convergence or a large deviation of displacement when moving points to a clean surface, affecting denoising performance. To improve denoising accuracy and speed, this study proposes point cloud denoising based on an external iterative fractional model. **Method** First, the input noisy point cloud is chunked and divided into parts to be inputted into the network. Next, the part of the point cloud with noise is inputted into the feature extraction module, through which the features of a point cloud are extracted. Then, the features are inputted into the score estimation unit to obtain the score of the point cloud. Considering that the iteration time of the score model is too long, we add the method of momentum gradient ascent to accelerate the iteration of the point cloud. Finally, the denoised part of the point cloud is spliced together to form a complete denoised point cloud. After the denoised point cloud is obtained, it is used as the input for the next denoising, and the above operations are repeated. The model in this study is set with four external iterations as the total denoising process. Among them, the external iteration is a complete point cloud denoising process that includes a series of complete operations, such as point cloud chunking, feature extraction, and score estimation. By contrast, internal iteration refers to the multiple shifts of noise points by the estimated scores in the score estimation model. In this study, the operation that originally requires a large number of internal iterations is transformed into a limited number of external iterations, accelerating denoising speed. **Result** The experiments are compared with seven models, namely, point clean net (PCN), graph-convolutional point cloud denoising network (GPDNet), DMRDenoise, PDFlow, Pointfilter, Scoredenoise, and IterativePFN, in 1%, 2%, and 3% noise for the point cloud upsampling (PU) datasets 10 K and 50 K point clouds. The model is optimal in the evaluation metrics, Chamfer distance (CD) and point-to-mesh distance (P2M) (lower values are better). A comparison of scene denoising is performed on the RueMadame dataset, which contains only noisy scanned data, and thus, we only consider visual results. After denoising by using our method, the least noise is left in the scene. Thereafter, denoising time comparison is performed on this dataset, and our method reduces time by nearly 30% compared with the model with the third-place performance, which is similar to the time of the model with the second-place performance. We then perform a comparison of generalizability on the PC dataset of 10 K and 50 K point clouds with 3% noise. Our method also has the lowest CD and P2M values. Finally, we perform a series of ablation experiments to demonstrate the effectiveness of our model. All the aforementioned experiments are tested on NVIDIA GeForce RTX 4090 graphics processing unit to ensure their fairness and impartiality. **Conclusion** The point cloud denoising model proposed in this study exhibits better denoising accuracy and faster denoising speed compared with other methods. In the future, we hope to apply our network architecture to other tasks, such as point cloud up-sampling and complementation.

Key words: point cloud denoising; external iterative; score model; momentum gradient ascent; deep learning

0 引言

点云是三维坐标系下点的集合数据,具有无序性和无结构性,几何信息非常丰富,包括 X, Y, Z 三维坐标、颜色等。学者经常使用这些三维信息进行自动驾驶、机器人以及3D重建(郁钱等,2022;Bai等,2023)等的技术研究。点云通常是由三维成像传感器获得的,但是由于传感器质量和环境因素的影响,点云数据的捕获可能会引入噪声,使获得的数据出错。因此,对捕获到的嘈杂点云进行去噪是点云领域的一个基础性研究问题。

当前点云去噪的方法主要分为两类:传统滤波算法和基于深度学习的去噪算法。与传统方法相比,基于深度学习的去噪算法在精度上表现更为优异,因此受到广泛关注。目前基于深度学习的点云去噪方法种类繁多,性能较为突出的有以下几种:直接对点云进行位移的PointCleanNet(Rakotsoana等,2020)和Pointfilter(Zhang等,2021)、基于图卷积的GPDNet(graph-convolutional point cloud denoising network)(Pistilli等,2020)、利用归一化流的PDFlow(Mao等,2022)、通过重采样实现的DMRDenoise(Luo和Hu,2020)、基于分数模型的ScoreDenoise(Luo和Hu,2021)以及采用多个迭代模块模拟真正

的迭代过滤的IterativePFN(iterative point cloud filtering network)(de Silva Edirimuni等,2023)。这些方法通过构建复杂的去噪神经网络模型,可以有效去除点云中的噪声,提升了点云质量。

IterativePFN不仅具有较高的去噪精度,还充分利用外部迭代的优势,加快去噪速度。然而,IterativePFN在判断噪声点是否已准确移动到物体表面时存在局限,可能导致去噪收敛过度或产生较大的位移偏差。相比之下,基于分数模型的ScoreDenoise通过计算噪声点偏离物体表面的梯度,逐步移动噪声点云,使其逐渐接近干净表面。尽管该方法的去噪效果较为出色,但是由于内部迭代次数过多,使得去噪时间较长。为了使去噪方法既有较高的去噪精度,又能保证去噪的速度,本文提出基于外部迭代分数模型的点云去噪。这项研究具有以下几点重要贡献:1)提出基于编码器—解码器结构的点云迭代模型,该模型通过减少内部迭代、增加外部迭代实现对点云的去噪。主要框架如图1所示;2)利用动量梯度上升,保持一部分过去的梯度更新下一次的迭代方向,加快去噪的速度,提高去噪效率;3)在合成数据和真实数据上的实验表明,本文方法在不同的点云和噪声类型下,与之前的方法相比,具有更快的去噪速度,以及更高的去噪精度。




图1 模型架构
Fig. 1 Model framework

1 相关工作

1.1 基于优化思想的传统滤波算法

基于优化思想的传统滤波算法主要分为空间域滤波(Rusu等, 2011)、基于移动最小二乘(moving least squares, MLS)(Kolluri, 2008; Guennebaud 和 Gross, 2007; Öztireli等, 2009)、基于局部最优投影(locally optimal projection, LOP)系列(Lipman等, 2007; Huang等, 2009, 2013)、稀疏重建(Avron等, 2010; Sun等, 2015; Mattei 和 Castrodad, 2017)以及图信号处理方法(Schoenenberger等, 2015; Gao等, 2018)。

空间域滤波(Rusu和Cousins, 2011)算法是通过学习点云的空间坐标信息,同时考虑点云的邻域数目及邻域上的点到点云的距离分布,设计出相应的过滤规则。其中,算数均值滤波器和几何均值滤波器广泛用于消除高斯噪声。这些滤波器(戴士杰等, 2018; 崇斯杰等, 2022)首先计算邻域内每个点的欧氏距离,然后为其分配相应的权重,最后通过加权平均的方式对点云进行修正。尽管这些方法具有较强的去噪效果,但在去噪的同时也平滑处理了边角及其他棱角区域,导致去噪后的点云缺失锐利部分。

Shen等人(2004)提出一种利用多边形数据建立隐式曲面的插值或逼近方法,其中隐式函数通过移动最小二乘公式与多边形上的约束进行整合来表示。考虑到点云数据同样具有无序性,Guenebaud和Gross(2007)提出的方法可以对输入点集进行近似或插值,并能自然地处理平面点云。Kolluri(2008)将IMLS(implicit MLS)方法用于从点云数据重构曲面,但该方法仅在点的局部邻域进行操作,缺乏全局信息的考量,从而导致最终结果可能出现膨胀或收缩等现象。针对该局限性,Öztireli等人(2009)提出RIMLS(robust IMLS)方法,该方法能够处理稀疏采样数据,并生成连续的表面,从而更好地保留细节,并且能够自然地处理各种锐利特征,具有可控的锐度。这些基于MLS的方法都依赖于局部表面参数,需要对局部法线进行估计并拟合局部平面(郜金艳等, 2022)。

为了解决MLS方法过度依赖局部表面参数的问题,Lipman等人(2007)提出一种局部最优投影的

算法,该算法首先应用于曲面拟合,并直接对点进行的操作,不需要任何局部参数。然而,该方法训练的loss振荡,不容易收敛,造成生成的点云分布不均。Huang等人(2009)为了解决上述方法造成的问题,提出WLOP(weighted LOP)算法,该算法设计了一个新的梯度下降函数,并在函数中加入局部自适应密度项。WLOP算法为了使点云分布更加均匀,采用过滤的方法将点云分散,减少点云的聚集现象。基于该算法,后续出现了很多基于过滤的算法设计。上述算法主要关注噪声点云的去噪效果,对于点云的表面锐利特征的保留仍存在问题。为了增强点云锐利特征的保留,RIMLS等方法在设计时充分学习点云的空间几何形状信息(Mao等, 2022)。然而由于这些算法过度依赖于点云的法线信息,造成算法只对外点进行过滤。Preiner等人(2014)提出的CLOP(continuous LOP)算法,以及Lu等人(2018)提出的GPF(GMM-inspired feature-preserving)算法都是基于高斯混合模型(Gaussian mixture model, GMM)(Myronenko和Song, 2010)进行的改进,这些算法都注重于在点云去噪过程中减少特征的流失。

上述两类方法的去噪无法保持底层干净表面的尖锐几何特征,并且对噪声非常敏感。Avron等人(2010)为了点云去噪,专门设计了基于L1正则的稀疏重建框架。理论上,L1正则可视为L0正则的最优凸近似(Öztireli等, 2009),且相对于L0正则更易于优化。然而在实际算法中L0正则能够生成更为稀疏的有效解,因此,很多研究都是基于L0正则进行优化设计。Xu等人(2011)在图像去噪中使用L0正则,而He和Schaefer(2013)则将L0正则运用到网格的处理中。受到这些工作的启发,Sun等人(2015)首先构建基于L0正则的点云去噪算法,将L0正则运用于点云去噪的领域。通过稀疏重建,平滑噪声点云,并且保留一些点云的锐利部分。

图信号处理(graph signal processing, GSP)是用来处理不规则信号的方法。考虑到点云同样是不规则的数据结构,Schoenenberger等人(2015)首先将GSP引入点云去噪领域,利用点之间的相似性信息构建图结构,之后通过对图结构的处理完成点云去噪任务。与上述算法直接选择点云坐标信息作为图信号不同,Gao等人(2018)首先将点云中的噪声分为异常值和表面噪声。根据领域信息消除异常值,再将点到表面的距离作为图信号,通过对图信号的

正则优化,达到去除点云噪声的目的。这一算法还利用了将点云切分为块的思想,最终加快了点云去噪的速度。

1.2 基于深度学习的方法

基于传统滤波的点云去噪算法或者受到法线精度的限制,或者去噪后丢失几何细节。学者提出基于深度学习的点云去噪算法,以解决传统方法带来的缺点和局限性。

Roveri 等人(2018)首先提出 PointProNets,该框架使用一种生成式神经网络架构,通过解决点云几何中的模糊性,生成一个精确的密集点云,以此达到点云去噪的目的。然而,PointProNets 网络不是直接在原始输入点云上执行去噪操作,而是通过将点云转化为二维图像,基于图像进行去噪。其网络架构对图像进行投影、反投影等操作时,造成几何信息的丢失,从而使生成的点云去噪不完全,存在大量的噪声点。

Rakotosaona 等人(2020)首先提出一种基于神经网络的直接对点云进行操作的去噪框架,即 PointCleanNet,该框架被设计为一个两阶段网络,首先去除点云上的离群点,然后学习每个点的噪声偏移向量,并根据此向量将每个点移动到适当的位置(陈建文等,2023)。PointCleanNet 能够很好地学习点云的特征信息,为后续进行的点云工作提供了很好的特征提取方式。

与 PointCleanNet 类似,Zhang 等人(2021)提出一种更为精简的点云去噪框架,即 Pointfilter。该框架首先将点云切分为点云块,然后以局部点云块作为输入,最后预测点云块中心点的偏移向量。同时,为了学习到点云的全部特征,通过引入点云的法线信息,提取点云的高阶空间几何特征,设计出基于双边机制的权重项,并且设计了一个新的损失函数,增强框架对于点云特征的学习能力。

此外,Pistilli 等人(2020)提出一种基于图卷积层的深度神经网络 GPDNet (graph-convolutional point denoising network),可以有效地解决点云处理过程中排列不变性的问题。Mao 等人(2022)提出一种名为 PDFlow 的模型,将归一化流和噪声去纠缠技术相结合,从分布学习和特征解纠缠的角度制定去噪过程。以往的去噪方法主要通过训练神经网络预测点的位移,然后将有噪声的点云移动到干净的表面上,因此去噪效果并不理想。

针对预测点位移偏差的问题,Luo 和 Hu(2020)首先提出一种名为 DMRDenoise 微分流形重建框架,通过学习采样点及邻域特征,推断点云的基础流形,然后对流形进行重采样,最后得到一个干净的点云。随后,Luo 和 Hu(2021)提出一种基于分数网络的点云去噪框架 ScoreDenoise。该算法通过神经网络预测出噪声点的分数值,然后通过梯度上升的方式,模拟点云潜在噪声卷积概率分布的梯度对数,经过不断迭代,使得噪声点云接近干净表面,从而完成点云去噪。该方法比以前的方法对收缩的鲁棒性更强,但是,该方法的迭代时间过长。

为了减少迭代时间,de Silva Edirimuni 等人(2023)提出一种新的网络架构,名为 IterativePFN,该网络架构采用多个迭代模块模拟真正的迭代过滤过程,并使用新型损失函数在训练过程中以自适应的方式捕捉中间过滤结果之间的关系,从而确保过滤结果更快地收敛到干净的点云表面。但是,该方法去噪后的点云出现收缩的现象,而收缩的点云不能直接用于实际应用。针对以上基于深度学习进行点云去噪带来的问题,本文设计一个新型去噪网络架构,通过本文模型架构可以解决迭代时间过长的问題,并且可以获得更好的去噪精度。

2 方 法

2.1 模型总览

如图1所示,本文方法首先将输入的噪声点云进行切块,分成部分输入到网络;接下来,将部分带有噪声的点云输入特征提取模块,通过该模块提取点云的特征;然后,将特征输入到分数估计单元,得到点云的分数。考虑到分数模型的迭代时间过长,采用加入动量梯度上升的方法,加快速度的迭代,最后将去噪好的部分点云拼接在一起,组成一个完整的去噪后的点云。得到去噪后的点云后,将其作为下一次去噪的输入,重复上面的操作,本文模型设置4次外部迭代层数作为一次总的去噪过程。

图1中的外部迭代是一次完整的点云去噪过程,包括点云切块、特征提取和分数估计等一系列完整的操作。内部迭代则指的是在分数估计模型(如 ScoreDenoise)中,通过估计出的分数对噪声点进行多次移动。为了使噪声点移动到物体表面,分数模型需要较多的内部迭代,从而导致去噪速度较慢。

本文方法引入了动量梯度上升以确保梯度估计的准确性和稳定性,同时采用外部迭代来减少内部迭代次数。具体而言,本文方法将原本需要大量内部迭代的操作转变为有限次数的外部迭代,从而加快了去噪速度。实验证明,这种基于外部迭代的分数模型具有更好的去噪精度。下面详细描述本文提出的点云去噪模型的各个模块。

2.2 特征提取

给定一个干净的点云,具体为

$$P_y = \{y_i | y_i \in \mathbf{R}^3, i = 1, \dots, n\} \quad (1)$$

本文通过在边界球半径0.5%~2%范围内添加标准差 σ_0 的高斯噪声生成扰动点。由此得到了一个带有噪声的点云,即

$$P_x = P_y + \sigma_0 \delta, \delta \sim N(0, I) \quad (2)$$

然后,使用最远点采样(farthest point sampling, FPS)从噪声点云中选取参考点,对每个参考点使用K最近邻(K-nearest neighbor, KNN)方法找到其邻域内的点,形成局部patch。以参考点 $x_n \in P_x$ 为基准,这样就得到了噪声部分 X ,具体为

$$X = \{x_i | x_i \in P_x \wedge x_i \in kNN(x_n, P_x, k = 1000)\} \quad (3)$$

式中, $\wedge$ 表示“且”, $kNN(x, P_x, k = m)$ 是点集 P_x 中 x 的 m 个最近邻居。具体而言,选择 x_n 的1000个近邻,其对应的干净部分 Y 为

$$Y = \{y_i | y_i \in P_y \wedge y_i \in kNN(x_n, P_y, k = 1200)\} \quad (4)$$

X 的边界点可能源于 Y 中 x_n 的1000个最近邻之外的干净表面上的点,这些点可能会因为噪声而被扰动到 X 上,进而丢失局部信息。为此,本文采用ScoreDenoise(Luo和Hu, 2021)的策略,将 Y 中的点数设置为略大于 X 。然后,每个patch中的点减去参考点坐标,实现局部标准化,即 $X = X - x_n$ 和 $Y = Y - x_n$ 。之后,利用patch中的点构造一个有向图 $G = (V, E)$,通过有向图捕捉局部几何结构,具体为

$$V = \{i | x_i \in X\} \quad (5)$$

$$E = \{(i, j) | x_i, x_j \in X \wedge x_j \in kNN(x_i, X, k = 32)\}$$

式中, x_i 是噪声部分中的点, x_j 是 x_i 在噪声部分 X 的32个近邻。对于每个顶点 x_i ,边由顶点和它的32个最近的邻居组成。得到有向图后进行点云的特征提取。

在基于图卷积的方法中,一次性处理图中的所有顶点,并对每个顶点推断出经过去噪后的位移。

对于本文的网络,采用了Wang等人(2019)提出的Dynamic EdgeConv层的修改形式,在每个编码器中使用这些层生成输入图形的丰富特征表示。具体而言,首先将输入的点云 $N \times 3$ 经过多层感知机(multi-layer perceptron, MLP)变换到一个新的维度,然后再经过两个MLP,将维度变为更高,之后将前3层所得到的特征维度相加,并通过一个MLP将其变为512维。在提取特征之后,将这些特征输入到分数估计模块中,通过这个模块得到输入点云 x 的分数。接下来,通过3个全连接层(fully connected layer, FC)回归噪声点的预测位移 d ,这些全连接层均采用ReLU(rectified linear unit)激活函数,而最后一层则使用tanh激活函数来约束 d ,从而得到最终的预测点 $\hat{x}$,如图2所示。




图2 特征提取模块

Fig. 2 Feature extraction module

2.3 分数去噪

去噪点云可以视为通过梯度上升更新每个点的位置,观察到之前一些基于深度学习的去噪方法(吴一全等, 2024):PCNet(PointCleanNet)(Rakotosaona等, 2020)、Totaldenoising(Casajus等, 2019)和IterativePFN(de Silva Edirimuni等, 2023),存在着形状收缩的问题。而基于ScoreDenoise(Luo和Hu, 2021)的

方法并没有显示出这种形状收缩的现象。因此,在本文模型中,采用分数估计单元确保去噪后点云不会出现收缩。如图3所示,分数估计单元主要由4个残差单元以及卷积层构成(胡豪等,2023)。输入点云经过特征提取模块得到特征 f ,最终输出 x 的分数(即网络估计的梯度)。

输入 x_n 周围点坐标 $x \in \mathbf{R}^3$,学习到点的特征 f_n ,输出估计的梯度,具体为

$$g_n(x) = D(x - x_n, f_n) \quad (6)$$

式中, $D(x - x_n, f_n)$ 是由多层感知器实现的梯度估计网络。在分数计算后,集合梯度计算为

$$z_n(x) = \frac{1}{k} \sum_{x_j \in kNN(x, k)} g_j(x) \quad (7)$$

式中, x_j 是 x_i 的 k 个最近邻域。




图3 分数估计单元

Fig. 3 Fraction estimation unit

在使用ScoreDenoise时,本文观察到其受到梯度波动的影响。这意味着一旦估计的梯度偏离了正确的方向,误差就会逐渐累积,最终导致严重的异常值。这种累积误差的影响可能会在处理点云数据时带来挑战,需要采取适当的措施减轻其影响,确保算法的稳定性和准确性。同时,观察到分数去噪的迭代时间过长。

为了克服分数模型迭代时间过长和可能会带来异常值的问题,本文采用了动量梯度上升对分数模型计算点移动的梯度进行改进,提高了内部迭代的

稳定性,并减少推理时间,加快去噪速度。具体方法如下:

在点云去噪的初始阶段,根据输入点云对每个点的坐标进行初始化,具体为

$$x_i^{(0)} = x_i, x_i \in X \quad (8)$$

为了利用过去的梯度信息,本文引入了一个辅助向量 v ,它被初始化为零,并且通过对过去梯度的平均值进行更新,具体为

$$v_i^{(0)} = 0 \in \mathbf{R}^3 \quad (9)$$

$$v_i^{(t)} = \alpha z_i(x_i^{(t-1)}) + (1 - \alpha) v_i^{(t-1)}$$

式中, t 为迭代步长, α 为动量权值, v_i 用于缓解梯度方差,获得更稳定的去噪方向。最后,利用动量梯度上升更新点坐标对点云进行去噪,具体为

$$x_i^{(t)} = x_i^{(t-1)} + \beta \gamma^t v_i^{(t)} \quad (10)$$

式中, t 为迭代步长, β 为步长大小, γ^t 为为保证收敛而向0递减的衰减系数。如图4所示,与经典梯度上升相比,动量梯度上升通过利用之前迭代的信息确定点的轨迹,从而提高了内部迭代的稳定性,并且减少了推理时间。




图4 动量梯度上升法

Fig. 4 Momentum gradient ascent

2.4 损失函数

本文使用IterativePFN提供的损失函数计算方法迭代地降低噪声。该损失函数为

$$L_i^{(T)}(Y^{(T)}) = \|d_i^{(T)} - \delta x_i^{(T)}(Y^{(T)})\|_2^2 \quad (11)$$

$$\delta x_i^{(T)}(Y^{(T)}) = NN(x_i^{(T-1)}, Y^{(T)}) - x_i^{(T-1)}$$

式中, $d_i^{(T)}$ 为过滤位移。 $NN(x_i^{(T-1)}, Y^{(T)})$ 是 $x_i^{(T-1)}$ 到 $Y^{(T)}$ 的最近邻居。 $Y^{(T)}$ 是去噪后真实点云的部分,具体为

$$Y^{(T)} = Y + \sigma^T \xi \wedge \xi \sim N(0, I) \quad (12)$$

与 $Y^{(T-1)}$ 相比, 该目标 patch 包含更少的噪声。本文确保 $\sigma^0 > \sigma^1 > \dots > \sigma^T$, 设置 $\sigma^T = 0$ 。为方便实验, 设定 $\sigma^{T+1} = \sigma^T / \theta$, 其中 $\theta = 16/T$ 是控制目标部分噪声尺度的衰减超参数。总的来说, 训练目标是最小化过滤位移和最近邻居之间的 L_2 损失。

2.5 拼接模块

Zhou 等人 (2022) 提出一种 patch 拼接机制, 旨在获取区域内的最佳过滤点。然而, 该方法依赖于使用自注意模块获得的网络推断权值, 从而推断出产生最佳过滤点的最佳 patch。这一依赖导致需要大量的计算资源, 并且这种方法不容易推广到不使用这种模块的算法。因此, 本文网络采用一种更通用的切片拼接方法, 它可以与任何基于图的神经网络体系结构结合使用。本文方法将 50 K 个点分成 300 个 patch, 然后分别对每个 patch 进行去噪, 最后将所有 patch 拼接到一起。然而这些 patch 上的点有重合的部分, 导致去噪后会有偏移的点。这是由于靠近 patch 边界的点具有非对称的邻域, 使其在图卷积过程中接收到偏置信号, 从而影响去噪输出。因此, 本文根据与参考点 $\mathbf{x}_n$ 的接近程度, 采用高斯分布对输入点进行加权, 计算每个点在多个 patch 中的权重, 选择权重最大的 patch 作为该点的结果, 融合去噪后的 patch, 形成完整的去噪点云, 即

$$w_i = \frac{\exp\left(-\frac{\|\mathbf{x}_i - \mathbf{x}_n\|_2^2}{r_s^2}\right)}{\sum_i \exp\left(-\frac{\|\mathbf{x}_i - \mathbf{x}_n\|_2^2}{r_s^2}\right)} \quad (13)$$

式中, $\mathbf{x}_i$ 为输入点, r_s 为支持的半径, 将其设置为 $r_s = r/3$, r 为 patch 半径。此时, $t = T$ 处的损失为

$$L^{(T)} = \sum_i w_i L_i^{(T)} \quad (14)$$

式中, 各点的个体损失贡献由 $L_i^{(T)}$ 表示。最后, 累加各迭代的损失贡献, 得到最终损失, 具体为

$$L_{\text{final}} = \sum_{i=2}^T L^{(i)} \quad (15)$$

3 实验

3.1 数据集

本文遵循 ScoreDenoise (Luo 和 Hu, 2021) 和 IterativePFN (de Silva Edirimuni 等, 2023) 的操作, 利

用 PU (point cloud upsampling) 数据集 (Yu 等, 2018) 训练本文网络。同时, 本文重新训练所有其他方法, 包括 PCN (point clean net) (Rakotosaona 等, 2020)、GPDNet (Pistilli 等, 2020)、DMRDenoise (Luo 和 Hu, 2020)、PDFlow (Mao 等, 2022)、Pointfilter (Zhang 等, 2021)、ScoreDenoise (Luo 和 Hu, 2021) 和 IterativePFN (de Silva Edirimuni 等, 2023)。之后, 对 40 个训练网格进行泊松采样, 分别生成了分辨率为 10 K、30 K 和 50 K 的点云, 形成了 120 个训练集。接着, 对每个点云添加 0.5%~2% 的高斯噪声。为了测试本文方法, 采用了 ScoreDenoise 的策略, 在 10 K 和 50 K 分辨率下对 20 个测试集进行了采样。这 40 个点云都受到了标准差为 1% 和 2% 的点云边界框对角线长度的高斯噪声的影响。

为了对比真实世界的扫描结果, 本文研究了 Paris-Rue-Madame 数据集的测试结果: 这个数据集由移动激光扫描系统 L3D2 (laser mobile mapper 3D dual) (Serna 等, 2014) 采集的扫描组成, 该系统捕获了巴黎第六区 Madame 街的街道。这些扫描包含了真实世界的噪声, 这是扫描技术局限性的结果, 同时也为比较模型在真实世界数据的去噪性能提供了一个很好的基础。

3.2 评价指标

本文采用 CD (chamfer distance) (Fan 等, 2017) 和 P2M (point-to-mesh distance) (Li 等, 2021) 两个评价指标评估算法性能。CD 误差 (Lu 等, 2022) 表示去噪后点云和干净点云之间的平均最短距离。能够有效衡量两个点云之间的相似度, 数值越小代表模型性能越好。为了更准确地反映点云相对于干净表面的偏移程度, 采用 P2M 指标进行衡量。这两个指标的计算都使用了它们在 PyTorch3D (Johnson 等, 2020) 中的最新实现。

3.3 合成数据集上的结果

在合成数据集上的数据结果比较如表 1 所示。基于基线位移的方法 PCN 和 GPDNet 在 1% 噪声下和 2% 噪声下都表现出次优的性能。基于重采样的 DMRDenoise 和基于分数模型的 ScoreDenoise 对于点云数为 50 K 噪声为 2% 的去噪效果较好。基于归一化流的 PDFlow 在点数为 10 K 的数据集下性能良好, 但在点数为 50 K 噪声为 2% 的情况下去噪不理想。基于多个迭代模块的 Pointfilter 和 IterativePFN 的方法在 CD 和 P2M 评价指标上表现良

表 1 各模型对 PU 数据集的去噪结果 (CD 和 P2M 的数值 $\times 10^5$)
Table 1 Denoising results on the PUNet dataset (CD and P2M distances are multiplied by 10^5)

模型	10 K 点						50 K 点					
	1% 噪声		2% 噪声		3% 噪声		1% 噪声		2% 噪声		3% 噪声	
	CD	P2M	CD	P2M	CD	P2M	CD	P2M	CD	P2M	CD	P2M
Noisy	36.90	16.03	79.39	47.72	133.82	96.00	18.69	12.82	50.48	41.36	98.40	86.67
PCN	36.86	15.99	79.26	47.59	130.67	87.37	11.03	6.46	19.78	13.70	22.89	12.85
GPDNet	23.10	7.14	42.84	18.55	134.11	93.37	10.49	6.35	32.88	25.03	96.56	81.42
DMRDenoise	47.12	21.96	50.85	25.23	58.92	28.46	12.05	7.62	14.43	9.70	24.32	15.28
PDFlow	21.26	6.74	32.46	13.24	44.56	20.57	6.51	4.16	12.70	9.21	19.45	12.62
Pointfilter	24.61	7.30	35.34	11.55	108.73	74.11	7.58	4.32	9.07	5.07	17.09	11.41
ScoreDenoise	25.21	4.63	36.86	10.74	47.08	19.42	7.16	1.50	12.88	5.66	19.28	10.41
IterativePFN	20.56	5.01	30.43	8.45	42.39	16.86	6.05	3.02	8.03	4.36	19.71	13.04
本文	19.97	4.88	30.10	8.13	37.87	13.70	5.92	2.94	8.00	4.35	13.22	8.16

注:加粗字体表示各列最优结果。

好,但在去噪后的视觉效果方面还有进一步提升的空间。

图 5 为各模型在 7 个数据集 Camel、Casting、Chair、Cow、Kitten、Duck 和 Horse (50 K 个点 2% 的噪声)去噪后的视觉效果。图中点云颜色逐渐变深表示去噪后点云与干净点云的距离关系。通过颜色渐深的转变,直观显示各模型的去噪效果。距离干净点云越远,颜色越鲜艳。深色越多表明去噪效果越好。可以看出,PDFlow 去噪后有流形的黄色噪声点;Pointfilter 在动物的数据集上表现良好,但在其他数据集上存在大量噪声点;ScoreDenoise 去噪后留下均匀的噪声点;IterativePFN 留下相对较少的噪声点,本文方法去噪后留下的噪声点最少。在实验过程中,发现 IterativePFN 去噪后的点云存在收缩现象。这是由于 IterativePFN 的模型是以自适应的方式进行过滤去噪,不能精准判断噪声点是否移动到物体表面,会出现去噪收敛过度或位移偏差的问题。而本文方法是通过分数模型逐步将噪声点移动到干净点云表面,因此不会出现过度收缩或偏移的现象。图 6 为 IterativePFN 与本文方法的对比图。红色为干净点云的边框,灰色为去噪后的边框。可以明显看出,IterativePFN 去噪后的点云相对于干净点云存在收缩现象,这种现象影响了使用点云进行的下游任务。而本文方法在去噪后没有明显收缩的情况。图 7 为不同模型在 Elephant 点云去噪后的视觉效果,展

示各模型去噪后的细节。从图中可以直观地看出,本文方法去噪后点云边缘更加光滑,在处理细节方面,本文方法更胜一筹。

3.4 扫描数据集上的结果

图 8 展示了 RueMadame 数据集两个场景的去噪结果。由于该数据集只包含有噪声的扫描数据,因此只考虑其视觉结果。Pointfilter 留下了许多嘈杂的点,ScoreDenoise 的性能稍微好一点,但仍去噪不理想,这是因为它们学习点云特征不完全,且迭代时间过长,积累了大量的异常。相比之下,Iterative-PFN 在完成场景过滤时只保留了一些有噪声的点,但在场景物体的边缘轮廓去噪方面表现不够平滑。就本文方法而言,在图 8 的视觉效果中,本文方法在树和汽车的细节去噪方面要优于其他方法,主要表现在对树去噪后有更少的噪声点;对汽车去噪后,能更直观地看见车玻璃框,以及更加平滑了汽车轮廓。

此外,本文还对比了去噪时间,在 NVIDIA GeForce RTX 4090 GPU 上进行测试,以确保测试时间的公平比较。如表 2 所示。本文方法在推理时间上比 ScoreDnoise 用时少 30%,与 IterativePFN 的推理时间相近。由于本文方法是基于 ScoreDenoise 的改进和提升,表中的实验数据证明了本文方法的优势。综合考虑,本文方法比现有去噪方法更有效。




图5 各模型在 Camel、Casting、Chair、Cow、Kitten、Duck、Horse (50 K 个点 2% 的噪声) 去噪后的视觉效果
Fig. 5 Visual effects of each model after denoising in Camel, Casting, Chair, Cow, Kitten, Duck, Horse (2% noise at 50 K points)



图6 IterativePFN与本文方法的对比图
Fig. 6 Comparison image between IterativePFN and ours




图7 不同模型在 Elephant 点云去噪后的视觉效果
Fig. 7 Visual effects of different models after denoising the Elephant point cloud




图8 不同模型在RueMadame数据集上的视觉效果

Fig. 8 Visual effects of different models after denoising the RueMadame dataset

表2 模型在RueMadame数据集上的去噪时间

Table 2 Denoising time of the model on the RueMadame dataset		
/s		
模型	RueMadame_2	RueMadame_3
ScoreDenoise	107	100
IterativePFN	68	67
本文	71	70

3.5 泛化性比较

本文方法训练带有0.5%~2%噪声的数据集,从表1的实验数据中可以看出,本文方法比其他方法更好。在实际情况中,本文方法获得的噪声水平不一定在训练的范围内。因此,为了证明模型具有更好的泛化能力,本文分别在噪声为3%的PU数据集(Yu等,2018)和PC数据集(Rakotosaona等,2020)上进行了测试。鉴于本文模型是基于ScoreDenoise的改进算法。因此,主要关注其与分数去噪方法泛化性的比较。具体结果见表1和表3。从实验数据来看,本文方法展现出更强的泛化性能。

3.6 消融研究

本文讨论了几个因素对本文方法的影响。首先,迭代层数的大小影响模型的大小,因此,需要进行消融实验来确定模型的迭代层数。表4展示了不同迭代层数对去噪的影响。从CD和P2M的数据结

表3 在3%噪声的PC数据集进行泛化性的比较(CD和P2M的数值×10⁵)

Table 3 Comparison of generalisability in PC dataset with 3% noise(CD and P2M distances are multiplied by 10⁵)

模型	PCNet			
	10 K点		50 K点	
	CD	P2M	CD	P2M
ScoreDenoise	72.46	27.95	35.57	15.49
IterativePFN	60.25	31.25	25.49	17.21
本文	56.25	28.49	18.78	11.79

注:加粗字体表示各列最优结果。

果来看,4层迭代的效果最佳。因此,选择了4次外部迭代作为本文模型的迭代层数。通过观察结果,发现2次和8次迭代效果相对于其他模型的效果也更好,这间接表明了本文模型在去噪方面优于现有大部分模型。

另外,对使用的动量梯度上升和外部迭代模块是否有效进行了消融研究。首先去除模型中的动量梯度上升模块与完整模型进行对比,然后去除外部迭代模块与完整模型进行对比,通过两组对比突出本文模型的有效性。如表5和表6所示,分别在10 K和50 K的点云上对噪声1%和2%进行测试。结果表明,在模型中加入动量梯度上升和外部迭代模块是有效的。通过对实验数据的分析,加入动量梯度

表 4 不同迭代次数下的消融实验(CD和P2M的数值 $\times 10^5$)
Table 4 Ablation experiments with different number of iterations(CD and P2M distances are multiplied by 10^5)

迭代次数	50 K点			
	1% 噪声		2% 噪声	
	CD	P2M	CD	P2M
$T = 2$	6.10	3.04	8.62	4.73
$T = 4$	5.92	2.94	8.00	4.35
$T = 8$	6.02	3.06	8.25	4.47

注:加粗字体表示各列最优结果。

上升后,模型对于数据的处理整理有了提升;加入迭代模块后,虽然在1%噪声下P2M的数据没有更好,但是整体对数据的提升很大,因此,这个模块也是必不可少的。最后对动量梯度上升和外部迭代模块对点云去噪速度的影响做了消融实验。在RueMadame数据集上进行实验。如表7所示,动量梯度上升和外部迭代模块都提升了去噪速度。动量梯度上升对速度的提升微小,外部迭代模块对速度的提升较大。

表 5 是否使用动量梯度上升和外部迭代模块的消融实验 1
(CD和P2M的数值 $\times 10^5$)

Table 5 Ablation experiment 1 with or without the use of momentum gradient rise and external iterative modules (CD and P2M distances are multiplied by 10^5)

方法	10 K点			
	1% 噪声		2% 噪声	
	CD	P2M	CD	P2M
无动量梯度上升	20.82	5.15	31.86	9.45
无外部迭代模块	25.22	4.68	36.84	10.83
本文	19.97	4.88	30.10	8.13

注:加粗字体表示各列最优结果。

4 结 论

在3D重建、自动驾驶环境感知及机器人导航避障等领域都需要点云数据。然而点云数据的获取容易受到外界各种噪声的干扰。为此,本文研究了传统去噪与深度学习去噪的优缺点,提出一种新的深度学习点云去噪模型,即外部迭代分数模型,并与最新的点云去噪算法进行对比实验,结果表明本文方法更加有效。外部迭代分数模型算法是在原本分数

表 6 是否使用动量梯度上升和外部迭代模块的消融实验 2
(CD和P2M的数值 $\times 10^5$)

Table 6 Ablation experiment 2 with or without the use of momentum gradient rise and external iterative modules (CD and P2M distances are multiplied by 10^5)

方法	50 K点			
	1% 噪声		2% 噪声	
	CD	P2M	CD	P2M
无动量梯度上升	6.11	3.11	9.39	5.28
无外部迭代模块	7.16	2.50	12.89	5.72
本文	5.92	2.94	8.00	4.35

注:加粗字体表示各列最优结果。

表 7 动量梯度上升和外部迭代模块对点云去噪速度的消融实验

Table 7 Ablation experiments on point cloud denoising speed by momentum gradient ascent and external iteration modules

方法			/s
	RueMadame_2	RueMadame_3	
无动量梯度上升	75	74	
无外部迭代模块	105	98	
本文	71	70	

注:加粗字体表示各列最优结果。

模型去噪的基础上,加入多层外部迭代模块,将原本无限次的分数模型内部迭代转化为有限次的外部迭代,加快去噪的速度。并且在分数模型内部计算点云移动的梯度时,加入动量梯度上升来稳定和加快点的位移,确保去噪结果能稳定收敛到干净表面。在3个数据集上与其他方法比较,实验结果表明本文方法有更好的去噪精度和更快的去噪速度。

本文提出的基于外部迭代分数模型的点云去噪在1%、2%和3%高斯噪声水平上的表现基本良好,然而在低噪声或高噪声水平上仍有很大的提升空间,这需要后续继续补充实验进行验证。此外,在时间上虽然有大幅降低,但相比于最新方法没有很大提升。这可能是由于本文网络框架较大,在后续研究中,可以通过优化损失函数来提高网络的训练速度和模型的性能。

在文中所提的噪声是高斯噪声,但是实际生活中存在各种各样的噪声,例如乘性噪声等,这些噪声同样会影响获取到的点云。在后续工作中将模型适

用于去除各类噪声是一个极具价值的研究方向。

参考文献(References)

- Avron H, Sharf A, Greif C and Cohen-Or D. 2010. ℓ_1 -sparse reconstruction of sharp point set surfaces. *ACM Transactions on Graphics*, 29(5): #135 [DOI: 10.1145/1857907.1857911]
- Bai J Q, Yang Z W, Guan Y C and Yu Q. 2023. PCRT: multi-branch point cloud reconstruction from a single image with transformers// *Proceedings of the 6th Chinese Conference on Pattern Recognition and Computer Vision*. Singapore, Singapore: Springer: 259-270 [DOI: 10.1007/978-981-99-8432-9_21]
- Casajus P H, Ritschel T and Ropinski T. 2019. Total denoising: unsupervised learning of 3D point cloud cleaning//*Proceedings of 2019 IEEE/CVF International Conference on Computer Vision*. Seoul, Korea (South): IEEE: 52-60 [DOI: 10.1109/ICCV.2019.00014]
- Chen J W, Zhao L L, Ren L C, Sun Z Q, Zhang X F and Ma S W. 2023. Deep learning-based quality enhancement for 3D point clouds: a survey. *Journal of Image and Graphics*, 28(11): 3295-3319 (陈建文, 赵丽丽, 任蓝草, 孙卓群, 张新峰, 马思伟. 2023. 深度学习点云质量增强方法综述. *中国图象图形学报*, 28(11): 3295-3319) [DOI: 10.11834/jig.221076]
- Chong S J, Wang S W and Liu L G. 2022. Guided normal GPU filtering of depth images. *Journal of Graphics*, 43(1): 118-124 (崇斯杰, 王士玮, 刘利刚. 2022. 深度图像的法向指导GPU滤波. *图学学报*, 43(1): 118-124) [DOI: 10.11996/JG.j.2095-302X.2022010118]
- Dai S J, Ren Y C and Zhang H B. 2018. Study on smooth denoising of 3D scattered point clouds with anisotropic diffusion filtering. *Journal of Computer-Aided Design and Computer Graphics*, 30(10): 1843-1849 (戴士杰, 任永潮, 张慧博. 2018. 各向异性扩散滤波的三维散乱点云平滑去噪算法. *计算机辅助设计与图形学学报*, 30(10): 1843-1849) [DOI: 10.3724/SP.J.1089.2018.16940]
- de Silva Edirimuni D, Lu X Q, Shao Z W, Li G, Robles-Kelly A and He Y. 2023. IterativePFN: true iterative point cloud filtering//*Proceedings of 2023 IEEE/CVF Conference on Computer Vision and Pattern Recognition*. Vancouver, Canada: IEEE: 13530-13539 [DOI: 10.1109/CVPR52729.2023.01300]
- Fan H Q, Su H and Guibas L. 2017. A point set generation network for 3D object reconstruction from a single image//*Proceedings of 2017 IEEE Conference on Computer Vision and Pattern Recognition*. Honolulu, USA: IEEE: 2463-2471 [DOI: 10.1109/CVPR.2017.264]
- Gao J Y, Guo Y W, Wang L S, Wang J and Wei M Q. 2022. Geometric prior and deep learning co-supported normal estimation for point cloud. *Journal of Computer-Aided Design and Computer Graphics*, 34(1): 9-17 (郜金艳, 郭延文, 王连生, 汪俊, 魏明强. 2022. 基于几何先验和深度学习的点云法矢估算. *计算机辅助设计与图形学学报*, 34(1): 9-17) [DOI: 10.3724/SP.J.1089.2022.18820]
- Gao X, Hu W and Guo Z M. 2018. Graph-based point cloud denoising// *Proceedings of the 4th IEEE International Conference on Multimedia Big Data (BigMM)*. Xi'an, China: IEEE: 1-6 [DOI: 10.1109/BigMM.2018.8499090]
- Guennebaud G and Gross M. 2007. Algebraic point set surfaces//*ACM SIGGRAPH 2007 Papers*. San Diego, USA: ACM: #23 [DOI: 10.1145/1275808.1276406]
- He L and Schaefer S. 2013. Mesh denoising via L_0 minimization. *ACM Transactions on Graphics*, 32(4): #64 [DOI: 10.1145/2461912.2461965]
- Hu H, Wang Q B, Lu J W, Su H Y, Lai J K and Xiao G. 2023. MSPoint: point cloud denoising network based on multiscale distribution score. *Laser and Optoelectronics Progress*, 60(16): #1615002 (胡豪, 王琪冰, 陆佳伟, 苏宏业, 来见坤, 肖刚. 2023. MSPoint: 基于多尺度分布分数的点云去噪网络. *激光与光电子学进展*, 60(16): #1615002 [DOI: 10.3788/LOP222402]
- Huang H, Li D, Zhang H, Ascher U and Cohen-Or D. 2009. Consolidation of unorganized point clouds for surface reconstruction. *ACM Transactions on Graphics*, 28(5): 1-7 [DOI: 10.1145/1618452.1618522]
- Huang H, Wu S H, Gong M L, Cohen-Or D, Ascher U and Zhang H. 2013. Edge-aware point set resampling. *ACM Transactions on Graphics*, 2013, 32(1): #9 [DOI: 10.1145/2421636.2421645]
- Johnson J, Ravi N, Reizenstein J, Novotny D, Tulsiani S, Lassner C and Branson S. 2020. Accelerating 3D deep learning with pyTorch3D//*SIGGRAPH Asia 2020 Courses*. New York, USA: Association for Computing Machinery: #10 [DOI: 10.1145/3415263.3419160]
- Kolluri R. 2008. Provably good moving least squares. *ACM Transactions on Algorithms*, 4(2): #18 [DOI: 10.1145/1361192.1361195]
- Li R H, Li X Z, Heng P A and Fu C W. 2021. Point cloud upsampling via disentangled refinement//*Proceedings of 2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition*. Nashville, USA: IEEE: 344-353 [DOI: 10.1109/CVPR46437.2021.00041]
- Lipman Y, Cohen-Or D, Levin D and Tal-Ezer H. 2007. Parameterization-free projection for geometry reconstruction. *ACM Transactions on Graphics*, 26(3): #22 [DOI: 10.1145/1276377.1276405]
- Lu J X, Li Z Z, Bai J Q and Yu Q. 2022. Oriented and directional chamfer distance losses for 3D object reconstruction from a single image. *IEEE Access*, 10: 61631-61638 [DOI: 10.1109/ACCESS.2022.3179109]
- Lu X Q, Wu S H, Chen H H, Yeung S K, Chen W Z and Zwicker M. 2018. GPF: GMM-inspired feature-preserving point set filtering. *IEEE Transactions on Visualization and Computer Graphics*, 24(8): 2315-2326 [DOI: 10.1109/TVCG.2017.2725948]
- Luo S T and Hu W. 2020. Differentiable manifold reconstruction for point cloud denoising//*Proceedings of the 28th ACM International Conference on Multimedia*. Seattle, USA: ACM: 1330-1338 [DOI: 10.1145/3394171.3413727]

- Luo S T and Hu W. 2021. Score-based point cloud denoising//Proceedings of 2021 IEEE/CVF International Conference on Computer Vision. Montreal, Canada: IEEE: 4563-4572 [DOI: 10.1109/ICCV48922.2021.00454]
- Mao A H, Du Z H, Wen Y H, Xuan J and Liu Y J. 2022. Pd-flow: a point cloud denoising framework with normalizing flows//Proceedings of the 17th European Conference. Tel Aviv, Israel: Springer: 398-415 [DOI: 10.1007/978-3-031-20062-5_23]
- Mattei E and Castrodad A. 2017. Point cloud denoising via moving RPCA. *Computer Graphics Forum*, 36 (8): 123-137 [DOI: 10.1111/cgf.13068]
- Myronenko A and Song X B. 2010. Point set registration: coherent point drift. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 32(12): 2262-2275 [DOI: 10.1109/TPAMI.2010.46]
- Öztireli A C, Guennebaud G and Gross M. 2009. Feature preserving point set surfaces based on non-linear kernel regression. *Computer Graphics Forum*, 28 (2): 493-501 [DOI: 10.1111/j.1467-8659.2009.01388.x]
- Pistilli F, Fracastoro G, Valsesia D and Magli E. 2020. Learning graph-convolutional representations for point cloud denoising//Proceedings of the 16th European Conference. Glasgow, UK: Springer: 103-118 [DOI: 10.1007/978-3-030-58565-5_7]
- Preiner R, Mattausch O, Arikan M, Pajarola R and Wimmer M. 2014. Continuous projection for fast L_1 reconstruction. *ACM Transactions on Graphics*, 33(4): #47 [DOI: 10.1145/2601097.2601172]
- Rakotosaona M J, La Barbera V, Guerrero P, Mitra N and Ovsjanikov M. 2020. PointCleanNet: learning to denoise and remove outliers from dense point clouds. *Computer Graphics Forum*, 39(1): 185-203 [DOI: 10.1111/cgf.13753]
- Roveri R, Öztireli A C, Pandele I and Gross M. 2018. PointProNets: consolidation of point clouds with convolutional neural networks. *Computer Graphics Forum*, 37 (2): 87-99 [DOI: 10.1111/cgf.13344]
- Rusu R B and Cousins S. 2011. 3d is here: point cloud library (PCL)//Proceedings of 2011 IEEE International Conference on Robotics and Automation. Shanghai, China: IEEE: 1-4 [DOI: 10.1109/ICRA.2011.5980567]
- Schoenenberger Y, Paratte J and Vandergheynst P. 2015. Graph-based denoising for time-varying point clouds//Proceedings of 2015 3DTV-Conference: the True Vision-Capture, Transmission and Display of 3D Video (3DTV-CON). Lisbon, Portugal: IEEE: 1-4 [DOI: 10.1109/3DTV.2015.7169366]
- Serna A, Marcotegui B, Goulette F and Deschaud J E. 2014. Paris-rue-Madame database: a 3D mobile laser scanner dataset for benchmarking urban detection, segmentation and classification methods//Proceedings of the 4th International Conference on Pattern Recognition, Applications and Methods ICPRAM 2014. Angers, France: HAL
- Shen C, O'Brien J F and Shewchuk J R. 2004. Interpolating and approximating implicit surfaces from polygon soup//ACM SIGGRAPH 2004 Papers. Los Angeles, USA: ACM: 896-904 [DOI: 10.1145/1186562.1015816]
- Sun Y J, Schaefer S and Wang W P. 2015. Denoising point sets via L_0 minimization. *Computer Aided Geometric Design*, 35-36: 2-15 [DOI: 10.1016/j.cagd.2015.03.011]
- Wang Y, Sun Y B, Liu Z W, Sarma S E, Bronstein M M and Solomon J M. 2019. Dynamic graph CNN for learning on point clouds. *ACM Transactions on Graphics*, 38(5): #146 [DOI: 10.1145/3326362]
- Wu Y Q, Chen H X and Zhang Y. 2024. Review of 3D point cloud processing methods based on deep learning. *Chinese Journal of Lasers*, 51(5): #0509001 (吴一全, 陈慧娴, 张耀. 2024. 基于深度学习的三维点云处理方法研究进展. *中国激光*, 51(5): #0509001) [DOI: 10.3788/CJL230924]
- Xu L, Lu C W, Xu Y and Jia J Y. 2011. Image smoothing via L_0 gradient minimization//Proceedings of 2011 SIGGRAPH Asia Conference. Hong Kong, China: ACM: #174 [DOI: 10.1145/2024156.2024208]
- Yu L Q, Li X Z, Fu C W, Cohen-Or D and Heng P A. 2018. Pu-Net: point cloud upsampling network//Proceedings of 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Salt Lake City, USA: IEEE: 2790-2799 [DOI: 10.1109/CVPR.2018.00295]
- Yu Q, Lu J X, Bai J Q and Fan H H. 2022. A review of 3D objects reconstruction based on deep learning. *Journal of Jiangsu University of Technology*, 28(4): 31-41 (郁钱, 路金晓, 柏基权, 范洪辉. 2022. 基于深度学习的三维物体重建方法研究综述. *江苏理工学院学报*, 28(4): 31-41) [DOI: 10.19831/j.cnki.2095-7394.2022.04.002]
- Zhang D B, Lu X Q, Qin H and He Y. 2021. Pointfilter: point cloud filtering via encoder-decoder modeling. *IEEE Transactions on Visualization and Computer Graphics*, 27 (3): 2015-2027 [DOI: 10.1109/TVCG.2020.3027069]
- Zhou J, Jin W, Wang M J, Liu X P, Li Z Y and Liu Z B. 2022. Fast and accurate normal estimation for point clouds via patch stitching. *Computer-Aided Design*, 142: #103121 [DOI: 10.1016/j.cad.2021.103121]

作者简介

管雨辰,女,硕士研究生,主要研究方向为3D视觉和深度学习。E-mail:2022655227@smail.jsut.edu.cn

郁钱,通信作者,男,副教授,主要研究方向为3D视觉和深度学习。E-mail: yuqian@jsut.edu.cn

胡宇,男,硕士研究生,主要研究方向为3D视觉和深度学习。E-mail: 2448129724@qq.com

张肖莹,女,硕士研究生,主要研究方向为3D视觉和深度学习。E-mail: 2227284091@qq.com

李昱卓,女,硕士研究生,主要研究方向为3D视觉和深度学习。E-mail:1377324917@qq.com