

中图法分类号: TP391; TP18 文献标识码: A 文章编号: 1006-8961(2026)01-0261-12

论文引用格式: Quan S W, Zhang S T, Zhao H B, Nie Z M, Hu Z W and Yang J Q. 2026. Two-stage dual-branch model for 3D point cloud denoising. Journal of Image and Graphics, 31(1):0261-0272(权思文, 张淑婷, 赵河彬, 聂子铭, 胡忠文, 杨佳琪. 2026. 双阶段双分支模型的三维点云去噪. 中国图象图形学报, 31(1):0261-0272)[DOI:10.11834/jig.250076]

双阶段双分支模型的三维点云去噪

权思文¹, 张淑婷¹, 赵河彬¹, 聂子铭², 胡忠文^{3*}, 杨佳琪²

1. 长安大学电子与控制工程学院, 西安 710064; 2. 西北工业大学计算机学院, 西安 710072;

3. 深圳大学自然资源部大湾区地理环境监测重点实验室, 深圳 518060

摘要: 目的 三维点云数据在三维重建、自动驾驶等领域有着广泛应用, 然而由于传感器设备受限和环境因素, 点云数据不可避免地受到噪声影响, 降低了数据质量, 进而影响了后续处理和分析的准确性。现有的基于深度学习的点云去噪主流方法大多采取单阶段单分支去噪流程, 导致模型学习到的特征的表达能力有限, 难以捕捉点云复杂的结构信息。因此, 提出一种双阶段双分支模型用于三维点云去噪, 旨在获得综合点云特征。**方法** 阶段1: 利用双分支编码器提取点云块局部和全局特征, 并用交叉注意力融合; 阶段2: 利用注意力机制增强阶段1特征, 聚焦强特征表达。最终, 加权融合两阶段解码位移, 指导点云去噪。**结果** 在3个数据集上与较新的6种方法进行比较, 在PUNet(point cloud upsampling network)数据集上, 相比Pointfilter取得3个最佳性能、2个次佳性能, 双分支双编码器模型取得6个最佳性能、3个次佳性能; 在PCNet(point clean network)数据集上, 相比于IterativePFN取得2个最佳性能、6个次佳性能, 双分支双编码器模型取得7个最佳性能、3个次佳性能; 在Kinect_v1数据集上, 相比于同期最优模型, 双阶段双分支模型在两种指标上取得次佳效果, 整体达到最佳。**结论** 本文所提出的双阶段双分支模型的三维点云去噪, 解决了点云数据块局部特征和全局特征的提取和融合问题, 实现了更好的去噪效果。

关键词: 深度学习; 三维点云去噪; 双分支编码器; 特征融合; 注意力机制

Two-stage dual-branch model for 3D point cloud denoising

Quan Siwen¹, Zhang Shuting¹, Zhao Hebin¹, Nie Ziming², Hu Zhongwen^{3*}, Yang Jiaqi²

1. School of Electronics and Control Engineering, Chang'an University, Xi'an 710064, China; 2. School of Computer Science, Northwestern Polytechnical University, Xi'an 710072, China; 3. Key Laboratory for Geo-Environmental Monitoring of Great Bay Area, Ministry of Natural Resources, Shenzhen University, Shenzhen 518060, China

Abstract: Objective Three-dimensional point cloud data has become an vital component in various modern technological applications, including autonomous navigation systems and the rapidly evolving realm of virtual reality. In these domains, the demand for precise and high-quality point cloud data is critical to ensuring that operational tasks are performed efficiently and accurately. However, generating accurate and clean point cloud data presents considerable challenges. Numerous factors, such as limitations in sensor technologies, varying environmental conditions, and errors during data processing, can introduce noise into the point cloud data, drastically compromising its quality and precision. Noise within point cloud data represents a significant hurdle to obtaining reliable information about the environment. This noise presents a

收稿日期: 2025-03-07; 修回日期: 2025-05-05; 预印本日期: 2025-05-12

* 通信作者: 胡忠文 zwhoo@szu.edu.cn

基金项目: 国家自然科学基金项目(62372377); 自然资源部大湾区地理环境监测重点实验室开放基金资助项目(GEMLab-2024005)

Supported by: National Natural Science Foundation of China (62372377); Open Research Fund Program of MNR Key Laboratory for Geo-Environmental Monitoring of Great Bay Area (GEMLab-2024005)

major obstacle to acquiring reliable environmental information. Noise in point cloud data can obscure important spatial details, leading to uncertainties in applications that rely on accurate spatial data. For instance, in autonomous navigation, noise may result in incorrect obstacle detection, while in virtual reality, it can diminish the realism and immersion of virtual environments. Recognizing these challenges, researchers have invested considerable efforts in devising denoising techniques aimed at removing noise and enhancing data reliability. Among these strategies developed, deep learning methods have attracted substantial attention. These advanced approaches leverage neural networks to learn intricate mappings from noisy inputs to clean outputs. By capturing complex relationships between noisy and clean point cloud features, deep learning approaches offer promising improvements in denoising performance. **Method** Aiming to address the persistent challenge of noise in point cloud data, a novel method has been introduced. This method employs a network architecture comprising two primary stages, each augmented with distinct and complementary components. The first stage features a dual-branch encoder-decoder framework. Within this stage, the encoder is divided into two branches: a local encoder dedicated to learning local point cloud features, and a patch-based encoder that captures overall block features. An innovative aspect of this design lies in the integration of a cross-attention module. This module is designed to facilitate information exchange between local and block features, thus fostering a robust and comprehensive representation of point cloud data. During the feature extraction process in the first stage, the local encoder performs calculations to combine point distribution features. Meanwhile, the patch encoder computes and integrates patch shape features. This dual approach ensures that local micro-level details and global macro-level characteristics are preserved during the learning phase. Following feature extraction, the decoder plays a crucial role by estimating an initial displacement vector. This vector is subsequently added to the original noisy point cloud data, producing an intermediate output. This output is then channeled into the second stage, shifting the focus to feature enhancement. The second stage is designed to further refine and update the feature sets extracted during the first stage. A key characteristic of this two-stage model lies in its iterative learning process. The output features from the feature enhancement module in the second stage are recursively fed back into the decoder of the first stage. This recursive feedback loop enables an additional round of displacement decoding, allowing the newly generated displacement to interact synergistically with the previously updated point cloud data, thereby ensuring progressive refinement. In this stage, the decoder processes this feedback information to regress a refined displacement vector. The final vector emerges from a weighted summation of the displacement vectors generated by both stages. Consequently, an optimized displacement vector is achieved, adeptly guiding the denoising process of the noisy point clouds. **Result** Aiming to evaluate the effectiveness of the proposed methodology, extensive experiments were conducted on three renowned point cloud denoising datasets: point cloud upsampling network (PUNet), point cloud network (PCNet), and Kinect_v1. These experiments were accompanied by comparative analyses with six leading denoising techniques. The results demonstrated the superior performance of the proposed model. For instance, on the PUNet dataset, while Pointfilter achieved three best performances and two second-best performances, the dual-branch dual-encoder model achieved six best and three second-best performances. Similarly, on the PCNet dataset, IterativePFN recorded two best and six second-best performances, whereas the dual-branch dual-encoder model achieved seven best and three second-best performances. On the Kinect_v1 dataset, although the proposed model delivered suboptimal performance in certain individual metrics compared to the best-performing methods, it achieved the highest overall performance. **Conclusion** The successful implementation of the two-stage dual-branch model effectively addresses the complex challenge of extracting and integrating local and global features within point cloud data blocks. By incorporating advanced attention mechanisms, the proposed method achieves considerable improvements in denoising performance while maintaining the geometric integrity and structural characteristics of the data. The notable gains across multiple benchmark datasets highlight the method's potential to advancing point cloud processing, with promising applications in areas such as 3D reconstruction, autonomous navigation, and immersive virtual reality.

Key words: deep learning; 3D point cloud denoising; dual-branch encoder; feature fusion; attention mechanism

0 引言

三维点云是物体或场景在三维空间的数字化表示,由大量离散的点组成,每个点包含其在三维空间的坐标信息,能够精确表示物体或场景的形状、结构和表面特征。三维点云可以通过激光雷达、立体相机和深度相机等设备获得,并广泛应用于自动驾驶、机器人导航与定位和虚拟现实等领域(孙刘杰等,2024)。但由于数据采集过程中的环境因素干扰和扫描设备精度限制,三维点云中不可避免地夹杂了噪声点,而三维点云去噪旨在去除点云数据中的噪声点,以提高点云分割、三维目标检测以及三维重建等下游任务的准确度和效率(管雨辰等,2025)。

传统的点云去噪算法可分为两大类:基于滤波的点云去噪算法和基于优化的点云去噪算法。基于滤波的点云去噪算法如:双边点云滤波(Digne和de Franchis,2017)将双边网格滤波(Fleishman等,2003)思想直接应用于点云数据上;点云位置信息引导滤波的点云去噪(Han等,2018a)根据点的位置信息,推导出与引导点云和滤波点云相关的线性模型;点云法线信息引导的点云去噪(Zheng等,2017;Han等,2018b)不仅关注点的位置,还利用法线作为引导信号,点的位置根据估计的法线进行更新;利用超图的新型点云模型(Zhang等,2021b)设计了超图滤波器,适用于理想的噪声环境。基于优化的点云去噪算法如:各向异性去噪算法(Xu和Foi,2021)将每个点的重叠自适应局部估计聚合,获得稳定且准确的点估计;局部最优投影的点云去噪算法强制生成一组均匀分布的点表示潜在表面,无参数化局部投影去噪技术(Lipman等,2007)克服了基于局部平面拟合方法的局限性,对噪声和离群点具有很高的鲁棒性;稀疏重建方法通过L1正则化(Leal等,2020;Mattei和Castrodad,2017)或字典学习(Digne等,2018)重建稀疏的表面法线;非局部去噪方法利用点云片段之间存在的非局部自相似性,以更好地保留细微的形状特征(Zheng等,2010;Digne,2012;Digne等,2014)。虽然上述传统点云算法都能在一定程度上去除噪声,但都依赖于几何先验信息或点法线估计,点法线的精度限制了点云去噪的最终结果,并且这些传统去噪算法计算复杂度高,容易造成点云数据的几何细节丢失。

基于深度学习的点云去噪算法能够自适应学习点云数据中的复杂特征,同时更好地保留点云几何细节信息,克服了传统点云去噪算法的局限。PointNet(Qi等,2017a)和PointNet++(Qi等,2017b)算法能够直接处理点云数据,为基于深度学习的点云去噪算法奠定了基础。现有基于深度学习的点云去噪算法可分为基于监督学习的点云去噪算法和基于无监督学习的点云去噪算法。基于监督学习的点云去噪算法如:EC-Net(edge-aware point set consolidation network)(Yu等,2018a)提出边缘感知技术,实现了更为准确的三维重建;PointcleanNet(Rakotosaona等,2020)将噪声点投影到原始干净曲面上的校正向量,去除了不同程度的噪声;Pointfilter(Zhang等,2021a)从噪声点云中学习位移向量,用来引导原始噪声点云回归;ScoreDenoise(Luo和Hu,2021)将噪声点云的分布视为干净样本与某种噪声模型的卷积,通过梯度上升法增加该卷积的对数似然,逐步更新每个点的位置;PDFlow(point cloud denoising framework with normalizing flows)(Mao等,2022)使用归一化流建模欧几里得空间和潜在空间之间的映射,在潜在空间解耦分离出噪声表示,干净的潜在表示通过逆向的归一化流映射回欧几里得空间;IterativePFN(de Silva Edirimuni等,2023)在单个网络内部建模真实的迭代滤波过程,使用自适应真值目标,加速滤波的收敛;PathNet(Wei等,2024)为点云中的每个点动态选择最合适的去噪处理路径。基于无监督学习的点云去噪算法如:Total Denoising(Casajus等,2019)通过引入空间先验项克服三维点云数据无结构性带来的挑战;Noise4Denoise(Wang等,2024)利用不同噪声水平之间的关系学习点云去噪过程。现有的基于深度学习的点云去噪算法相较于传统方法具有显著优势,但大多算法只采取单阶段特征提取,难以捕捉到点云中的细节信息,且这些算法忽略了点云数据块的整体流形信息,导致提取到的点云特征表达能力受限,进而限制了模型性能。

为解决上述问题,本文提出一种双阶段双分支模型的点云去噪方法,双分支模型提取点云数据块的局部特征和全局特征,双阶段模型则进一步精炼提取的特征,通过学习到的噪声点云的数据特征预测一个位移向量,用来引导点云去噪。阶段1的双分支编码器包含局部编码器和基于块的编码器,分别用于学习局部点云特征和整体点云数据块的特

征,并使用交叉注意力模块对两种特征进行信息融合。阶段1的解码器用来初步回归一个位移向量并输出,将该位移与原始噪声点云数据相加,通过阶段2的特征增强模块实现特征更新。此外,阶段1的解码器与阶段2的特征增强模块会进行迭代学习,最终得到精确的位移向量,该位移向量便能最大程度地引导噪声点云回归到干净的表面。

总而言之,本文的贡献如下:1)设计了双阶段双分支点云去噪模型,通过双阶段双分支特征精炼,让点云潜在表征更加接近真实底层表面,并将阶段1解码器输出预测的中间级点云位移与阶段2的解码器输出的位移向量按权重相加和,从而使得最后回归的位移向量更为准确;2)提出双分支点云编码器架构,两个分支分别对点云局部特征和点云块特征进行学习,获得点云几何细节信息和点云块的整体信息,两种信息相融合,在维持点云细节信息的同时保留了更为完整的点云数据信息。

本文进行了全面的实验,与现有的点云去噪算法进行对比,无论在合成数据集上,还是真实场景扫描的数据集上都取得了较好的实验效果。

1 模型方法

1.1 整体框架

基于深度学习的点云去噪旨在利用深度学习算法去除点云数据中的噪声,以提高点云数据的质量。现有的主流方法通常将完整的点云场景划分为点云数据块,进行分块去噪后合并。

本文利用双阶段双分支的点云去噪模型预测点云数据块中每个点到潜在底层干净表面的位移,该位移便可引导点云数据块中的点回归到干净的表面上,具体为

$$\hat{P}_i = \tilde{P}_i + \hat{d}_i \quad (1)$$

式中, $\tilde{P}_i \in \mathbf{R}^{N \times 3}$ 表示原始噪声点云数据块, N 表示数据块中点的数量, 3 为点云数据的坐标维度; $\hat{P}_i \in \mathbf{R}^{N \times 3}$ 表示去噪后的点云数据块; $\hat{d}_i$ 表示模型预测的点云数据块中每个点对应的位移。

如图1所示,本文提出的双阶段双分支的点云去噪模型可分为两个阶段,包括4个模块。分别为阶段1:双分支编码器、解码器;阶段2:特征增强模块、解码器。阶段1的双分支编码器将噪声点云数

据块输入两个不同的编码器,获得点云局部特征 f_l 和点云数据块整体特征 f_p , 将两个特征进行特征融合后得到整体特征 f_o 。阶段1的解码器输出 τ 个中间级预测的位移 d_p^τ 。阶段2的特征增强模块旨在利用 d_p^τ 对经过双分支编码器得到的点云特征 f_o 进行增强,使其更接近于干净点云的潜在空间表示,增强后特征用 f_e^τ 表示。为提升去噪效果,阶段1的解码器和阶段2的特征增强模块会进行迭代,迭代次数为8次。阶段2的解码器最终会将特征增强模块的最终输出解码为一个位移向量 d_i , 该位移向量与阶段1解码器输出的位移向量加和,得到最终的位移向量 $\hat{d}_i$ 。

1.2 子模块介绍

1.2.1 阶段1的双分支编码器模块

双分支编码器的设计是为了同时捕捉点云数据块的局部特征和全局特征,以增强模型对复杂几何结构的理解能力。该编码器由局部编码器和点云块编码器两个主要部分组成,并通过交叉注意力机制进行特征融合。

局部编码器负责提取点云数据块中每个点的局部邻域特征。在局部编码器中,原始噪声点云数据块 $\tilde{P}_i$ 先分别经过动态图卷积层(dynamic graph convolution neural network, DGCNN)(Wang 等, 2019)和均匀性计算层。动态边缘卷积层通过动态构建邻接图,捕捉每个点与其 k 个近邻点之间的关系。动态图卷积层共有4层,为了确保最大限度保留点云特征信息,选择了跳跃连接将前3层的输出作为第4层的输入。具体为

$$\mathbf{x}_i^{j+1} = f_{\text{DGCNN}}(\mathbf{x}_i^j), j = 0, 1, 2 \quad (2)$$

式中, $\mathbf{x}_i^j$ 是 $\tilde{P}_i$ 中的点特征, $\mathbf{x}_i^0$ 为边缘卷积层的输入, $\mathbf{x}_i^1$ 表示经过第1层动态卷积层后提取的点特征。在均匀性计算层中,计算每个点与其 k 个近邻点的平均距离作为该点的均匀性特征 $\mathbf{x}_u$ 。随后,动态图卷积层和均匀性计算层提取的特征通过多头注意力层(multi-head attention, MHA)。

$$\mathbf{h}_p = f_{\text{MHA}}(\mathbf{x}_i^4, \mathbf{x}_i^4, \mathbf{x}_i^4) \quad (3)$$

$$\mathbf{h}_u = f_{\text{MHA}}(\mathbf{x}_u, \mathbf{x}_u, \mathbf{x}_u) \quad (4)$$

式中, $\mathbf{h}_p$ 和 $\mathbf{h}_u$ 表示经过 MHA 层之后的 $\mathbf{x}_i^4$ 和 $\mathbf{x}_u$ 。 $\mathbf{h}_p$ 和 $\mathbf{h}_u$ 再经过特征融合层 Fusion 和归一化层 norm

$$\mathbf{f}_i = f_{\text{Fusion}}(f_{\text{norm}}(\mathbf{h}_p), f_{\text{norm}}(\mathbf{h}_u)) \quad (5)$$

式中, $\mathbf{f}_i$ 为最终融合生成的点云数据块局部特征。




图1 双阶段双分支去噪模型框架

Fig. 1 Two-stage dual-branch denoising model framework

点云块编码器负责捕捉整个点云数据块中的全局结构信息。在点云块编码器中,原始噪声点云数据块 \$\tilde{P}_i\$ 首先经过一系列一维卷积层和最大池化层提取点云数据块全局特征,接着经过形状描述器,计算协方差矩阵的主方向和包围盒信息,接着通过注意力权重对该特征进行加权,突出重要的全局信息。最终,使用跳跃连接,将形状描述器生成的特征与加权形状描述器特征进行融合,生成点云数据块全局特征表示 \$f_p\$。

为了实现点云数据块局部特征和全局特征的信息交互,模型中添加了交叉注意力机制,实现了局部特征关注全局特征,全局特征关注局部信息。

$$f_1' = f_{\text{MHA}}(f_1, f_p, f_p) \quad (6)$$

$$f_p' = f_{\text{MHA}}(f_p, f_1, f_1) \quad (7)$$

式中, \$f_1'\$ 和 \$f_p'\$ 分别表示经过信息整合后的点云数据块的局部信息和全局信息,接着进行残差连接和归一化。

$$f_1'' = f_{\text{norm}}(f_1 + f_1') \quad (8)$$

$$f_p'' = f_{\text{norm}}(f_p + f_p') \quad (9)$$

式中, \$f_1''\$ 和 \$f_p''\$ 表示将 \$f_1'\$、\$f_1\$ 和 \$f_p'\$、\$f_p\$ 进行残差连接和归一化之后的特征。随后,利用门控机制加权

$$G = \sigma(W \cdot [f_s \| f_s'] + b) \quad (10)$$

$$f_o = G \cdot f_s + (1 - G) \cdot f_s' \quad (11)$$

式中, \$f_s\$ 表示 \$f_1''\$ 与 \$f_p''\$ 拼接后的特征, \$f_s'\$ 表示 \$f_s\$ 经过多层感知机后得到的特征, \$\sigma\$ 表示 sigmoid 激活函数, \$\| \$ 表示特征拼接, \$W\$ 表示可学习的权重矩阵, \$b\$ 表示偏置项, \$G\$ 为最终得到的门控向量。最后,使用门控向量分别对 \$f_s'\$ 和 \$f_s\$ 进行加权融合, \$f_o\$ 表示加权融合后的特征。

1.2.2 阶段1的解码器模块

该模块用来预测中间级位移,指导阶段2的特征增强模块进行特征更新。通过双分支编码器生成的特征 \$f_o\$ 首先进入阶段1的解码器,生成初次的解码位移。

$$d_p^0 = f_{\text{MLP}}(f_o) \quad (12)$$

式中, \$d_p^0\$ 表示初次解码位移, \$f_{\text{MLP}}\$ 表示多层感知机 (multi-layer perceptron, MLP)。在之后的迭代过程中,该解码器还会生成中间级预测位移 \$d_p^\tau\$, \$\tau\$ 表示第 \$\tau\$ 次迭代学习。

1.2.3 阶段2的特征增强模块

特征增强模块参考 PD-Refiner(Zhang 等, 2024) 设计,主要负责点云特征的更新和增强,提升点云数

据的表达能力和模型整体性能,通过统一建模空间与特征信息,实现对点云数据的精细处理。

经过阶段1解码器生成的位移 $\mathbf{d}_p^\tau$ 输入特征增强模块更新特征。首先,将位移与原始噪声点云拼接,此时点云数据被更新,初步更新过后的点云数据随后分别经过两个不同的多层感知机,进行特征提取。

$$\tilde{\mathbf{P}}'_i = \tilde{\mathbf{P}}_i + \mathbf{d}_p^\tau \quad (13)$$

$$\mathbf{f}_{u_1}^\tau = f_{\text{MLP } 1}(\tilde{\mathbf{P}}'_i) \quad (14)$$

$$\mathbf{f}_{u_2}^\tau = f_{\text{MLP } 2}(\tilde{\mathbf{P}}'_i) \quad (15)$$

式中, $\tilde{\mathbf{P}}'_i$ 表示经过更新的点云数据, $\mathbf{f}_{u_1}^\tau$ 和 $\mathbf{f}_{u_2}^\tau$ 表示利用两个不同的多层感知机重新从 $\tilde{\mathbf{P}}'_i$ 中学习到的特征。随后, $\mathbf{f}_{u_1}^\tau$ 和 $\mathbf{f}_{u_2}^\tau$ 经过注意力层 Attention 得到特征 $\mathbf{f}_{a_1}^\tau$ 和 $\mathbf{f}_{a_2}^\tau$ 。 $\mathbf{f}_{a_1}^\tau$ 和 $\mathbf{f}_{a_2}^\tau$ 相加进行最大池化后得到特征 $\mathbf{f}_a^\tau$ 。 $\mathbf{f}_a^\tau$ 经过特征压缩层 Compress 得到特征 $\mathbf{f}_c^\tau$ 。 $\mathbf{f}_{a_1}^\tau$ 、 $\mathbf{f}_c^\tau$ 和 $\mathbf{f}_{a_2}^\tau$ 、 $\mathbf{f}_c^\tau$ 加权后得到特征 $\mathbf{f}_{aw_1}^\tau$ 和 $\mathbf{f}_{aw_2}^\tau$ 。

具体为

$$\mathbf{f}_{a_1}^\tau = f_{\text{Attention}}(\mathbf{f}_{u_1}^\tau) \quad (16)$$

$$\mathbf{f}_{a_2}^\tau = f_{\text{Attention}}(\mathbf{f}_{u_2}^\tau) \quad (17)$$

$$\mathbf{f}_a^\tau = f_{\text{Maxpool1D}}(\mathbf{f}_{a_1}^\tau + \mathbf{f}_{a_2}^\tau) \quad (18)$$

$$\mathbf{f}_c^\tau = f_{\text{Compress}}(\mathbf{f}_a^\tau) \quad (19)$$

$$\mathbf{f}_{aw_1}^\tau = \mathbf{f}_{a_1}^\tau \cdot \text{softmax}(\mathbf{f}_c^\tau) \quad (20)$$

$$\mathbf{f}_{aw_2}^\tau = \mathbf{f}_{a_2}^\tau \cdot \text{softmax}(\mathbf{f}_c^\tau) \quad (21)$$

式中,Maxpool1D表示最大池化。 softmax 表示归一化指数函数。

接着, $\mathbf{f}_{aw_1}^\tau$ 和 $\mathbf{f}_{aw_2}^\tau$ 进入多层感知机调整维度后,与 $\tilde{\mathbf{P}}'_i$ 经过第2个多层感知机学习到的特征 $\mathbf{f}_{u_2}^\tau$ 进行特征融合,得到增强后的特征 $\mathbf{f}_e^\tau$ 。

1.2.4 阶段2的解码器模块

阶段2解码器的作用主要是将经过特征增强模块增强的特征 $\mathbf{f}_e^\tau$ 解码为一个位移向量。 $\mathbf{f}_e^\tau$ 首先会经过一个特征解码层,该部分由多层感知机组成,经过特征解码得到的特征通过另一个多层感知机生成粗点位移 $\mathbf{d}_c$,该粗点位移进入由一系列一维卷积层、激活函数等组成细化模块,生成精细的位移。将粗点位移与精细位移拼接,得到解码位移 $\mathbf{d}_f$ 。 $\mathbf{d}_f$ 输入归一化指数函数层进行权重计算, τ 个特征增强模块中输出的 $\mathbf{d}_p^\tau$ 同样也输入归一化指数函数层进行权重计算,最终将 $\mathbf{d}_p^\tau$ 与 $\mathbf{d}_f$ 按照权重相加和,得到最终解码位移 $\hat{\mathbf{d}}_i$,用来指引点云去噪。

1.2.5 损失函数

损失函数量化了模型在训练数据上的表现,为模型优化提供了指导。通过最小化损失函数,模型可以不断学习并提高性能。

本文选择模型预测的位移 $\hat{\mathbf{d}}_i$,干净点云数据与噪声点云数据之间的真实位移 $\mathbf{d}_i$,进行损失函数 L 的设计,具体为

$$w_i = \frac{\exp\left(-\frac{\|\mathbf{p}_i - \mathbf{s}_j\|^2}{\max(\|\mathbf{p}_i - \mathbf{s}_j\|^2)/9}\right)}{\sum_{i=1}^N \exp\left(-\frac{\|\mathbf{p}_i - \mathbf{s}_j\|^2}{\max(\|\mathbf{p}_i - \mathbf{s}_j\|^2)/9}\right)} \quad (22)$$

$$L = \sum_{i=1}^N w_i \cdot \|\hat{\mathbf{d}}_i - \mathbf{d}_i\|^2 \quad (23)$$

式中, w_i 是第 i 个噪声点的权重, $\mathbf{p}_i$ 是第 i 个噪声点, $\mathbf{s}_j$ 是第 j 个种子点, $\max(\|\mathbf{p}_i - \mathbf{s}_j\|^2)$ 是求变量的最大距离平方, $\|\hat{\mathbf{d}}_i - \mathbf{d}_i\|^2$ 是求两者的距离平方。 $\exp$ 为指数函数。

该损失函数用来衡量预测的点位移和真实点位移之间的差距,在计算中,会赋予距离种子点较近的点以更大的权重,提升模型的学习效果。

2 实验及结果

2.1 数据集及实验设置

本文遵循基于深度学习的点云去噪经典实验方法设计,如 IterativePFN(de Silva Edirimuni 等, 2023) 和 ScoreDenoise(Luo 和 Hu, 2021), 本文选择 PUNet(point cloud upsampling network)(Yu 等, 2018b)数据集,该数据集利用泊松圆盘采样对40个网格数据进行采样,分辨率分别为10 K、30 K和50 K,生成了120个点云数据作为训练集中的干净点云,随后在每个点云中添加标准差为边界球体半径的0.5%~2%的高斯噪声作为训练集中的噪声点云。接着利用相同的方法对另外20个网格数据进行采样,生成10 K和50 K分辨率的点云数据,随后在这40个点云中添加标准差为边界球体半径的1%、3%和6%的高斯噪声,这120个噪声点云便作为测试集。为进一步对比不同数据集的实验效果,本文选择了合成数据集 PCNet(point clean network)(Rakotosaona 等,

2020)数据集,与PUNet数据集一样,添加了同等程度的噪声进行测试实验。此外,为对比模型扫描数据集上的实验效果,本文选择了 Kinect_v1 (Wang 等,2016)数据集,Kinect_v1 包含 71 个由微软 Kinect v1 相机扫描的模型的点云数据进行测试实验。

实验选择倒角距离(chamfer distance, CD) (Fan 等,2017)和点到网格距离(point to mesh distance, P2M) (Li 等,2021)作为评估方法。

本文提出的双阶段双分支点云去噪模型在 NVIDIA A100 GPUs 上使用 PyTorch 1.11.0 和 CUDA 11.3 进行训练,所有对比实验方法在 NVIDIA GeForce RTX 3090 GPU 上进行测试确保实

验结果公平合理。

2.2 PUNet和PCNet数据集测试结果

选择 Pointfilter (Zhang 等,2021a)、ScoreDenoise (Luo 和 Hu, 2021)、PDFlow (Mao 等,2022)、MAG (momentum ascent in gradient fields, MAG) (Zhao 等,2023)、IterativePFN (de Silva Edirimuni 等,2023)和 PathNet (Wei 等,2024)6种基于深度学习的点云去噪方法与双阶段双分支点云去噪模型进行对比实验。表1和表2展示了PUNet和PCNet数据集上的测试结果。图2和图3展示了PUNet数据集上的部分去噪结果可视化,点云数据分辨率为50 K,噪声程度分别为3%和6%。

表 1 PUNet数据集上的去噪结果(CD和P2M的数值乘 10 ⁵)												
Table 1 Denoising results on the PUNet dataset(CD and P2M distances are multiplied by 10 ⁵)												
方法	10 K 分辨率						50 K 分辨率					
	1% 噪声		3% 噪声		6% 噪声		1% 噪声		3% 噪声		6% 噪声	
	CD	P2M	CD	P2M	CD	P2M	CD	P2M	CD	P2M	CD	P2M
Pointfilter	33.45	14.07	93.20	60.49	<u>188.56</u>	<u>139.26</u>	7.13	3.84	16.32	10.98	34.20	26.26
ScoreDenoise	25.22	4.68	55.85	25.22	264.03	211.09	7.16	1.51	30.91	20.29	<u>199.17</u>	176.39
PDFlow	21.32	11.05	51.90	29.00	290.58	243.18	6.50	4.16	38.98	32.34	294.52	274.48
MAG	25.71	5.08	53.54	23.41	247.70	195.82	7.23	1.58	30.07	19.54	199.25	176.21
IterativePFN	20.55	<u>2.18</u>	<u>42.41</u>	<u>13.76</u>	246.04	183.01	<u>6.05</u>	<u>0.59</u>	19.71	<u>10.12</u>	221.25	184.21
PathNet	26.72	8.73	49.28	22.43	172.77	130.51	7.16	3.74	41.59	32.08	228.98	210.04
本文	<u>20.92</u>	2.02	40.64	12.10	224.52	165.23	5.98	0.49	<u>16.58</u>	8.15	206.84	<u>173.48</u>

注:加粗、下划线字体分别表示各列最优、次优结果。

如表1所示,双阶段双分支点云去噪模型在PUNet数据集上取得6个最佳值、3个次佳值,综合达到最佳。在10 K分辨率添加3%的噪声、50 K分辨率添加1%的噪声、50 K分辨率添加3%的噪声条件下,双阶段双分支点云去噪模型的去噪效果达到最佳。在10 K分辨率添加1%的噪声条件下,双阶段双分支点云去噪模型与IterativePFN去噪效果相当,均优于其他算法。在10 K分辨率添加6%的噪声条件下,双阶段双分支点云去噪模型的去噪效果在Pointfilter和PathNet之后。在50 K分辨率添加6%的噪声条件下,双阶段双分支点云去噪模型在P2M指标上达到次佳。PathNet在10 K分辨率添加6%的噪声时达到最佳,Pointfilter在50 K分辨率添加6%的噪声时达到最佳,但它们在10 K分

辨率添加1%的噪声、10 K分辨率添加3%的噪声、50 K分辨率添加1%的噪声条件下的去噪效果均较差。

如表2所示,双阶段双分支点云去噪模型在PCNet数据集上取得7个最佳值、3个次佳值,综合达到最佳。在10 K分辨率添加1%的噪声、50 K分辨率添加3%的噪声条件下,双阶段双分支点云去噪模型的去噪效果达到最佳。在10 K分辨率添加3%的噪声、50 K分辨率添加1%的噪声条件下,双阶段双分支点云去噪模型与IterativePFN去噪效果相当,均优于其他算法。在10 K分辨率添加6%的噪声条件下,双阶段双分支点云去噪模型在P2M指标上达到最佳。在50 K分辨率添加6%的噪声条件下,双阶段双分支点云去噪模型在P2M指标上达到

表2 PCNet数据集上的去噪结果(CD和P2M的数值乘10⁵)
Table 2 Denoising results on the PCNet dataset (CD and P2M distances are multiplied by 10⁵)

方法	10 K分辨率						50 K分辨率					
	1%噪声		3%噪声		6%噪声		1%噪声		3%噪声		6%噪声	
	CD	P2M	CD	P2M	CD	P2M	CD	P2M	CD	P2M	CD	P2M
Pointfilter	74.80	56.63	137.7	103.57	<u>232.10</u>	181.46	11.25	6.10	<u>24.27</u>	18.17	56.49	46.00
ScoreDenoise	33.73	12.65	72.29	27.98	269.64	151.63	10.67	3.13	35.58	15.51	195.39	117.99
PDFlow	32.45	11.05	66.16	37.68	290.27	241.45	9.68	4.67	42.76	34.24	267.75	249.12
MAG	34.13	17.40	70.31	39.85	255.16	206.91	10.67	5.31	34.79	25.53	<u>192.97</u>	175.39
IterativePFN	<u>26.20</u>	<u>6.99</u>	60.23	<u>15.52</u>	254.84	<u>120.64</u>	9.12	<u>1.39</u>	25.49	<u>7.11</u>	209.01	102.99
PathNet	31.36	17.23	65.23	35.75	170.10	128.46	9.91	4.44	41.72	31.67	206.86	189.08
本文	25.74	6.16	<u>61.23</u>	14.99	235.62	110.30	<u>9.27</u>	1.16	23.58	5.74	193.67	<u>95.84</u>

注:加粗、下划线字体分别表示各列最优、次优结果。




图2 PUNet数据集上50 K分辨率并添加3%的噪声不同算法去噪结果可视化

Fig. 2 Visualization of denoising results of different algorithms on the PUNet dataset at 50 K resolution with 3% noise
((a) noisy point clouds; (b) ScoreDenoise; (c) PDFlow; (d) IterativePFN; (e) ours; (f) clean point clouds)

次佳。Pointfilter在50 K分辨率添加6%的噪声条件下达到最优,但在10 K分辨率添加1%的噪声、10 K分辨率添加3%的噪声、50 K分辨率添加1%的噪声条件下,表现均较差。

双阶段双分支模型在不同数据集上综合去噪性能达到最优。如图3所示,在高噪声条件下其性能下降,是由于点云几何细节被严重破坏,导致基于邻

域的特征学习效果变差。

2.3 Paris-rue-Madame数据集去噪结果

Paris-rue-Madame(Serna等,2014)是真实场景的扫描数据集,本文对比了ScoreDenoise、Iterative-PFN和双阶段双分支点云去噪模型在该数据集上的去噪效果,如图4所示,图中蓝色框选区被放大显示。通过浅蓝色框选区放大对比发现,IterativePFN




图3 PUNet数据集上50 K分辨率并添加6%的噪声不同算法去噪结果可视化

Fig. 3 Visualization of denoising results of different algorithms on the PUNet dataset at 50 K resolution with 6% noise

((a) noisy point clouds; (b) ScoreDenoise; (c) PDFlow; (d) IterativePFN; (e) ours; (f) clean point clouds)




图4 Paris-rue-Madame数据集去噪结果对比

Fig. 4 Visualization of test results on the Paris-rue-Madame dataset

((a) noisy point clouds; (b) ScoreDenoise; (c) IterativePFN; (d) ours)

在边缘处理上效果最好, 双阶段双分支模型次之, ScoreDenoise在边缘处理上效果最差。通过深蓝色框选区放大的细节(绿色框选区)对比发现, 去噪前的点云空隙较小, IterativePFN去噪后空隙变大, 而双阶段双分支模型更好地维持了原有细节, ScoreDenoise的去噪效果最差。

2.4 Kinect_v1数据集测试结果

本文选择了模型扫描 Kinect_v1 数据集测试 Pointfilter、ScoreDenoise、PDFlow、MAG、IterativePFN、PathNet算法和双阶段双分支点云去噪模型的性能, 测试结果如表3所示。可以看出, 双阶段双分支模型在两种性能评估下皆取得次佳值, 综合达到最优。

表3 Kinect_v1数据集上的去噪结果

Table 3 Denoising results on the Kinect_v1 dataset

方法	CD/ 10^5	P2M/ 10^5
Pointfilter	12.63	7.88
ScoreDenoise	13.21	6.52
PDFlow	13.32	8.68
MAG	13.56	8.42
IterativePFN	13.20	6.85
PathNet	13.24	8.40
本文	<u>13.18</u>	<u>6.79</u>

注:加粗、下划线字体分别表示各列最优、次优结果。

2.5 消融实验

本文为进一步探索双阶段双分支点云去噪模型的双阶段特征提取过程设计和双分支编码器设计是否能够有效提升去噪效果,特进行消融实验,选择PUNet数据集不同分辨率的噪声点云进行实验,实验中添加的噪声为标准差为边界球体半径的1%的

高斯噪声。

如表4所示,双阶段双分支点云去噪模型在测试中取得3个最佳值、1个次佳值,整体去噪效果达到最佳。双阶段局部编码模型去噪效果位于第3,双阶段全局编码模型去噪效果最差,但经过两个不同分支的编码器进行特征提取并融合,获得了更为精确的点云特征,提升了模型的去噪性能。

如表4所示,单阶段双分支点云去噪模型取得1个最佳值、3个次佳值,对比双分支点云去噪模型取得3个最佳值,1个次佳值的表现,证明阶段2的特征细化模块进一步优化了双分支编码器提取的特征,提升了模型去噪效果。

双阶段双分支模型与单阶段双分支模型的参数量如表5所示,两个模型在PUNet数据集上的训练时间及测试时间如表6所示。单阶段模型的参数量少且时间成本低,但如表4所示,单阶段模型的去噪性能低于双阶段模型,因此在利用训练好的网络模型及参数进行非实时去噪时,牺牲时间成本达到更好的去噪效果是有意义的。

表4 PUNet数据集上的消融实验

Table 4 Ablation study on the PUNet dataset

方法	10 K(1%)分辨率		50 K(1%)分辨率	
	CD/ 10^5	P2M/ 10^5	CD/ 10^5	P2M/ 10^5
单阶段模型	<u>21.14</u>	2.01	<u>6.03</u>	<u>0.55</u>
仅全局编码	36.88	12.87	18.67	9.98
仅局部编码	21.29	2.18	6.25	0.63
完整模型	20.92	<u>2.02</u>	5.98	0.49

注:加粗、下划线字体分别表示各列最优、次优结果。

表5 单阶段模型与双阶段模型参数量对比

Table 5 The comparison of parameter count between one-stage model and two-stage model

方法	参数量/M
单阶段模型	9.2
双阶段模型	28.5

表6 单阶段模型与双阶段模型在PUNet数据集上的训练时间和测试时间对比

Table 6 The comparison of training and testing time between one-stage model and two-stage model on PUNet dataset

方法	训练时间	测试时间(10K)
单阶段模型	41 h 40 min	44 s
双阶段模型	66 h 40 min	1 min 10 s

3 结 论

本文提出的双阶段双分支模型的三维点云去噪方法在阶段1利用双分支编码器综合提取并融合了

点云块局部特征和全局特征,获得了较全面的信息;在阶段2利用特征增强模块使得点云潜在表征更加接近底层干净表面,从而能够利用解码位移最大限

度引导点云去噪。实验及结果分析中,如表1—表3所示,本文方法在PUNet、PCNet和Kinect_v1数据集上皆取得最佳去噪效果,如表4所示,证明特征融合模块和特征增强模块的设计起到了关键作用。又如表1和表2所示,Pointfilter虽然在高分辨率高噪声下取得最佳效果,但其在低噪声时去噪效果最差;IterativePFN在低噪声时取得仅次于本文方法的效果,但其在高噪声时去噪效果不佳;而本文方法在针对高噪声的点云数据进行去噪时性能会下降,这是由于点云的局部细节被严重破坏,使得基于邻域关系的特征学习变得困难。为此,下一步实验拟通过不同程度噪声路径选择训练及提取更加鲁棒的特征解决该问题。

参考文献(References)

- 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]
- de Silva Edirimuni D, Lu X, Shao Z, 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]
- Digne J. 2012. Similarity based filtering of point clouds//Proceedings of 2012 IEEE Computer Society Conference on Computer Vision and Pattern Recognition Workshops. Providence, USA: IEEE: 73-79 [DOI: 10.1109/CVPRW.2012.6238917]
- Digne J, Chaine R and Valette S. 2014. Self-similarity for accurate compression of point sampled surfaces. Computer Graphics Forum, 33(2): 155-164 [DOI: 10.1111/cgf.12305]
- Digne J and De Franchis C. 2017. The bilateral filter for point clouds. Image Processing on Line, 7: 278-287 [DOI: 10.5201/ipol.2017.179]
- Digne J, Valette S and Chaine R. 2018. Sparse geometric representation through local shape probing. IEEE Transactions on Visualization and Computer Graphics, 24(7): 2238-2250 [DOI: 10.1109/TVCG.2017.2719024]
- 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]
- Fleishman S, Drori I and Cohen-Or D. 2003. Bilateral mesh denoising//Proceedings of the ACM SIGGRAPH 2003 Papers. San Diego, USA: ACM: 950-953 [DOI: 10.1145/1201775.882368]
- 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]
- Han X F, Jin J S, Wang M J and Jiang W. 2018a. Guided 3D point cloud filtering. Multimedia Tools and Applications, 77(13): 17397-17411 [DOI: 10.1007/s11042-017-5310-9]
- Han X F, Jin J S, Wang M J and Jiang W. 2018b. Iterative guidance normal filter for point cloud. Multimedia Tools and Applications, 77(13): 16887-16902 [DOI: 10.1007/s11042-017-5258-9]
- Leal E, Sanchez-Torres G and Branch J W. 2020. Sparse regularization-based approach for point cloud denoising and sharp features enhancement. Sensors, 20(11): #3206 [DOI: 10.3390/s20113206]
- 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]
- 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 on Computer Vision. 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]
- Qi C R, Su H, Mo K C and Guibas L J. 2017a. PointNet: deep learning on point sets for 3D classification and segmentation//Proceedings of 2017 IEEE Conference on Computer Vision and Pattern Recognition. Honolulu, USA: IEEE: 77-85 [DOI: 10.1109/cvpr.2017.16]
- Qi C R, Yi L, Su H and Guibas L J. 2017b. PointNet++: deep hierarchical feature learning on point sets in a metric space//Proceedings of the 31st International Conference on Neural Information Processing Systems. Long Beach, USA: Curran Associates Inc.: 5105-5114
- Rakotosaona M J, La Barbera V, Guerrero P, Mitra N J 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]
- 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 3rd International Conference on Pattern Recognition Applications and Methods. Angers, France: SciTePress: 819-

- 824 [DOI: 10.5220/0004934808190824]
- Sun L J, Zeng T F, Fan J X and Wang W J. 2024. Double-view feature fusion network for LiDAR semantic segmentation. *Journal of Image and Graphics*, 29(1): 205-217 (孙刘杰, 曾腾飞, 樊景星, 王文举. 2024. 大场景双视点云特征融合语义分割方法. *中国图象图形学报*, 29(1): 205-217) [DOI: 10.11834/jig.220943]
- Wang P S, Liu Y and Tong X. 2016. Mesh denoising via cascaded normal regression. *ACM Transactions on Graphics*, 35(6): # 232 [DOI: 10.1145/2980179.2980232]
- Wang W J, Liu X, Zhou H L, Wei L, Deng Z G, Murshed M, et al. 2024. Noise4Denoise: leveraging noise for unsupervised point cloud denoising. *Computational Visual Media*, 10(4): 659-669 [DOI: 10.1007/s41095-024-0423-3]
- 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]
- Wei Z Y, Chen H H, Nan L L, Wang J, Qin J and Wei M Q. 2024. PathNet: path-selective point cloud denoising. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 46(6): 4426-4442 [DOI: 10.1109/TPAMI.2024.3355988]
- Xu Z W and Foi A. 2021. Anisotropic denoising of 3D point clouds by aggregation of multiple surface-adaptive estimates. *IEEE Transactions on Visualization and Computer Graphics*, 27(6): 2851-2868 [DOI: 10.1109/TVCG.2019.2959761]
- Yu L Q, Li X Z, Fu C W, Cohen-Or D and Heng P A. 2018a. EC-Net: an edge-aware point set consolidation network//*Proceedings of the 15th European Conference on Computer Vision*. Munich, Germany: Springer: 398-414 [DOI: 10.1007/978-3-030-01234-2_24]
- Yu L Q, Li X Z, Fu C W, Cohen-Or D and Heng P A. 2018b. 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]
- Zhang C W, Zhang X Y, Yue X H, Lao M R, Jiang T, Wang J W, et al. 2024. PD-Refiner: an underlying surface inheritance refiner with adaptive edge-aware supervision for point cloud denoising//*Proceedings of the 32nd ACM International Conference on Multimedia*. Melbourne, Australia: ACM: 3381-3390 [DOI: 10.1145/3664647.3681540]
- Zhang D B, Lu X Q, Qin H and He Y. 2021a. 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]
- Zhang S Y, Cui S G and Ding Z. 2021b. Hypergraph spectral analysis and processing in 3D point cloud. *IEEE Transactions on Image Processing*, 30: 1193-1206 [DOI: 10.1109/TIP.2020.3042088]
- Zhao Y P, Zheng H T, Wang Z R, Luo J B and Lam E Y. 2023. Point cloud denoising via momentum ascent in gradient fields//*Proceedings of 2023 IEEE International Conference on Image Processing (ICIP)*. Kuala Lumpur, Malaysia: IEEE: 161-165 [DOI: 10.1109/ICIP49359.2023.10222122]
- Zheng Q, Sharf A, Wan G W, Li Y Y, Mitra N J, Cohen-Or D, et al. 2010. Non-local scan consolidation for 3D urban scenes. *ACM Transactions on Graphics*, 29(4): #94 [DOI: 10.1145/1833351.1778831]
- Zheng Y L, Li G Q, Wu S H, Liu Y X and Gao Y F. 2017. Guided point cloud denoising via sharp feature skeletons. *The Visual Computer*, 33(6): 857-867 [DOI: 10.1007/s00371-017-1391-8]

作者简介

权思文,女,副教授,主要研究方向为三维计算机视觉。

E-mail: siwenquan@chd.edu.cn

胡忠文,通信作者,男,副教授,主要研究方向为遥感数据处理、实景三维解译、城市/海岸带遥感应用。

E-mail: zwhoo@szu.edu.cn

张淑婷,女,硕士研究生,主要研究方向为三维点云去噪。

E-mail: 2024132042@chd.edu.cn

赵河彬,男,硕士研究生,主要研究方向为三维点云去噪。

E-mail: hebinzhao@chd.edu.cn

聂子铭,男,硕士研究生,主要研究方向为三维点云上采样。

E-mail: nzm@mail.nwpu.edu.cn

杨佳琪,男,副教授,主要研究方向为三维计算机视觉。

E-mail: jqyang@nwpu.edu.cn