

MSPoint: 基于多尺度分布分数的点云去噪网络

胡豪^{1*}, 王琪冰¹, 陆佳炜¹, 苏宏业², 来见坤³, 肖刚^{1**}

¹中国计量大学机电工程学院, 浙江 杭州 310018;

²浙江大学控制科学与工程学院, 浙江 杭州 310027;

³浙江新再灵科技股份有限公司, 浙江 杭州 310051

摘要 激光扫描仪等设备直接收集到的原始点云通常会受到噪声的影响, 这会影响后续的处理, 如三维重建、语义分割等, 因此点云去噪算法尤为重要。现有的点云去噪网络大多以噪声点与干净点的距离作为目标函数进行迭代训练, 这可能导致点云聚集与异常值。针对以上问题, 提出一种基于多尺度点云分布分数(即点云对数概率函数的梯度)的新型去噪网络 multiscale score point(MSPoint)。MSPoint 网络主要由两部分组成: 特征提取模块和位移预测模块。在特征提取模块中输入点云的邻域, 通过对数据添加多尺度噪声扰动加强 MSPoint 的抗噪性能, 使提取到的特征具有更强的表达能力。位移预测模块根据分数估计单元预测的分数迭代学习噪声点的位移。在公开数据集上的实验结果表明, 相比现有的方法, MSPoint 有着更好的去噪效果以及更强的鲁棒性。

关键词 机器视觉; 点云去噪; 深度学习; 点云分布; 多尺度扰动

中图分类号 TP391 文献标志码 A

DOI: 10.3788/LOP222402

MSPoint: Point Cloud Denoising Network Based on Multiscale Distribution Score

Hu Hao^{1*}, Wang Qibing¹, Lu Jiawei¹, Su Hongye², Lai Jiankun³, Xiao Gang^{1**}

¹College of Mechanical and Electrical Engineering, China Jiliang University, Hangzhou 310018, Zhejiang, China;

²College of Control Science and Engineering, Zhejiang University, Hangzhou 310027, Zhejiang, China;

³Zhejiang Xin Zailing Technology Co., Ltd., Hangzhou 310051, Zhejiang, China

Abstract The original point cloud obtained directly by equipment such as laser scanners is usually affected by noise, which will affect subsequent processing, such as three-dimensional reconstruction and semantic segmentation; as a result, the point cloud denoising algorithm becomes particularly crucial. The majority of currently available point cloud denoising networks use the distance between noise and clean points as the objective function during iterative training, which may cause point cloud aggravation and outliers. To address the above issues, a new denoising network called multiscale score point (MSPoint) based on multiscale point cloud distribution fraction (i. e., the gradient of point-cloud logarithmic probability function) is proposed. The displacement prediction and feature extraction modules make up the majority of the MSPoint network. Input the neighborhood of the point cloud in the feature extraction module and strengthen the antinoise performance of MSPoint by adding multiscale noise disturbance to the data, thereby leading the extracted features to have a stronger expression ability. According to the fraction predicted by the fraction estimation unit, the displacement prediction module iteratively learns the displacement of noise points. MSPoint provides stronger robustness than previous approaches and a superior denoising impact, according to experimental results on public datasets.

Key words machine vision; point cloud denoising; deep learning; point cloud distribution; multiscale disturbance

1 引言

随着科技的发展, 通过激光扫描仪以及无人机倾斜摄影等方法能直接获得被检测物的三维点云, 点云

数据因而受到越来越多科研人员关注, 逐渐成为计算机视觉领域重要的三维数据表示形式^[1]。点云由从连续表面不规则采样的离散三维点组成, 被广泛应用于几何处理、自动驾驶、模型三维重建等领域^[2-7]。同时

收稿日期: 2022-08-29; 修回日期: 2022-09-19; 录用日期: 2022-10-13; 网络首发日期: 2022-10-23

基金项目: 浙江省重点研发计划(2021C03136)

通信作者: *huhao0127@yeah.net; **xg@zjut.edu.cn

点云的质量易受环境、经验、光线等因素的影响,激光扫描仪或倾斜摄影等设备直接生成的点云不可避免地具有噪声。点云中的噪声会显著影响下游的任务,比如渲染、三维重建和语义分割等。因此,为了有效地利用三维点云数据,需要进行高效的点云去噪处理。

传统的去噪方法主要有双边滤波、高斯滤波去噪、主成分分析法去噪、法线方向平滑、曲面拟合去噪等,后续又出现了许多基于传统方法改进的方法。林洪彬等^[8]根据邻域点在切平面的投影提出一种基于各向高斯核的散乱点云去噪方法。卢钰仁等^[9]针对双边滤波需要法线这一特点,对点云进行法向修正之后再行滤波处理。杨鹏等^[10]用最小二乘法求解维度密度的拟合曲线,随后根据标准阈值原则提取各维度点集的交集。李鹏飞等^[11]提出噪声尺度分类去噪方法,使用快速双边滤波平滑小尺度噪声。柳赞等^[12]提出基于主成分分析与曲面拟合进行点云去噪的方法。尽管近年来对传统方法的改进取得了长足进展,但是以上方法很大程度上依赖于点云拟合的曲线或者曲面形状,没有对点云的尖锐特征进行保留,难以在噪声点云的细节保持和去噪效果之间取得平衡^[13]。

深度学习技术的高速发展,为点云处理提供了许多新的研究思路。与二维图像不同,点云数据具有无序性、非结构性、分布不均匀以及数据量大等特点,这使得基于深度学习的图像去噪方法难以直接应用到点云去噪领域,如何从杂乱的点云中学习特征是一个具有挑战的问题。早期,为了解决点云无序性导致的特征学习困难问题,许多学者都致力于将三维点云数据转化为规则化的结构表示,例如多视图投影、三角化和体素化等^[14-15]。尽管这些方法取得了不错的效果,但是依然存在信息丢失、计算复杂等问题。

Charles 等^[16-17]提出基于深度学习的 PointNet 以及 PointNet++,这是以原始点云作为输入进行学习的开创性成果。随着 PointNet 的出现,直接应用在原始点云上的神经网络架构开始兴起^[18],基于深度学习的点云去噪方法应用得越来越广泛^[19-20],且性能大部分

优于传统方法。Rakotosaona 等^[21]提出 PointCleanNet 点云去噪网络,将去噪任务分解为移除离群点和学习偏移量两个子任务,并通过实验证明其去噪效果优于传统方法。Zhang 等^[22]提出一种由编码器和解码器组成的网络 Pointfilter 来过滤点云,根据点云相邻结构将每个噪声点投影到基础表面上,预测噪声点云的位移向量来将噪声点推回原始模型表面的位置。Casajus 等^[23]首次提出基于无监督学习的点云去噪网络,借鉴 Noise2Noise^[24]的思想去除当前点并根据邻域点云进行学习来预测干净点的值,并通过引入先验项来改变点的采样模式。以上大多数方法都以噪声点与无噪声点的最近距离作为神经网络迭代训练的目标函数,然后预测噪声点的位移,并将逆位移作用于噪声点云完成去噪。但是这类网络的训练过程仅仅孤立地考虑噪声点与干净点之间的距离关系,对位移的估计并不准确,去噪之后的点云存在着异常值、收缩以及聚集等问题^[25]。

针对以上问题,本文提出一种基于点云分数的去噪网络 multiscale score point(MSPoint)。在 MSPoint 中,加入多尺度的噪声扰动来为点云特征的提取制造障碍,强迫网络学习更深层次、更具有表达能力的特征。同时,通过噪声点云分布的梯度来引导网络预测的方向,并不只是考虑每个点的位置,还覆盖点的邻域。最后,提出一种基于点云分布分数加权的损失函数,该损失函数充分考虑局部邻域点云分布的梯度方向,从而在整体的趋势上引导网络的训练过程。实验结果表明,针对不同噪声程度、不同特征的噪声点云模型,MSPoint 都表现出优良的去噪效果,能够很好地保留点云的尖锐特征,具有良好的鲁棒性与泛化能力。

2 MSPoint 网络结构

所提 MSPoint 网络总体结构如图 1 所示,主要分为两个部分:特征提取模块和位移预测模块。特征提取模块首先对输入噪声点云的邻域进行预处理,经过多尺度噪声扰动来加强网络的抗噪性能,使提取到的

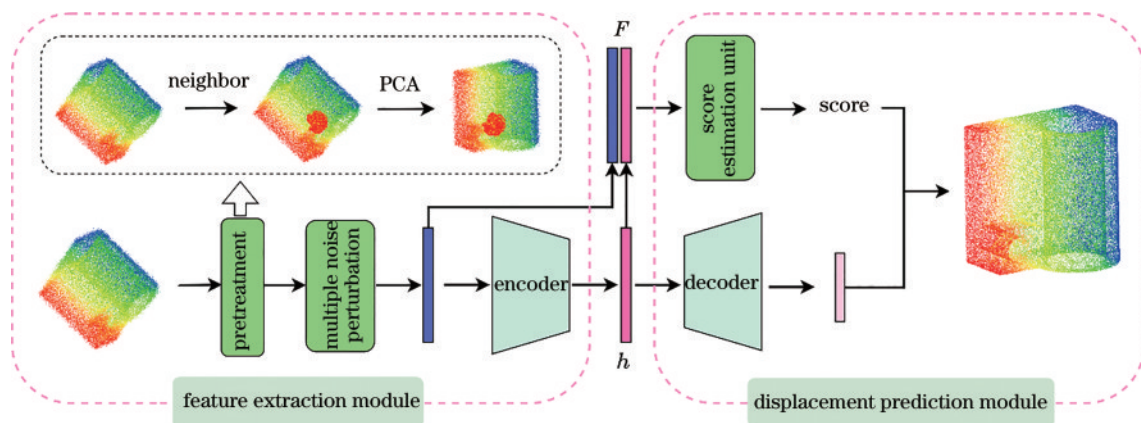


图 1 网络总体结构

Fig. 1 Overall network structure

特征具有更强的表达能力。位移估计模块通过 decoder 来预测噪声点的位移,根据分数估计单元预测的分数来迭代学习,完成去噪过程。

2.1 特征提取模块

对点云添加合适的噪声能够使得提取到的特征不易受到干扰,具有更强的泛化能力、鲁棒性以及抗噪能力^[26]。因此,MSPoint 使用带有噪声干扰的特征提取模块,其结构如图 2 所示。输入采样后维度为

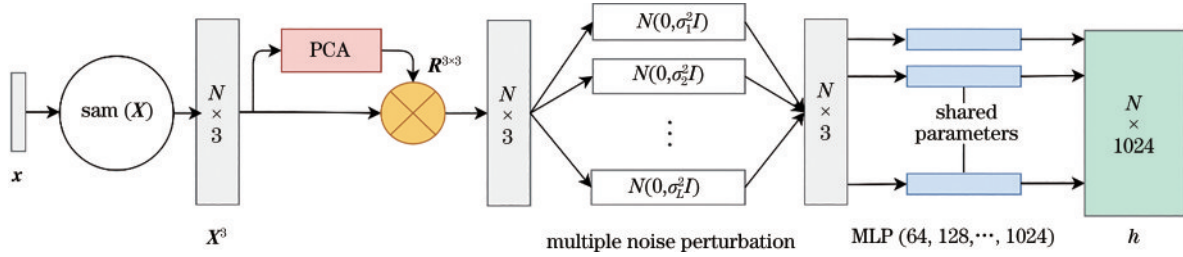


图 2 特征提取模块

Fig. 2 Feature extraction module

特征提取模块旨在从噪声点云 $\mathbf{X} = \{\mathbf{x}_i\}_{i=1}^M$ 中学习点的特征,点云的去噪问题被视为一个局部问题,任意噪声点 \mathbf{x}_i 的去噪结果源于该点的局部邻域 $\tilde{\mathbf{X}}$, $\tilde{\mathbf{X}}$ 与 \mathbf{x}_i 的欧氏距离不超过邻域半径 r 。以上规则实际上限定了一个以 \mathbf{x}_i 为球心以 r 为半径的点云球体,调节 r 的大小,可以决定去噪效果更依赖局部信息还是全局信息。为了减小计算量以及有效地调整网络中的参数,应该保证每个邻域中的点云数量一致。式(1)中,对 $\tilde{\mathbf{X}}$ 进行 $\text{sam}(\cdot)$ 采样得到 \mathbf{X} 。设定邻域点云的数量为 N :当邻域中点云的数量大于 N 时,则进行下采样操作,随机抽取邻域中 N 个点作为网络输入;当邻域中的点云数量小于 N 时,则进行上采样操作,填充原点 \mathbf{x}_i ,使得点云数量为 N 。

$$\begin{cases} \mathbf{X} = \text{sam}(\tilde{\mathbf{X}}) \\ \tilde{\mathbf{X}} = \{\mathbf{x}, \|\mathbf{x} - \mathbf{x}_i\| < r\}_{i=1}^M, \mathbf{x} \in \mathbf{X} \end{cases} \quad (1)$$

$$\mathbf{C} = \begin{bmatrix} \sum (a_i - \bar{a})^2 & \sum (a_i - \bar{a})(b_i - \bar{b}) & \sum (a_i - \bar{a})(c_i - \bar{c}) \\ \sum (b_i - \bar{b})(a_i - \bar{a}) & \sum (b_i - \bar{b})^2 & \sum (b_i - \bar{b})(c_i - \bar{c}) \\ \sum (c_i - \bar{c})(a_i - \bar{a}) & \sum (c_i - \bar{c})(b_i - \bar{b}) & \sum (c_i - \bar{c})^2 \end{bmatrix}. \quad (2)$$

对 \mathbf{C} 进行奇异值分解(SVD)计算出特征向量 \mathbf{v}_1 、 \mathbf{v}_2 以及 \mathbf{v}_3 ,这 3 个特征向量相互正交,且为投影方差最大的 3 个方向。特征向量按特征值从大到小组成旋转矩阵 \mathbf{R} ,使得不同旋转角度的点云对齐到一个方向,实现网络的旋转不变性。

$$\mathbf{R} = [\mathbf{v}_1, \mathbf{v}_2, \mathbf{v}_3]. \quad (3)$$

在对点云添加扰动时,更大的噪声可以给网络的学习过程添加阻碍,使得特征更具有表现能力,但是也可能使得处理之后的点云偏离原始分布,使提取的特征不准确。更小的噪声虽然不会对数据造成破坏性影

$N \times 3$ 的点云邻域, N 表示邻域点云数量、3 表示点云的 3 个维度。使用由主成分分析法(PCA)计算的旋转矩阵 \mathbf{R} 进行点云对齐,使用多尺度的噪声来对点云进行处理,通过加入若干个隐藏层来克服线性模式的限制,经过多层感知机(MLP)将数据映射到不同维度帮助网络提取点云特征,经过卷积最终获取点云的全局特征。

对于点云数据而言,对同一组点云进行旋转操作,所有的点的坐标都会发生变化,但是代表的还是同一组点云。而神经网络输入的数据为矩阵形式,如果输入同一组但是旋转不同角度的点云,网络可能识别为两组不同的点云,从而对网络的去噪性能造成影响。因此对点云进行处理,网络需要保证旋转不变性。旋转不变性是指通过旋转点云使每个点坐标发生变化,但是网络仍然能够识别为同一组点云。网络采用 PCA 来对点云进行对齐操作,保证旋转不变性。

PCA 可以根据点云方差的大小来计算出相互正交的方向,以上方向也叫作主方向。输入点云在某个基上的投影方差越大,该基保留的信息也就越多,信息量保存能力最大的基向量一定是协方差矩阵的特征向量。对 \mathbf{X} 内的每个点 \mathbf{x}_i 的坐标 (a_i, b_i, c_i) 求均值 $(\bar{a}, \bar{b}, \bar{c})$,可得到协方差矩阵 \mathbf{C} :

响,但是对性能的提升不明显。为了达到最佳效果,使用多尺度且均值为 0 的各向同性高斯噪声来干扰数据。假设有 L 个扰动信号,设置 L 为 100,高斯噪声的标准差从小到大为 $\sigma_1 < \sigma_2 < \dots < \sigma_L$,由 $\sigma_1 = 0$ 开始以等差数列上升到 $\sigma_L = \sigma$,分别使用每个扰动信号对数据进行处理,网络输出为不同噪声尺度处理的加权结果:

$$\begin{cases} \hat{\mathbf{x}} = \sum_{i=1}^L \lambda(i) f(\mathbf{x}_{\sigma_i}) \\ \mathbf{x}_{\sigma_i} \sim \mathbf{x} + N(0, \sigma_i^2 I) \end{cases}, \quad (4)$$

式中 \mathbf{x}_{σ_i} 表示对点云 \mathbf{x} 添加均值为 σ_i 的高斯噪声; $f(\cdot)$

表示训练完成的网络; \hat{x} 为输出去噪结果; $\lambda(\cdot)$ 表示权重且 $\lambda(i) = \sigma_i^2$ 。

2.2 位移预测模块

将无噪声点云 $Y = \{y_i\}_{i=1}^M$ 视为一组来自二维流形支持的三维分布 p 的样本 $p(y)$, 当 y 正好在二维流形上时, $p(y) \rightarrow \infty$ 。假设噪声遵循分布 n , 则噪声点云可以表示为 $X = \{x_i = y_i + n_i\}_{i=1}^M$, 其中, n_i 是噪声分布 n 中的分量。所提位移预测网络如图 3 所示, 进行位移预

测之前由分数估计单元学习噪声点云分布来预测逐点的分数 $S(x)$, 模块经过最大池化(maxpooling)来聚合每个点的特征, 然后经过 3 个全连接层(FNN)回归噪声点的预测位移 \hat{n} , 全连接层均采用 batch normalization 正则化和 ReLU 激活函数, 最后一层仅使用 tanh 激活函数来约束 \hat{n} , 得到预测点 \hat{x} , 根据分数估计单元预测的分数 $S(x)$ 迭代学习使 \hat{x} 接近无噪声点 y 达到点云去噪的效果:

$$\{x_i + \hat{n}_i\}_{i=1}^M = \{\hat{x}_i\}_{i=1}^M \rightarrow \{y_i\}_{i=1}^M. \quad (5)$$




图 3 位移预测模块

Fig. 3 Displacement prediction module

噪声点云 X 的概率密度函数 $q(x)$ 可以视为分布 p 与分布 n 之间的卷积 $(p*n)(x)$,

$$q(x) = (p*n)(x) = \int p(y)n(x-y)dy. \quad (6)$$

同时对两边求导, 当 n 为 0 时, 来自无噪声分布 p 的无噪声点云 Y 恰好位于 q , 如图 4 所示, 噪声点云分布 $(p*n)(x)$ 在无噪声流形上达到最大值, 因此 $(p*n)(x)$ 可以衡量点云的受噪声干扰程度。当 $(p*n)(x)$ 达到最大值时噪声点最接近干净表面, 即 $\nabla_x \log[(p*n)(x)]$ 为 0 时, 点 x 恰好位于干净表面。分数估计单元通过学习噪声点云 $X = \{x_i\}_{i=1}^M$ 的分布来预测 $\nabla_x \log[(p*n)(x)]$ 得到输入点的分数 $S(x)$, 该分数在局部基础上体现点云去噪的方向, 当分数 $S(x)$ 趋近于 0 时, 去噪效果达到最佳, 通过作用于损失函数引导噪声点位移预测的迭代过程。




图 4 分数与去噪效果的关系

Fig. 4 Relation between score and denoising effect

一般情况下, 卷积神经网络通过堆叠卷积层与下采样层, 提取更为丰富的图像信息, 但是当卷积层叠加到一定深度时, 就可能会出现梯度消失和梯度爆炸等问题, ResNet 中的残差单元可以有效解决此类问题。

为了提取点云更深层次的特征、使网络收敛更快, 采用带有残差结构的分数估计单元, 如图 5 所示。分数估计单元主要由 4 个残差单元 ResBlock1、ResBlock2、ResBlock3、ResBlock4 以及最终的卷积层组成。输入由采样邻域 X 与特征 h 组成的聚合特征 F , 最终输出 x 的分数。相较于传统的 ResNet, 残差单元之后增加由输入层卷积处理的 shortcut 连接, 进一步优化梯度消失和梯度爆炸等问题。

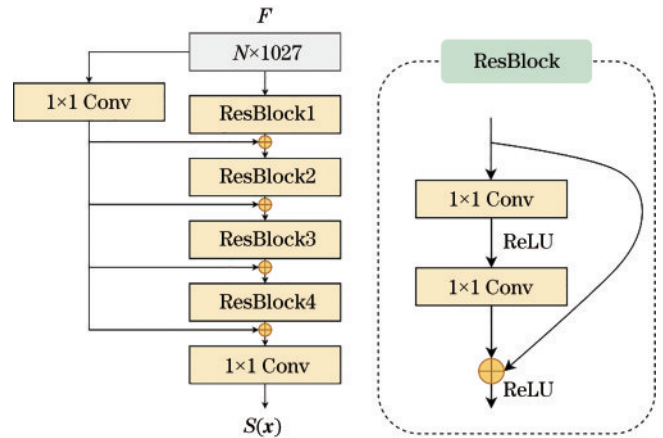


图 5 分数估计单元

Fig. 5 Score estimation unit

2.3 损失函数

分数估计单元学习的分数是噪声点云 X 对数概率函数的梯度, 该分数可以体现点云受噪声的程度, 这里使用无噪声点云 Y 定义输入点 x 的目标分数:

$$s(x) = NN(x, Y) - x, \quad x \in X, \quad (7)$$

式中: $NN(x, Y)$ 返回在 Y 中最靠近 x 的点。直观地说 $s(x)$ 相当于从 x 到干净表面的向量。分数估计单元的

目标函数将预测的分数 $S_i(\mathbf{x})$ 与定义的目标分数 $s(\mathbf{x})$ 对齐,

$$\mathcal{L}^{(i)} = E_{\mathbf{x} \sim N(\mathbf{x}_i)} [\|s(\mathbf{x}) - S_i(\mathbf{x})\|_2^2], \quad (8)$$

式中: $N(\mathbf{x}_i)$ 代表 \mathbf{x}_i 邻域点云的分布, 这意味着该目标函数不仅与 \mathbf{x}_i 位置上预测的分数匹配, 还和 \mathbf{x}_i 的相邻区域上的分数相匹配; E 表示期望。在此基础上预测的点 \mathbf{x}_i 的分数 $S_i(\mathbf{x})$ 覆盖整个邻域, 而不是孤立地考虑单个点的信息。

为了增强鲁棒性并减小偏差, 使用集成分数函数来构建局部邻域分数函数 $\epsilon_i(\mathbf{x})$:

$$\epsilon_i(\mathbf{x}) = \frac{1}{N} \sum_{j=1}^N S_j(\mathbf{x}), \quad \mathbf{x} \in X_i. \quad (9)$$

算法最终预测作用于噪声点的位移, 因此需要选择一个合适的损失函数使得噪声点云更加接近干净表面。这符合 L2 距离的特点, 因此定义 L_s 损失函数为无噪声点云中距离预测点最近的点与预测点之间的

L2 距离:

$$L_s = \|\text{NN}(\hat{\mathbf{x}}, Y) - \hat{\mathbf{x}}\|_2. \quad (10)$$

然而, L_s 损失函数只是孤立地考虑了噪声点与最近无噪声点之间的距离, 没有充分考虑点云的特征信息。单纯采用 L_s 损失函数, 去噪后的点云有着过度聚集以及异常值等现象, 如图(6)所示。为了使去噪后的点云能够逼近干净曲面, 同时保留点云的尖锐特征, 定义了一种局部邻域分数 ϵ 加权的新型损失函数 L_a , L_a 能使得去噪后的点云分布更加均匀且更贴近干净曲面, 可以从点云邻域的分布而不是仅从单个点的距离来衡量去噪效果。MSPoint 的损失函数 L_a 是对两个损失项的加权组合, 初始的时候 L_s 可以帮助网络更快收敛, 因此权值 α 初始设为 0.5, 在训练过程中逐渐衰减到 0, 使网络兼顾收敛速度与预测精度。因为局部邻域分数 ϵ 实际上预测的是点云分布的梯度, 对 ϵ 取模, 可得 L_a 为

$$L_a = \alpha L_s + (1 - \alpha) \sqrt{\epsilon_x^2 + \epsilon_y^2 + \epsilon_z^2}. \quad (11)$$

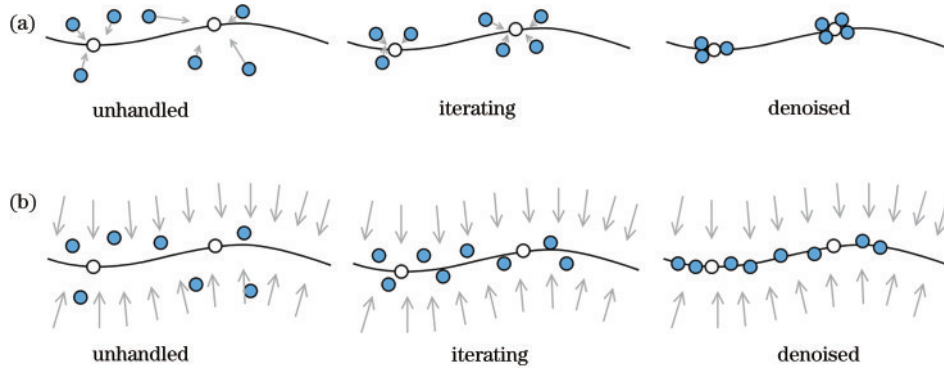


图 6 不同损失函数对点云去噪结果的影响。(a) L_s ; (b) L_a

Fig. 6 Effect of different loss functions on point cloud denoising results. (a) L_s ; (b) L_a

3 实验与分析

3.1 实验环境与数据集

实验的硬件环境为 Intel i7 12700K CPU、32 GB 内存、3080 显卡。软件环境为 Windows 10 操作系统、VS2017、CUDA10.1、CuDNN 7.5、Python3.6 以及 PyTorch 1.5.0 开发环境。

实验数据集如图 7 所示, 采用斯坦福公开点云数据集, 每个点云模型从干净表面随机采样 10 万个点生成, 作为无噪声点云数据集。通过添加均值为 0 的各向同性高斯噪声合成其相应的噪声模型, 噪声的程度由无噪声点云边界框的对角线长度来确定, 例如 0.5% 噪声表示添加标准差为 0.5% 点云边界框对角线长度的高斯噪声。

3.2 评价指标

使用 chamfer distance (D_{CD})^[27] 误差来评估 MSPoint 的去噪效果, D_{CD} 误差定义如下:

$$D_{\text{CD}}(\hat{\mathbf{X}}, \mathbf{Y}) = \frac{1}{N_1} \sum_{\hat{\mathbf{x}}_i \in \hat{\mathbf{X}}} \min_{\mathbf{y}_j \in \mathbf{Y}} (\|\hat{\mathbf{x}}_i - \mathbf{y}_j\|_2) + \frac{1}{N_2} \sum_{\mathbf{y}_j \in \mathbf{Y}} \min_{\hat{\mathbf{x}}_i \in \hat{\mathbf{X}}} (\|\mathbf{y}_j - \hat{\mathbf{x}}_i\|_2), \quad (12)$$

式中: N_1 和 N_2 分别代表无噪声点云 \mathbf{Y} 的个数以及预测点云 $\hat{\mathbf{X}}$ 的个数。 D_{CD} 误差可以很好地衡量两个点云之间的相似度, D_{CD} 误差越小代表两组点云越接近, 算法的去噪性能越好。

考虑到 D_{CD} 误差主要衡量两组点云之间最近点的距离, 不能准确衡量点云距离干净表面的程度。除了 D_{CD} 误差外, point-to-surface (P2F)^[28] 误差也被用来全面地衡量去噪效果, P2F 误差相比于 D_{CD} 误差更偏向于体现点云相对干净表面的偏移程度。

3.3 实验参数

以数据集集中的 block、blade、column 以及 joint 作为分析网络参数的实验数据。MSPoint 的输入为指定点的邻域, 点云邻域半径 r 可以控制输入点局部邻域的大小, 通过实验验证 r 对去噪效果的影响。 r 分别取




图7 点云数据集。(a) block; (b) blade; (c) column; (d) joint; (e) casting; (f) cube; (g) fandisk
Fig. 7 Point cloud dataset. (a) block; (b) blade; (c) column; (d) joint; (e) casting; (f) cube; (g) fandisk

对角线长度的2%、5%、8%以及10%，对噪声点云进行去噪并对比效果，结果如图8所示。可以看出，当 r 取2%时点云的邻域较小，几何特征不够明显，网络可能较难提取潜在特征。由图8(a)、(b)可以看出，当 r 过大时，输入点的局部邻域过大，可能有多个局部邻域的几何特征混在一起，干扰到对当前点的特征提取。

表1为使用 D_{CD} 误差作为评估标准下不同邻域半

径的去噪效果对比结果。可以看出，当 r 过小时，去噪效果较弱，当 r 过大时，去噪效果并没有随着 r 的增大呈线性增长，单点的去噪效果应该更偏向于局部信息而不是全局信息。综上所述，针对当前数据集， r 取值为对角线长度5%时综合效果最好。实际应用中，最佳邻域半径与点云结构相关，最佳邻域半径应该根据实际数据集的特点或训练效果进行选择。




图8 点云邻域提取示意图。(a) joint; (b) blade; (c) block; (d) column

Fig. 8 Schematic diagrams of point cloud neighborhood extraction. (a) joint; (b) blade; (c) block; (d) column

综上所述，网络的训练参数设置如下：输入点云邻域 r 取5%，初始学习率设置为0.001，衰减率为0.5，batch size设置为64，epoch设置为100次，采用Adam优化器优化损失函数，根据模型训练过程自适应调整学习率。

3.4 实验结果

为了验证所提算法的去噪效果，与PointClearnNet^[20]、TD^[22]以及Pointfilter^[21]等算法进行对比。采用数据集cube、casting、fandisk等3个点云模型进行对比实验，分别对原始点云添加0.3%、0.5%以及1.0%的噪

表1 使用 D_{CD} 误差作为评估标准下不同邻域半径的去噪效果对比

Table 1 Comparison of denoising effects of different neighborhood radii using D_{CD} error as the evaluation standard

r	joint	blade	block	column
2%	5.751	5.164	7.222	4.697
5%	2.742	3.661	4.527	2.467
8%	3.826	5.219	4.056	2.926
10%	7.873	5.771	6.745	3.566

声来模拟噪声数据,即共包括9组数据,训练结果如

表2 使用 D_{CD} 误差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 using D_{CD} error as evaluation standard

Gaussian noise	D_{CD} error / $\times 10^{-5}$				
	Noisy	TD	PointCleanNet	Pointfilter	MSPoint
casting					
0.3%	1.916	2.234	1.754	1.401	1.266
0.5%	3.676	3.628	3.672	3.331	2.906
1.0%	9.033	9.581	8.260	7.391	7.113
cube					
0.3%	2.257	1.356	0.963	0.712	0.631
0.5%	4.388	1.691	1.512	1.537	1.236
1.0%	12.57	2.503	2.178	1.861	2.025
fandisk					
0.3%	1.744	2.901	1.631	0.853	0.672
0.5%	3.577	3.219	2.384	1.903	1.898
1.0%	11.13	4.196	3.012	3.599	2.891

表3 使用 P2F 误差作为评估标准下不同算法的去噪效果对比

Table 3 Comparison of denoising effects of different algorithms using P2F error as the evaluation standard

Gaussian noise	P2F error / $\times 10^{-3}$				
	Noisy	TD	PointCleanNet	Pointfilter	MSPoint
casting					
0.3%	2.389	3.258	2.369	1.870	1.774
0.5%	3.915	3.792	3.823	4.387	3.668
1.0%	13.27	14.18	9.337	9.701	8.487
Cube					
0.3%	2.675	1.934	1.430	1.309	0.903
0.5%	4.572	2.187	2.028	1.726	1.499
1.0%	15.92	3.066	2.273	2.837	1.968
fandisk					
0.3%	2.446	3.402	1.726	1.351	0.745
0.5%	4.473	3.776	3.222	2.878	2.182
1.0%	14.93	5.771	4.353	3.884	3.598

图9、10、11为对干净点云添加0.5%噪声下各算法的去噪效果对比,Noise为未经降噪处理的噪声点云。从图9(c)、图10(c)可以看出,TD算法存在着过

表2所示。在评价指标为 D_{CD} 误差时,尽管 MSPoint 对于 1.0% 噪声的 cube 模型去噪效果不如 Pointfilter,但是处理其他模型时均为最优。对不同程度噪声的不同类型模型进行去噪时,相比 PointCleanNet、TD 以及 Pointfilter 等算法,MSPoint 的平均 D_{CD} 误差最小,代表经过 MSPoint 去噪后,预测点云与无噪声点云最为接近。由表3也可以看出,MSPoint 在以 P2F 误差作为评价指标下明显优于其他去噪网络,这是因为其他方法只考虑了每个噪声点的位移,而 MSPoint 去噪单位为每个点的邻域。

度平滑的情况,将 casting 模型原本的孔洞过度拟合了,而 MSPoint 还保留着较为清晰的特征。从图12可以看出,PointCleanNet 对模型的去噪存在异常值的情




图 9 0.5% 噪声 casting 点云模型去噪结果对比

Fig. 9 Comparison of 0.5% noise casting point cloud model denoising results




图 10 0.5% 噪声 cube 点云模型去噪结果对比

Fig. 10 Comparison of 0.5% noise cube point cloud model denoising results




图 11 0.5% 噪声 fandisk 点云模型去噪结果对比

Fig. 11 Comparison of 0.5% noise fandisk point cloud model denoising results

况。从图 9(e)、图 11(e)可以看出, Pointfilter 算法虽然不会过度平滑点云模型,但是仍然无法保留清晰的特征,且泛化能力较差,对不同特征的噪声模型去噪效果有差距。综合图 9、10、11 可得,对不同点云进行去噪处理时, MSPoint 的去噪效果最好,不仅可以保留点云的尖锐特征,且去噪后点云几何特征相比其他算法更加清晰,不存在过度平滑的情况。综上所述,所提 MSPoint 网络在对点云进行去噪时有着更强的泛化能力以及抗噪能力。

通过无人机载激光雷达对某大学图书馆进行点云数据采集,获取的点云模型如图 12 所示,由 21358741 个点组成。为验证 MSPoint 对实际激光点云数据的去噪效果,使用 MSPoint 对该点云模型进行去噪处理,其局部去噪效果如图 13、14、15 所示。

建筑物点云数据有着点云数量多、密集以及特征复杂等特点,由图 13~15 可以观察到,相比原始激光点云模型,去噪后的模型有着更加精细的局部特征以及更好的视觉效果。由模型局部去噪效果对比可得, MSPoint 对不同特征类型的点云模型均有可观的去噪




图 12 某大学图书馆点云数据

Fig. 12 Point Cloud data of a university library

效果,有着良好的实际应用性。

3.5 消融实验

特征提取模块中的多尺度扰动单元通过对输入数据添加多尺度扰动为网络的学习过程添加阻碍,使提取的特征更具有表现能力,加强网络的泛化能力与鲁棒性。为了验证多尺度扰动的有效性,采用控制变量法对输入数据添加从无到有、从小到大的扰动来进




图 13 大门台阶去噪前后对比。(a)去噪前;(b)去噪后

Fig. 13 Comparison of gate steps before and after noise removal. (a) Before noise removal; (b) after noise removal




图 14 背部楼道去噪前后对比。(a)去噪前;(b)去噪后

Fig. 14 Comparison of back corridor before and after noise removal. (a) Before noise removal; (b) after noise removal




图 15 角落去噪前后对比。(a)去噪前;(b)去噪后

Fig. 15 Comparison of corner before and after noise removal. (a) Before noise removal; (b) after noise removal

行实验,分析网络的拟合曲线以验证多尺度高斯噪声对点云去噪效果的影响,结果如图 16 所示。从图 16(a)可以看出,未对数据进行处理时,虽然网络初始时收敛得更快,但是后续收敛较慢,难以从噪声点云中学习到更具有表达能力的特征。从图 16(c)可以看出,当 $\sigma=0.5\%$ 时,网络虽然在初始时收敛较慢,但是收敛效果更好。从图 16(d)可以看出,当 $\sigma=1.0\%$ 时,点云偏离原始分布,潜在特征难以提取,损失波动较大。由此可得,多尺度扰动单元能够帮助特征提取模块提取到更具有表现能力的特征并加强网络的抗噪性能。

位移预测模块中的分数估计单元可以预测输入点云的局部邻域分数 ϵ , 并作为损失函数 L_a 的加权项引导网络的收敛过程。为了验证分数估计单元的有效性,通过对 L_a 与去除 ϵ 加权的损失函数 L_s 进行对比实验,分析分数估计单元对点云去噪效果的影响,结果如表 4 所示。当损失函数采用无分数函数加权的 L_s 时,只根据到无噪声点的最近距离进行训练,无论是在 P2F 还是 D_{CD} 评价指标下去噪效果都明显下滑。而 L_a 通过加权基于点云分布的分数函数 ϵ , 以邻域为单位预测噪声点位移,去噪效果更好。由此可得,分数估计单元在一定程度上提升了 MSPoint 的去噪性能。

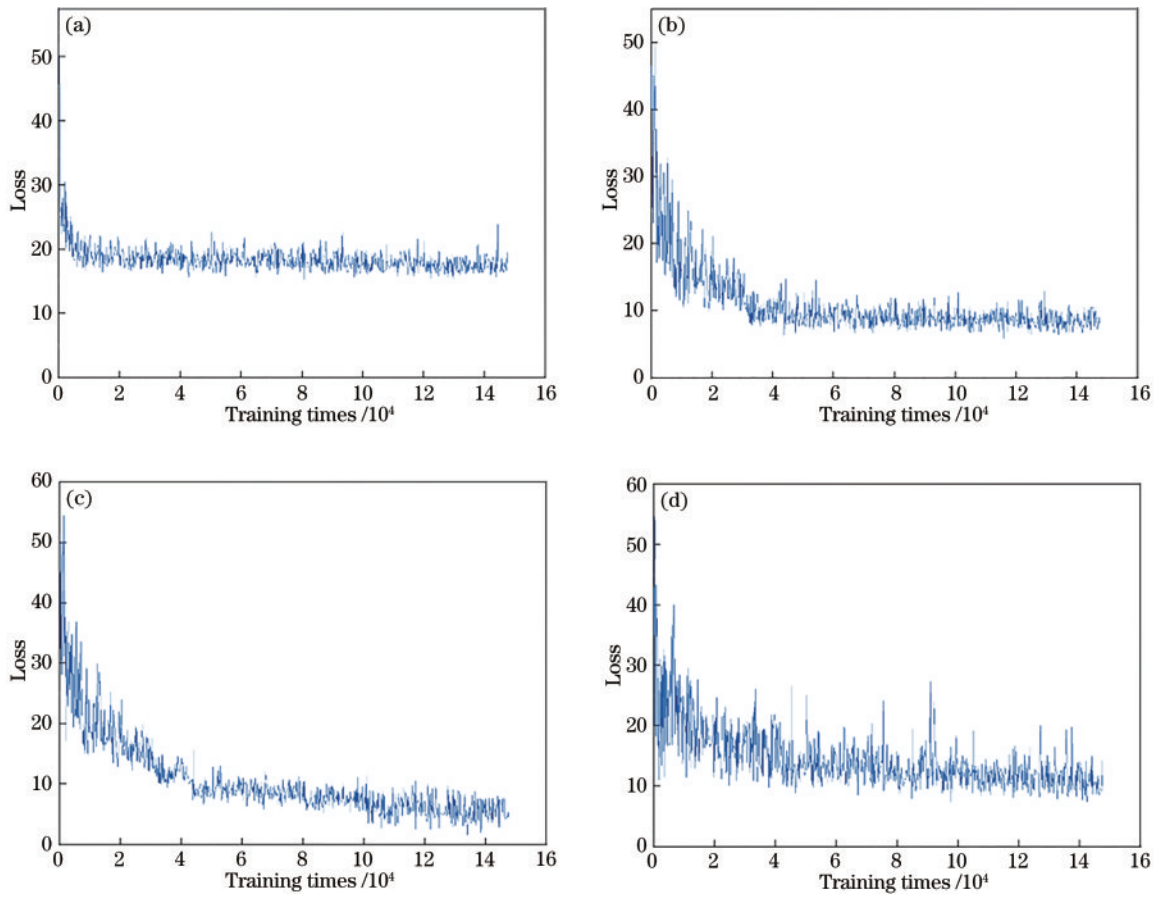


图 16 不同程度扰动的损失收敛情况。(a) $\sigma=0$;(b) $\sigma=0.1\%$;(c) $\sigma=0.5\%$;(d) $\sigma=1.0\%$

Fig. 16 Loss convergence of disturbances of different degrees. (a) $\sigma=0$; (b) $\sigma=0.1\%$; (c) $\sigma=0.5\%$; (d) $\sigma=1.0\%$

表 4 使用不同损失函数的去噪效果对比

Table 4 Comparison of denoising effects using different loss functions

Loss function	0.3%		0.5%		1%	
	D_{CD}	P2F	D_{CD}	P2F	D_{CD}	P2F
L_s	1.014	1.531	2.332	2.717	4.274	5.018
L_a	0.856	1.140	2.013	2.522	4.069	4.684

4 结 论

基于当前点云去噪存在的问题,提出一种新的去噪网络 MSPoint,该网络根据点云的分布来学习噪声点云的位移。特征提取模块通过加入多尺度的噪声扰动来为特征的提取制造障碍,强迫网络学习更深层次、更具有表达能力的特征。位移预测模块通过分数估计单元学习噪声点云分布的梯度来引导训练的方向,训练过程不仅考虑每个点的位置,还覆盖了点的邻域。实验结果表明,针对不同噪声程度、不同特征的噪声点云模型,MSPoint都表现出了优良的去噪效果,能够很好地保留点云的尖锐特征,具有良好的鲁棒性与泛化能力。后续工作将从优化网络结构入手,降低处理所需的时间,同时增强去噪的性能。

参 考 文 献

- [1] Mirzaei K, Arashpour M, Asadi E, et al. 3D point cloud data processing with machine learning for construction and infrastructure applications: a comprehensive review [J]. Advanced Engineering Informatics, 2022, 51: 101501.
- [2] 李琪琪, 花向红, 赵不钊, 等. 一种室内场景点云平面分割的新方法[J]. 中国激光, 2021, 48(16): 1604002.
Li Q Q, Hua X H, Zhao B F, et al. New method for plane segmentation of indoor scene point cloud[J]. Chinese Journal of Lasers, 2021, 48(16): 1604002.
- [3] 白崇岳, 王建军, 程霄霄, 等. 融合激光 SLAM 实现无人驾驶轮椅空间定位优化[J]. 激光与光电子学进展, 2022, 59(2): 0228007.
Bai C Y, Wang J J, Cheng X X, et al. Spatial positioning optimization of driverless wheelchair by fusion of laser SLAM[J]. Laser & Optoelectronics Progress, 2022, 59(2): 0228007.
- [4] 李维刚, 梅洋, 樊响, 等. 基于车载激光点云的铁路轨道检测[J]. 中国激光, 2022, 49(4): 0410002.
Li W G, Mei Y, Fan X, et al. Railway track detection based on vehicle laser point cloud[J]. Chinese Journal of Lasers, 2022, 49(4): 0410002.
- [5] Zhou H, Fang Z J, Gao Y B, et al. Feature fusion network based on attention mechanism for 3D semantic segmentation of point clouds[J]. Pattern Recognition Letters, 2020, 133: 327-333.

- [6] 赵亮, 胡杰, 刘汉, 等. 基于语义分割的深度学习激光点云三维目标检测[J]. 中国激光, 2021, 48(17): 1710004. Zhao L, Hu J, Liu H, et al. Deep learning based on semantic segmentation for three-dimensional object detection from point clouds[J]. Chinese Journal of Lasers, 2021, 48(17): 1710004.
- [7] 汪文琪, 李宗春, 付永健, 等. 基于改进多规则区域生长的点云多要素分割[J]. 光学学报, 2021, 41(5): 0528001. Wang W Q, Li Z C, Fu Y J, et al. Multi-factor segmentation of point cloud based on improved multi-rule region growing[J]. Acta Optica Sinica, 2021, 41(5): 0528001.
- [8] 林洪彬, 付德敏, 王银腾. 基于参数自适应各向异性高斯核的散乱点云保特征去噪[J]. 计算机集成制造系统, 2017, 23(12): 2583-2592. Lin H B, Fu D M, Wang Y T. Feature preserving denoising of scattered point cloud based on parametric adaptive and anisotropic Gaussian kernel[J]. Computer Integrated Manufacturing Systems, 2017, 23(12): 2583-2592.
- [9] 卢钰仁, 张明路, 吕晓玲, 等. 基于法向修正的双边滤波点云去噪处理[J]. 仪表技术与传感器, 2018(7): 111-115. Lu Y R, Zhang M L, Lü X L, et al. Point cloud denoising based on normal modification and bilateral filtering processing[J]. Instrument Technique and Sensor, 2018(7): 111-115.
- [10] 杨鹏, 刘德儿, 刘靖钰, 等. 基于最小二乘密度聚类的城市点云去噪算法[J]. 激光与红外, 2020, 50(11): 1402-1409. Yang P, Liu D E, Liu J Y, et al. Urban point cloud denoising algorithm based on least square density clustering[J]. Laser & Infrared, 2020, 50(11): 1402-1409.
- [11] 李鹏飞, 吴海娥, 景军锋, 等. 点云模型的噪声声分类去噪算法[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.
- [12] 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.
- [13] Zhou H, Chen K J, Zhang W M, et al. DUP-net: denoiser and upsampler network for 3D adversarial point clouds defense[C]//2019 IEEE/CVF International Conference on Computer Vision (ICCV), October 27-November 2, 2019, Seoul, Republic of Korea. New York: IEEE Press, 2019: 1961-1970.
- [14] 蒋通, 邹进贵. 基于区域生长的体素滤波点云去噪算法[J]. 测绘地理信息, 2021, 46(2): 63-66. Jiang T, Zou J G. Point cloud denoising algorithm of voxel filtering based on region growing[J]. Journal of Geomatics, 2021, 46(2): 63-66.
- [15] Li J L, Dai H, Shao L, et al. From voxel to point: IoU-guided 3D object detection for point cloud with voxel-to-point decoder[C]//MM '21: Proceedings of the 29th ACM International Conference on Multimedia, October 21, 2021, New York, NY, United States. New York: ACM, 2021: 4622-4631.
- [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] Qi C R, Yi L, Su H, et al. PointNet++: deep hierarchical feature learning on point sets in a metric space [EB/OL]. (2017-06-07)[2022-03-06]. <https://arxiv.org/abs/1706.02413>.
- [18] 徐俊, 杜宣莹, 宋俊锋, 等. 融合图注意力的摄影测量点云语义分割研究[J]. 小型微型计算机系统, 2022, 43(7): 1464-1470. Xu J, Du X X, Song J F, et al. Research on semantic segmentation of photogrammetric point clouds with image attention[J]. Journal of Chinese Computer Systems, 2022, 43(7): 1464-1470.
- [19] Wang Y, Sun Y B, Liu Z W, et al. Dynamic graph CNN for learning on point clouds[J]. ACM Transactions on Graphics, 2019, 38(5): 146.
- [20] Duan C, Chen S, 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 (ICASSP), May 12-17, 2019, Brighton, UK. New York: IEEE Press, 2019: 8553-8557.
- [21] 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.
- [22] Zhang D B, Lu X Q, Qin H, et al. Pointfilter: point cloud filtering via encoder-decoder modeling[J]. IEEE Transactions on Visualization and Computer Graphics, 2021, 27(3): 2015-2027.
- [23] 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, Republic of Korea. New York: IEEE Press, 2019: 52-60.
- [24] Lehtinen J, Munkberg J, Hasselgren J, et al. Noise2Noise: learning image restoration without clean data[EB/OL]. (2018-03-12)[2022-03-06]. <https://arxiv.org/abs/1803.04189>.
- [25] Luo S T, Hu W. Score-based point cloud denoising[C]//2021 IEEE/CVF International Conference on Computer Vision (ICCV), October 10-17, 2021, Montreal, QC, Canada. New York: IEEE Press, 2021: 4563-4572.
- [26] Zong D, Sun S, Zhao J. Ashf-net: Adaptive sampling and hierarchical folding network for robust point cloud completion[J]. Proceedings of the AAAI Conference on Artificial Intelligence, 2021, 35(4): 3625-3632.
- [27] Fan H Q, Su H, Guibas L J. 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.
- [28] Wang Y F, Wu S H, Huang H, et al. Patch-based progressive 3D point set upsampling[C]//2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), June 15-20, 2019, Long Beach, CA, USA. New York: IEEE Press, 2019: 5951-5960.