

嵌入注意力机制的并行多尺度点云上采样方法

肖霄, 柏正尧, 李泽锴, 刘旭珩, 杜佳锦

引用本文

肖霄, 柏正尧, 李泽锴, 刘旭珩, 杜佳锦. [嵌入注意力机制的并行多尺度点云上采样方法](#)[J]. 计算机科学, 2024, 51(8): 183-191.

XIAO Xiao, BAI Zhengyao, LI Zekai, LIU Xuheng, DU Jiajin. [Parallel Multi-scale with Attention Mechanism for Point Cloud Upsampling](#) [J]. Computer Science, 2024, 51(8): 183-191.

相似文章推荐 (请使用火狐或 IE 浏览器查看文章)

Similar articles recommended (Please use Firefox or IE to view the article)

[基于注意力机制的CNN和BiGRU的加密流量分类](#)

Encrypted Traffic Classification of CNN and BiGRU Based on Self-attention
计算机科学, 2024, 51(8): 396-402. <https://doi.org/10.11896/jsjcx.230500032>

[基于知识图谱与邻域感知注意力机制的推荐算法研究](#)

Study on Recommendation Algorithms Based on Knowledge Graph and Neighbor PerceptionAttention
Mechanism
计算机科学, 2024, 51(8): 313-323. <https://doi.org/10.11896/jsjcx.230500143>

[基于RoBERTa和加权图卷积网络的中文地质实体关系抽取](#)

Chinese Geological Entity Relation Extraction Based on RoBERTa and Weighted Graph Convolutional
Networks
计算机科学, 2024, 51(8): 297-303. <https://doi.org/10.11896/jsjcx.230600231>

[基于多模态注意力网络的红外人体行为识别方法](#)

Infrared Human Action Recognition Method Based on Multimodal Attention Network
计算机科学, 2024, 51(8): 232-241. <https://doi.org/10.11896/jsjcx.230600143>

[基于双鉴别器和伪视频生成的视频异常检测方法](#)

Video Anomaly Detection Method Based on Dual Discriminators and Pseudo Video Generation
计算机科学, 2024, 51(8): 217-223. <https://doi.org/10.11896/jsjcx.230600148>

嵌入注意力机制的并行多尺度点云上采样方法

肖 霄 柏正尧 李泽锴 刘旭珩 杜佳锦

云南大学信息学院 昆明 650500

(xenon@mail.ynu.edu.cn)

摘要 目前,基于深度学习的点云上采样方法缺失对局部区域特征关联性的关注和对全局特征的多尺度提取,导致输出的密集点云存在异常值过多、细粒度不高等问题。为解决上述问题,提出了嵌入注意力机制的并行多尺度点云上采样网络(Parallel Multi-scale with Attention mechanism for Point cloud Upsampling),网络由特征提取器、特征拓展器、坐标细化器和坐标重建器4个模块级联组成。首先给定一个 $N \times 3$ 的稀疏点云作为输入,为了获得点云的全局和局部特征信息,设计了一个嵌入注意力机制的并行多尺度特征提取模块(PMA)用于将三维空间的点云映射到高维特征空间。其次使用边缘卷积特征拓展器拓展点云特征维度,得到高维点云特征,以更好地保留点云特征的边缘信息,将高维点云特征通过坐标重建器转换回三维空间中。最后使用坐标细化器精细调整输出点云细节。在合成数据集PU1K上的对比实验结果表明,PMA-PU生成的密集点云在倒角距离(CD)、豪斯多夫距离(HD)和点面距离(P2F)上都有显著提升,分别比性能次优的网络模型优化了7.863%,21.631%,14.686%。可视化结果证明了PMA-PU具有性能更好的特征提取器,能够生成细粒度更高、形状更接近真实值的密集点云。

关键词:3D点云;深度学习;点云上采样;并行多尺度特征提取;注意力机制

中图分类号 TP391

Parallel Multi-scale with Attention Mechanism for Point Cloud Upsampling

XIAO Xiao,BAI Zhengyao,LI Zekai,LIU Xuheng and DU Jiajin

School of Information Science and Engineering,Yunnan University,Kunming 650500,China

Abstract The current deep learning-based point cloud upsampling method lacks the attention to a local area feature correlation and multi-scale extraction of global features,resulting in the dense output point cloud with too many outliers and low fine-grained granularity. To solve the above problem,a parallel multi-scale with attention mechanism for point cloud upsampling(PMA-PU) network is proposed,which consists of a feature extractor,a feature expander,a coordinate refiner and a coordinate reconstructor. Firstly,giving an $N \times 3$ sparse point cloud as input,a parallel multi-scale feature extraction module(PMA) with an embedded attention mechanism is designed to map the point cloud in 3D space to the high-dimensional feature space to obtain the global and local feature information of the point cloud. Secondly,the high-dimensional point cloud features are obtained after expanding the dimensionality of the point cloud features using the edge convolution feature expander to better preserve the edge information of the point cloud features,and the high-dimensional point cloud features are converted back to the 3D space by the coordinate reconstructors. Finally,the output point cloud details are fine-tuned by using the coordinate refiners. The results of the PMA-PU comparison experiments on the synthetic dataset PU1K show that the generated dense point cloud has significant improvement in the three evaluation metrics,Chamfer Distance(CD),Hausdorff Distance(HD),and P2F(point-to-surface),which are significantly better than the second highest performance. The network models with the second highest performance are optimized by 7.863%,21.631%,and 14.686%,respectively. The visualization results demonstrate that PMA-PU has a better performance feature extractor,which can generate dense point clouds with higher fine granularity and a shape closer to the true value.

Keywords 3D point cloud,Deep learning,Point cloud upsampling,Parallel multi-scale feature extraction,Attention mechanism

1 引言

随着激光扫描设备和3D传感设备(如RGB-D相机)的普遍出现,点云(Point Cloud)被越来越多地用作三维数据,其

促进了三维目标检测^[1]、3D点云分割^[2]等理论的研究兴起,对新的应用如自动驾驶技术、机器人操控起着关键性的作用。通过三维激光雷达传感器获取的点云数据能为汽车自动驾驶的路径规划和导航定位提供可靠的支撑,然而由于硬件条件

到稿日期:2023-05-15 返修日期:2023-10-11

基金项目:云南省重大科技专项计划(202002AD080001)

This work was supported by the Yunnan Provincial Major Science and Technology Special Plan(202002AD080001).

通信作者:柏正尧(baizhy@ynu.edu.cn)

尤其是三维传感器芯片的限制,直接采集到的点云通常都是低分辨率的甚至是有噪声的,难以满足使用要求。点云上采样技术旨在将稀疏的、不均匀的点云转化为视觉质量更好、细节更精细的点云。因此,点云上采样作为一种修正操作备受研究人员的关注。

近年来,随着高性能计算机的普及,基于深度学习的方法在点云上采样上取得了很好的结果,如 PU-NET^[3],MPU^[4],PU-GCN^[5],PU-GAC^[6]等基于深度学习的方法比基于传统的方法有了很大的改进。其依赖于数据驱动的学习方式,不需要繁琐的数据预处理,因而可以处理多尺度多特征点云数据。

目前大多数基于深度学习的点云上采样网络性能依赖其特征提取模块和特征拓展模块。上述方法只考虑全局信息,忽略了局部区域之间的关联性,对特征信息利用不够充分,导致输出的密集点云存在细粒度不足和异常值较多等问题。为解决上述问题,提出了一种嵌入注意力机制的并行多尺度点云上采样方法(PMA-PU),设计了新的特征提取器和特征拓展器,解决了局部区域关注度不足的问题并充分利用了特征信息。此外,还级联了一个空间细化器以调整输出点云的位置细节。综上所述,本文的主要贡献有以下几点:

- 1)提出了一种新的并行特征提取模块 PMA。将多条不同 K 近邻扩张率的图卷积并联,扩大了多路径图卷积的感受野;在图卷积中加入残差连接,加深图卷积的训练层数,更好地对高级特征信息进行提取;并将自注意力模块嵌入其中,解决了缺少区域之间关联性的问题。
- 2)采用边缘图卷积特征拓展模块,通过边缘图卷积拓展获得的点云特征,更好地拓展局部信息,保留点云的边缘特征。
- 3)加入一个基于自注意力机制的空间细化器,组成四模块级联结构。对输出点云坐标进行细化,使最终输出的密集点云更加贴近表面。
- 4)所提方法在合成数据集 PU1K^[6]采样任务中取得了较为优秀的效果,其指标超过了大多数主流方法。

2 相关工作

2.1 节总结了基于传统方法的点云上采样;2.2 节介绍了基于深度学习的点云上采样方法,总结了其特点与不足;2.3 节介绍了针对点云上采样任务提出的图卷积方法。

2.1 基于传统方法的点云上采样方法

传统点云上采样中最简单的是基于插值的算法,如 Alex 等^[7]提出的基于插值的方法。此方法计算量小但生成的点云在曲面多的区域无法维持原来的形状。基于优化的方法如基于深度图像序列的点云上采样方法使用时间密度提升空间密度。Ferstl 等^[8]提出的基于单帧深度图像的点云上采样方法需原始点云数据,系统效率高。其缺点是极度依赖先验信息,而非数据驱动,通常难以处理特征较多且携带噪声的点云数据。Schuon 等^[9]提出的双边正则化项的序列深度图像上采样方法利用多个点云数据之间的冗余,仅根据退化模型实现上采样,降低了系统成本和设计难度。其缺点在于只适用于静态的场景且多帧点云数据依赖精确的配准。

2.2 基于深度学习的点云上采样方法

近年来,深度学习技术迅速发展,研究人员积极地将深度学习技术运用在点云上采样上,相较于传统的点云上采样方法取得了更好的结果。PointNet^[10]的出现使得点云的特征得以被学习到,但由于不捕获由度量空间中引起的局部结构,因此对复杂点云的泛化能力受限。随后出现的 PointNet++^[11]使用分层特征学习体系结构捕获局部几何上下文信息,从而能高效地学习深度点云特征。PU-Net^[3]首次提出了数据驱动的点云上采样技术,其采用 PointNet++ 中的分层特征学习机制,通过多分支 MLP 学习和扩展输入数据中每个点的特征,但这种提取方式忽略了局部和邻居信息。MPU^[4]提出了基于点云块的端到端渐近学习方法。该模型由一系列上采样单元组成,每个单元有相同的结构,在不同的细节层次上使用。但由于其渐近的特性,因此计算需求大,训练时间长。PU-GAN^[12]在生成对抗网络(GAN)的基础上进行了改进,构造了具有误差反馈和自校正功能的点云上采样生成器单元。与 MPU 类似,其通过复制点的特征对点云数据进行上采样,极大地限制了输出的点云的变化且鉴别器结构过于复杂,资源消耗极大。Dis-PU^[13]首次将点云上采样任务分解为两个子任务:一个是密集点云生成器,将输入的稀疏点云生成粗略但密集的粗点云;另一个是空间细化器,通过调整粗点云每个点的位置进一步细化。但其网络训练的速度随数据集的增大而明显变慢。PU-GCN^[5]设计了基于图卷积(GCN)的全新特征提取 Inception 模块用于特征提取,节点洗牌(NodeShuffle)用于特征扩展。此网络能够更好地编码局部信息且在一段阶段就能完成上采样任务,然而其特征提取模块忽略了捕获区域之间的关联性。PUFA-GAN^[14]提出了一种新的生成对抗点云上采样方法,使用包含动态图分层残差聚集单元的生成器和图滤波鉴别器,捕捉了丰富的特征,保留了点云的高频特性。PU-Refiner^[15]同样基于生成对抗网络创建了粗特征提取和粗特征拓展模块,并用一个渐近几何细化模块恢复密集点云,使生成点云的形状更接近真实点云。PU-EVA^[16]通过基于边缘向量的仿射组合编码邻居特征,并将近似误差限制在泰勒展开的二阶项内,实现了一次训练就可以采用任何上采样率。但其上采样率的上限受制于网络大小和处理器性能。

2.3 用于点云数据的图卷积网络

点云数据与二维图像数据的结构不同,点集多为非欧氏数据。图卷积^[17]在点集上通过构造图结构及聚合图结构信息为非欧氏数据处理提供了合适的解决方案。因能够灵活地学习节点和节点构成的边的特征信息,图卷积在各种点云学习任务中广泛流行,代表性方法有 SpiderCNN^[18],IterpCNN^[19]等。DGCNN^[20]受启发于 CNN,提出了新的神经网络模块 EdgeConv 来构建动态的局部邻域图,即点的 K 近邻通过网络的每一层都在变化,充分捕获了局部几何结构。

Li 等^[21]针对图卷积训练深度较浅的问题,将残差链接和密集链接引入 GCN 并适应其结构,解决了 GCN 训练超过 3 层性能就会下降的问题。Kazi 等^[22]受到 GoogLeNet 的 Inception 架构的影响,提出了 InceptionGCN 模型。该模型在不同路径上使用不同大小内核的过滤器捕获图内和图间的结构异质性。受注意力机制的启发,Wang 等^[23]提出了一种

领域点,在 $k \times d$ 大小的领域获取到 k 个近邻顶点,扩大了图卷积的感受野而不会造成空间上的信息损失。RESGCN

模块如图 3 所示,将其将残差结构应用到图卷积上实现多层图卷积训练并且解决了梯度消失的问题。




图 3 残差多层图卷积(RESGCN)模块结构图

Fig. 3 Framework of RESGCN

$$G_{l+1} = F(G_l, W_l) + G_l = G_{l+1}^{\text{res}} + G_l \quad (1)$$

其中, F 表示残差映射,当图卷积不是第一层运算层时,将当前图卷积运算层的上一运算输出结果的残差映射与本层输出结果相加,输出得到特征 G_{l+1} ,将其作为下一层的输入。设 f_i 为几何特征 F_i 通过卷积核为 1×1 大小的压缩层压缩后 RESGCN 的输入特征。

$$G_l = \sigma\{MLP(\Delta f_{ij}) + MLP(f_i)\} \quad (2)$$

其中, $f_j = \{f_1, f_{1+d}, f_{1+2d}, f_{1+3d}, \dots, f_{1+(k-1)d}\} \subseteq F^{(d)}$ 为邻居点对应的特征, $f_i = \{f_1, f_2, f_3, \dots, f_N\} \subseteq F^{(n)}$ 为中心点对应的特征, G_l 为残差图卷积中第一个运算层的输出特征, $\Delta f_{ij} = (f_j - f_i)$ 表示邻居点特征和中心点特征的相关性, σ 表示 ReLU 非线性激活函数。中心点和中心点与邻居点构成的边分别通过两个 32 输出通道数的单层 MLP,最终得到的残差图输出 G_{l+1} 通过最大池化层聚合。每个残差多层图卷积中的运算层设置数量为 3 时效果最佳。 G_l 维度为 $N \times C$, C 为通道数 32。

将自注意力模块融合到未使用扩张 K 近邻的 RESGCN 中,提取局部区域之间的关联性,充分利用多路径图卷积的特点。自注意力模块如图 4 所示,第三条 RESGCN 路径输出的特征 G_l 经过 3 个 32 输出通道数 MLP 后得到 Q, K, V 矩阵。

$$F_l = MLP\{\text{softmax}(QK^T)V\} \quad (3)$$

其中, F_l 为经过自注意力模块后输出的点云特征。 Q 矩阵与 K 矩阵的转置进行矩阵乘法,得到的矩阵作为注意力权重矩阵 A ,然后使用 softmax 进行归一化处理,得到的矩阵与 V 矩阵相乘,最后通过多层感知机运算得到 F_l 。 F_l 和 G_l 特征维度相同。在并联的第三条图卷积路径上获取到全局信息,捕获了局部区域之间的相关性,充分利用了特征信息。此外,本文还添加了全局最大池化模块,针对不同接受域与多路径图卷积一起提取全局上下文信息。

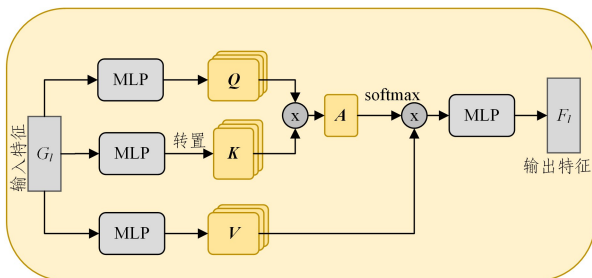


图 4 自注意力(self-attention)模块结构图

Fig. 4 Framework of self-attention module

$$F_c = (G_l^1 \oplus G_l^2 \oplus F_l \oplus F_p) + f_i \quad (4)$$

其中 F_c 为聚合特征,形状为 $N \times C$, C 为 97,由 3 条并行的 32 通道图卷积与 1 通道全局最大池化拼接而成, F_p 为全局最大池化输出特征。 F_c 聚合了 3 条路径图卷积输出特征和全局池化层。后续消融实验表明,增加或减少图卷积的路径数量对网络性能有一定影响,注意力机制模块能较大程度地提升 PMA-PU 的性能。

3.3 特征拓展器

特征拓展器将特征提取器获取到的 $N \times C$ 维聚合特征 F_c 根据设定的上采样率 r 拓展。特征 F_c 首先通过一个压缩层,将维度 C 从 97 压缩到 64。图 5 展示了边缘图卷积结构图。压缩后的特征输入边缘卷积,一条路径使用 K 近邻构造中心点特征 f_i 及其邻居特征 f_k ,将两者做差后得到有向边特征,通过 $r \times C$ 通道数的 MLP 拓展得到 F_{ik} 。另一路径直接将中心点特征通过相同规格的 MLP 拓展后得到 F_i 。 F_{ik} 和 F_i 聚合后通过 MLP 得到输出维度为 $N \times rC'$ 的特征 F ,其中 r 为网络设置的上采样率 4。最后用一个周期洗牌算子对拓展后的聚合特征重新排列,得到维度为 rN 的高维点云特征 $F_d = \{f_1, f_2, f_3, \dots, f_{rN}\} \subseteq \mathbb{R}^{C'}$ 。




图 5 边缘图卷积(EdgeConv)模块结构图

Fig. 5 Framework of EdgeConv

3.4 坐标重建器

为重建高分辨率稠密点云,坐标重建器要从获取到的高维点云特征 $F_d = \{f_1, f_2, f_3, \dots, f_{rN}\} \subseteq \mathbb{R}^{C'}$ 中回归三维坐标。本文使用和 PU-GAN^[11] 相同的方法,维度为 $rN \times C'$ 的点云特征通过两组 MLP 回归到三维坐标中,记为点云 $P' = \{p_1, p_2, p_3, \dots, p_{rN}\} \subseteq \mathbb{R}^3$ 。

3.5 坐标细化器

点云特征 $F_d = \{f_1, f_2, f_3, \dots, f_{rN}\} \subseteq \mathbb{R}^{C'}$ 若直接回归到三维空间中,会因近似误差而使得最终生成的点云分布不均匀。坐标细化器将已经回归三维空间的粗点云 $P' = \{p_1, p_2, p_3, \dots, p_{rN}\} \subseteq \mathbb{R}^3$ 和高维点云特征 $F_d = \{f_1, f_2, f_3, \dots, f_{rN}\} \subseteq$

\mathbb{R}^C 作为输入。如式(5)所示,将 F_d 输入坐标细化器的自注意力层(自注意力层结构如图 4 所示),获得 $F_{d'} = \{f_1, f_2, f_3, \dots, f_{rN}\} \subseteq \mathbb{R}^C$ 精细化特征。经过 MLP 回归到三维空间得到局部细化单元 $\mathbf{P}^d = \{p_1, p_2, p_3, \dots, p_{rN}\} \subseteq \mathbb{R}^3$ 。

$$\mathbf{P}^d = MLP(F_{d'}) = MLP(\text{softmax}(\mathbf{QK}^T)\mathbf{V}) \quad (5)$$

将 \mathbf{P}^d 与 \mathbf{P}' 相加,得到输出的 $\mathbf{P}^r = \{p_1, p_2, p_3, \dots, p_{rN}\} \subseteq \mathbb{R}^3$ 精细的稠密点云,如式(6)所示:

$$\mathbf{P}^r = \mathbf{P}' + \mathbf{P}^d \quad (6)$$

4 实验

PMA-PU 网络将在专用于点云上采样的大规模合成数据集 PU1K 上进行实验。定量和定性的结果说明 PMA-PU 具有优秀的点云上采样性能,大量的对比实验表明了网络参数设置的合理性与必要性。除此之外,本文进行了广泛的消融实验,展示了特征提取模块中 PMA 模块、边缘卷积模块、特征拓展模块和坐标细化器的优秀性能和有效性。

4.1 数据集与参数设置

合成数据集 PU1K 在 PU-GCN^[5] 中首次被提出并运用,是一个为点云上采样任务专门创建的大规模 3D 数据集。PU1K 数据集中包含 1147 个 3D 模型,其中有训练样本模型 1020 个,测试样本模型 127 个。训练和测试的模型包括来自 PU-GAN^[12] 数据集的 147 个 3D 模型和来自 ShapeNet-Core^[27] 的 1000 多个 3D 模型。而 PU-GAN 数据集仅包含 120 个训练样本和 27 个测试模型。相比之前 PU-GAN^[12] 提出的数据集,PU1K 数据集除了简单形状还包含复杂形状,覆盖了更大的语义范围。研究人员已经验证了 PU1K 数据集的优越性,在 PU1K 公开数据集上进行的实验证明了 PMA-PU 网络的有效性更加具有说服力。在训练阶段,将每个 3D 模型裁剪为 50 个点云块。1020 个训练样本共有 51000 个点云块,每个点云块有 256 个点作为低分辨率输入,1024 个点作为真实点云。在测试阶段,输入点云由 2048 个点组成,真实点云由 8192 个点组成。

全部实验均在 TensorFlow 平台上进行,在 InterCorei9-10900X CPU 和 NVIDIA RTX3090 GPU 上训练 PMA-PU,使用 ADAM 优化器,学习率为 0.001,衰减率为 0.9。epoch 设置为 100, batchsize 设置为 64。使用上采样率 $\times 4$,即 $r=4$ 得出实验结果,以便与其他主流点云上采样网络进行性能比较。

4.2 损失函数

PMA-PU 网络使用联合损失函数,结合了重建损失和排斥损失。

重建损失计算生成点云和真实点云之间的倒角距离加权值之和,用于评估输出点云与真实点云的相似性。重建损失如式(7)所示:

$$L_{\text{rec}} = \frac{1}{|\mathbf{P}_{\text{OP}}|} \sum_{p \in \mathbf{P}_{\text{OP}}} \min_{q \in \mathbf{P}_{\text{GT}}} \|p - q\|_2^2 + \frac{1}{|\mathbf{P}_{\text{GT}}|} \sum_{q \in \mathbf{P}_{\text{GT}}} \min_{p \in \mathbf{P}_{\text{OP}}} \|q - p\|_2^2 \quad (7)$$

其中, \mathbf{P}_{GT} 是真实点云, \mathbf{P}_{OP} 是输出点云。 p 为 \mathbf{P}_{OP} 中的 3D 点云, q 为 \mathbf{P}_{GT} 中的 3D 点云。 $\|\cdot\|_2^2$ 表示欧几里得范数的平方。加入排斥损失是为了使输出的密集点云分布不会过于

紧密从而使分布更加均匀。排斥损失如式(8)所示:

$$L_{\text{rep}} = \sum_{i=0}^{rN} \sum_{j \in N(i)} \eta(\|p_j - p_i\|_2) \omega(\|p_j - p_i\|_2) \quad (8)$$

其中, rN 为上采样后输出的点云数, p_j 表示顶点 p_i 的近邻点, $\|\cdot\|_2$ 表示欧几里得范数。 $\eta(x) = -x$ 为排斥项,是一个递减函数。为了让顶点 p_i 过于接近设置的 k 个近邻时才受到约束,将过于接近的点的距离拉开。 $\omega(x) = e^{-\frac{x^2}{k}}$ 为快速衰减权重函数。

联合损失函数由重建损失和排斥损失加权求和组成,如式(9)所示:

$$L_{\text{join}} = L_{\text{rec}} + \alpha L_{\text{rep}} + \beta \|\theta\|_2^2 \quad (9)$$

其中, α 为平衡重建损失和排斥损失的权重系数, β 为正则化项 θ 的权重衰减系数。对比实验说明了此联合损失函数的优越性。

4.3 评价指标与测试基准

本文使用倒角距离 (Chamfer Distance, CD)、豪斯多夫距离 (Hausdorff Distance, HD)、以及点面距离 (P2F) 3 个度量指标评价 PMA-PU 网络的性能。为了直观地展示和比较,后续章节的表格中,3 个评价指标使用度量单位 $N \times 10^{-3}$, 指标数值越低,性能越好。本文研究了特征提取器中 K 近邻算法所取的局部顶点 k 的个数对网络性能的影响。具体地,将局部区域顶点 k 的数量从 5 增加到 20, 分别测试其上采样性能。表 1 列出了不同 k 时的结果。当 $k=10$ 时 PMA-PU 达到了最好的效果。故模型使用的 K 近邻算法所取局部顶点 k 的个数为 10 个。

表 1 局部点数 k 对网络性能的影响

Table 1 Effects of the number of region points k on network performance

评价指标	$k=5$	$k=10$	$k=15$	$k=20$
CD ↓	1.025	0.539	0.697	0.631
HD ↓	13.090	5.938	8.700	6.878
P2Favg ↓	4.766	2.132	3.328	2.512

将 PMA-PU 与之前主流的方法进行定量和定性的对比,对比方法包括 PU-NET^[3], MPU^[4], Dis-PU^[13], PU-GCN^[5], PU-GAC^[6] 和 PU-EVA^[16]。其他代码和预训练模型不可用的网络如 PUFA-GAN^[14] 和 SPU-NET^[23] 等方法被排除在比较之外。

4.4 定量和定性结果分析

4.4.1 定量结果

表 2 列出了 PMA-PU 在 PU1K 合成数据集上与测试基准的性能对比结果。

表 2 PU1K 数据集上 PMA-PU 与主流方法的对比结果

Table 2 Comparison results of PMA-PU vs. mainstream methods on PU1K dataset

网络模型	距离			参数量 ↓ / kB	推理时间 ↓ / ms
	CD ↓	HD ↓	P2Favg ↓		
PU-NET ^[3]	1.155	15.170	4.834	814.3	10.00
MPU ^[4]	0.935	12.327	3.551	76.2	13.80
Dis-PU ^[13]	1.074	14.294	3.061	1036.9	5.50
PU-GCN ^[5]	0.585	7.577	2.499	75.9	8.83
PU-EVA ^[16]	0.649	8.870	2.715	2869.0	12.80
PU-GACNet ^[6]	0.665	9.053	2.429	41.3	6.40
PMA-PU	0.539	5.938	2.132	68.9	11.70

从表中可以看出,PMA-PU 在 3 个评价指标上都有显著的改进。CD,HD 和 P2F 作为评价点云上采样网络的重要指标,其直接计算两片点云间的距离,更具可靠性和适配性。PMA-PU 相比表中性能居第二位的网络在 3 个指标上分别提升 7.863%,21.631% 和 14.686%。表 2 中还对比了主流方法的运算成本参数,相比之下,本文方法比其他主流网络上采样生成稠密点云的时间略长,但参数量较少,表明 PMA-PU 的运算复杂度低。相比运算复杂度综合最优的 PU-GACNet^[6],本文方法生成点云性能有明显的提升,但复杂度提升不明显。本文方法用较小的运算复杂度提升换取更多点云生成质量的提升,综合来看效果良好。




图 6 PU1K 数据集上的点云上采样定性结果

Fig. 6 Qualitative results of point cloud upsampling on PU1K dataset

4.5 对比分析实验

4.5.1 输入点云数量的影响实验

图 7 展示了 PMA-PU 网络对不同输入点云数量的可视化定性结果。

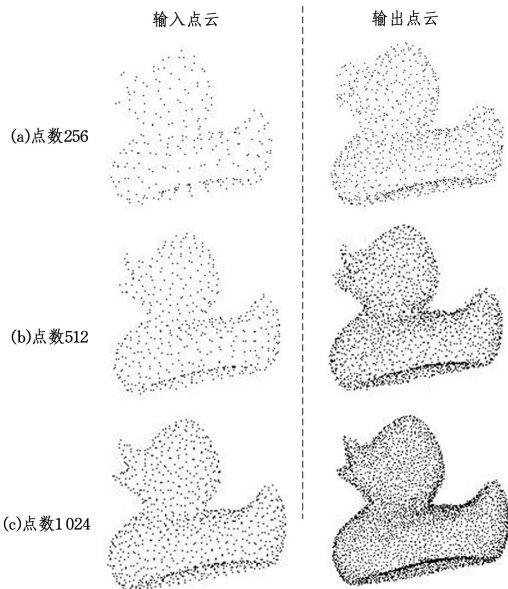


图 7 不同输入点云数量的点云上采样定性结果

Fig. 7 Qualitative results of point cloud upsampling with different number of input point clouds

结果显示无论输入点云数量为 256, 512 还是 1024, PMA-PU 网络都能够生成质量优秀的密集点云。本小节

4.4.2 定性结果

图 6 展示了 PMA-PU 和测试基准在 PU1K 上生成的定性点云上采样结果。图 6 随机选择了 3 个不同类型的物体,包括手提包、狗、摩托。从图 6 中上采样输出的密集点云及其放大图可观察到,PMA-PU 生成的点云可视化保留了较高质量细粒度的细节,还原程度更接近真实点云形状,见图 6 第一、二排的特写(手提包的把手,狗的尾巴)。PMA-PU 能够保持分离结构的质量,而非倾向于合并原来分离的结构,见第三排物体特写(摩托车的前轮)。综上所述,PMA-PU 输出的上采样密集点云的离群值数量相比基准方法明显减少,异常值数量相比主流的先进点云上采样网络有显著减少。

验证了 PMA-PU 网络在不同输入点云数量上的泛化能力,证明网络能够运用到不同输入数量的数据集。

4.5.2 加入噪声的鲁棒性实验

本小节为了展示 PMA-PU 模型的鲁棒性,使用与 PU-GACNet^[6] 相同的数据增强策略,改变抖动系数 σ 的值,对输入点云加入加性噪声干扰,定性、定量地分析模型的鲁棒性。定量结果如表 3 所列,结果表明 PMA-PU 加入一定的噪声后能够有效提升网络的性能,例如本文加入 $\sigma=0.01$ 的抖动系数后性能明显提升。当没有对输入点云进行加性噪声干扰时,网络性能下降明显。抖动系数并非越大越好,加入更多的噪声并不能继续提升性能,例如在对比实验中加入 $\sigma=0.02, \sigma=0.03$ 的抖动系数时,模型性能反而下降。

表 3 鲁棒性实验的定性结果

Table 3 Qualitative results of robustness experiments

抖动系数	距离		
	CD ↓	HD ↓	P2Favg ↓
$\sigma=0$	0.919	11.862	3.854
$\sigma=0.01$	0.539	5.938	2.132
$\sigma=0.02$	0.599	6.812	2.577
$\sigma=0.03$	0.590	6.807	2.739

定性结果如图 8 所示,PMA-PU 输出的高分辨率点云保留了更高的细粒度,在加入同等噪声条件下离群值比性能优秀的 PU-GCN^[6] 更小,形状更接近真实点云,边缘也与网格更贴近。

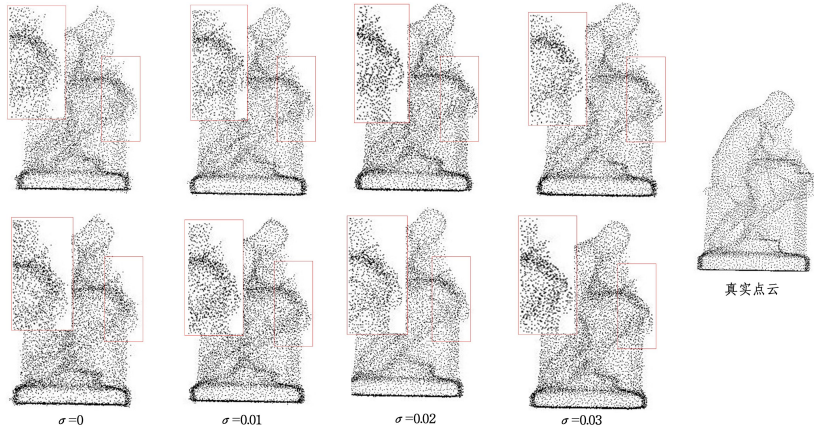


图 8 鲁棒性实验定性结果

Fig. 8 Qualitative results of robustness experiments

4.5.3 下游任务实验

点云上采样任务往往服务于众多点云数据下游任务。点云表面重建^[28]能够通过点云数据高效简便地生成高精度三维模型,是点云下游任务中最广泛的应用。本小节为了证明点云上采样后得到的密集点云能够重建为更高质量的网格表面,统一采用泊松表面重建^[29]方法,使用相同的法线计算策略,设置相同的重建深度。重建输入稀疏点云,输出密集点云,分别产生对应的网格。

图 9 展示了稀疏点云和密集点云表面重建后的可视化结果。如图所示,待上采样的稀疏点云重建后的物体表面缺失了应有的边缘信息,使得重建后的网格表面产生了很多凹凸不平的块(细节见可视化第一排熊猫对比)。此外,稀疏点云由于点数量和质量的落后,在使用相同的方法和参数重建后会产生相当多的错位,形状细节和原点云不匹配(细节见可视化第二排大象对比)。

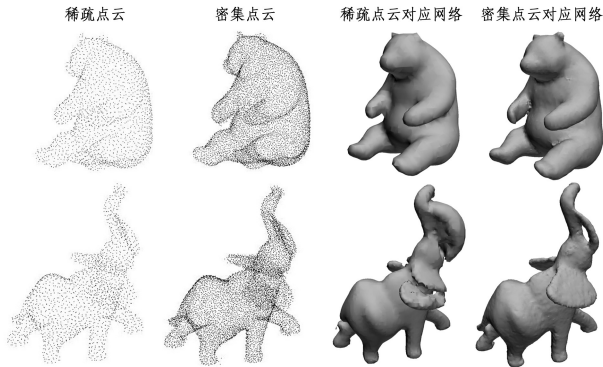


图 9 点云表面重建可视化定性结果

Fig. 9 Qualitative results of point cloud surface reconstruction visualization

综上所述,点云上采样对于点云表面重建等下游任务的更好应用具有重要作用。

4.6 消融实验

为了证明所提模型各模块的有效性,针对 PMA-PU 模型的特点,对并行特征提取模块(PMA)、边缘图卷积特征拓展器和联合损失函数进行了消融实验。所有实验都在 PU1K 公开数据集上训练和测试。

4.6.1 PMA 模块的消融实验

表 4 列出了 PMA 模块消融实验的定量结果,可以看出,完整的 PMA-PU 在综合 3 个评估指标中表现最优。模块 A 为嵌入 PMA 模块的自注意力模块,模块 B 为 RESGCN 模块,模块 C 为对 3 条不同扩张率的 K 近邻算法预处理。实验 1 在完整 PMA 模块的基础上去除自注意力模块,其性能下降明显,表明了自注意力模块对 PMA-PU 的显著贡献。实验 2 将残差模块去除,仅使用单层图卷积,结果表明更深的图卷积层能提升上采样效果。实验 3 结果表明,使用不同扩张率的 K 近邻算法能获得更好的性能,随着并行的路径增加,接受域扩大,效果越好。当并行的路径超过 3 条,网络性能开始下降。因此在 PMA-PU 中默认使用 3 条并行路径。定性可视化结果如图 10 所示,去除模块 A、B 和 C 后生成的点云细粒度明显不足,异常值多(见图 10 细节放大图)。

表 4 PMA 模块消融实验的定性结果

Table 4 Qualitative results of PAM module ablation experiments

实验编号	模块名称	模块编号			距离		
		A	B	C	CD↓	HD↓	P2Favg↓
1			✓	✓	0.649	9.695	2.756
2	PMA 模块	✓		✓	0.574	6.882	2.313
3		✓	✓		0.625	8.538	2.417
6	PMA-PU(本文)	✓	✓	✓	0.539	5.938	2.132

注:加粗字体为每列最优值,✓表示实验中使用此模块。




图 10 消融实验的定性结果

Fig. 10 Qualitative results of ablation experiments

4.6.2 特征拓展模块的消融实验

PMA-PU 在特征拓展模块使用边缘图卷积对特征提取输出的特征进行拓展。为了验证其有效性,将边缘图卷积中的有向边特征聚合去除。

表 5 的定性结果表明使用边缘图卷积拓展特征能使网络达到更好的效果,可视化结果如图 10 所示。

表 5 特征拓展器模块消融实验的定性结果

Table 5 Qualitative results of feature expander modules ablation experiments

实验编号	模块名称	距离		
		CD↓	HD↓	P2Favg↓
4	图卷积	0.601	6.755	2.419
6	边缘图卷积(本文)	0.539	5.938	2.132

4.6.3 坐标细化器的消融实验

表 6 中的结果表明,使用基于自注意力机制的坐标细化器变为四模块级联后,模型在所有指标上的表现都优于不使用细化器的三模块级联结构,HD 的量化表现提升尤其明显,提升了 11.18%,说明坐标细化器模块的加入对网络性能的优化有显著作用。可视化结果如图 10 所示,加入坐标细化器后输出的密集点云局部不会分布过于密集,密集点云分布更加均匀。

表 6 坐标细化器消融实验的定性结果

Table 6 Qualitative results of coordinate refiners ablation experiments

实验编号	损失函数	距离		
		CD↓	HD↓	P2Favg↓
5	无坐标细化器	0.540	6.686	2.167
6	PMA-PU(本文)	0.539	5.938	2.132

结束语 针对点云上采样网络中特征提取未考虑局部区域之间关联性以及特征信息利用不足导致生成点云异常值过多和细粒度不高的问题,提出了一种嵌入注意力机制的并行多尺度点云上采样网络。其中提出了新的特征提取模块 PMA,增加了并行图卷积的路径数量,每条路径使用不同 K 近邻扩张率的图卷积通道获取不同尺度的特征信息,扩大卷积层的感受野。路径中使用 RESGCN 实现多层训练,使图卷积训练层数加深。将自注意力模块与并行特征提取模块融合,自注意力模块能获取边缘特征区域之间的相关性,更好地提取局部区域特征信息。使用边缘图卷积拓展点云特征的特征拓展模块,获得的拓展特征很好地保留了点云边缘特征,使上采样后的点云更加平滑。最后加入基于自注意力机制的坐标细化器,精细地调整了粗点云的位置,构成了四模块级联的新结构。

实验结果表明,模型在合成数据集 PUIK 上的定量评价指标相比主流方法都取得了显著提升,定性的可视化结果更接近真实点云并且异常值更少。通过点云表面重建任务证明了本方法对点云下游任务的有效性。

参考文献

[1] XU S K, ZHANG L J, SHI L, et al. Few-shot 3D point cloud ob-

ject detection guided by Intention-attention[J]. Computer Engineering, doi:10.19678/j.issn.1000-3428.0068727.

- [2] YANG W K, YUAN X P, CHEN X F. Spatial Multi-feature Segmentation of 3D Lidar Point Cloud[J]. Computer Science, 2021, 49(8):143-149.
- [3] YU L Q, LI X Z, FU C W, et al. PU-Net: Point cloud upsampling network[C] // Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. 2018:2790-2799.
- [4] WANG Y F, WU S H, HUANG H, et al. Patch-based progressive 3d point set upsampling[C] // Proceedings of IEEE Conference on Computer Vision and Pattern Recognition. 2019:5958-5967.
- [5] QIAN G C, ABUALSHOUR A, LI G H, et al. PU-GCN: point cloud upsampling using graph convolutional networks[C] // Proceedings of IEEE/CVF Conference on Computer Vision and Pattern Recognition. 2021:11683-11692.
- [6] HAN B, ZHANG X Y, REN S. PU-GACNet: Graph Attention convolution Network for Point Cloud Upsampling[J]. Image and Vision Computing, 2022, 118:104371.
- [7] ALEXA M, BEHR J, COHEN-OR D, et al. Computing and rendering point set surfaces[J] IEEE Transactions on Visualization and Computer Graphics, 2003, 9(1):3-15.
- [8] FERSTL D, REINBACHER C, RANFTL R, et al. Image guided depth upsampling using anisotropic total generalized variation [C] // Proceedings of IEEE International Conference on Computer Vision. 2013:993-1000.
- [9] SCHUON S, THEOBALT C, DAVIS J, et al. High-quality scanning using time-of-flight depth super resolution[C] // 2008 IEEE Computer Society Conference on Computer Vision and Pattern Recognition Workshops. 2008:1-7.
- [10] QI C R, SU H, MO K C, et al. Pointnet: Deep learning on point sets for 3d classification and segmentation[C] // Proceeding of the IEEE Conference on Computer Vision and Pattern Recognition. 2017:652-660.
- [11] QI C R, LI Y, HAO S, et al. PointNet++: Deep Hierarchical Feature Learning on Point sets in a metric space[C] // Proceedings of the 31st International Conference on Neural Information Processing Systems. 2017:5105-5114.
- [12] LI R H, LI X Z, FU C W, et al. PU-GAN: a point cloud upsampling adversarial network[C] // Proceedings of IEEE/CVF International Conference on Computer Vision. 2019:7203-7212.
- [13] LI R H, LI X Z, HENG P A, et al. Point cloud upsampling via disentangled refinement[C] // Proceedings of IEEE/CVF Conference on Computer Vision and Pattern Recognition. 2021:344-353.
- [14] LIU H, YUAN H, HOU J, et al. PUFA-GAN: A Frequency-Aware Generative Adversarial Network for 3D point Cloud Upsampling[J]. IEEE Transactions on Image Processing, 2022, 31:7389-7402.
- [15] LIU H, YUAN H, HAMZAOU R, et al. PU-Refiner: A Geometry Refiner with Adversarial Learning for Point Cloud Upsampling[C] // IEEE International Conference on Acoustics, Speech and Signal Processing(ICASSP 2022). 2022:2270-2274.

- [16] LUO L Q, TANG L L, ZHOU W Y, et al. PU-EVA: an edge-vector based approximation solution for flexible-scale point cloud upsampling[C]//Proceedings of IEEE/CVF International Conference on Computer Vision. 2021:16208-16217.
- [17] ZHOU J, CUI G Q, HU S D, et al. Graph neural networks: a review of methods and applications[J]. AI Open, 2020, 1:57-81.
- [18] XU Y F, FAN T Q, XU M Y, et al. SpiderCNN: deep learning on point sets with parameterized convolutional filters[C]//Proceedings of European Conference on Computer Vision(ECCV). 2018:87-102.
- [19] MAO J, WANG X G, LI H S. Interpolated convolutional networks for 3d point cloud understanding [C] // Proceedings of IEEE/CVF International Conference on Computer Vision. 2019: 1578-1587.
- [20] WANG Y, SUN Y B, LIU Z W, et al. Dynamic graph cnn for learning on point clouds[J]. ACM Transactions on Graphics (ToG), 2019, 38(5):1-12.
- [21] LI G H, MÜLLER M, THABET A, et al. DeepGCNs: Can GCNs go as deep as CNNs? [C]//Proceedings of IEEE/CVF International Conference on Computer Vision. 2019:9267-9276.
- [22] KAZI A, SHEKARFOROUSH S, KRISHNA S A, et al. InceptionGCN: Receptive field aware graph convolutional network for disease prediction[C]//Proceedings of 26th International Conference on Medical Imaging. 2019:73-85.
- [23] WANG L, HUANG Y C, HOU Y L, et al. Graph attention convolution for point cloud semantic segmentation [C] // Proceedings of IEEE/CVF Conference on Computer Vision and Pattern Recognition. 2019:10296-10305.
- [24] VASWANI A, SHAZEER N, PARMAR N, et al. Attention is all you need[C]//Proceedings of the 31st International Conference on Neural Information Processing Systems. 2017: 6000-6010.
- [25] ZHONG F, BAI Z Y. 3D point cloud super resolution with dynamic residual graph convolution networks[J]. Journal of Zhejiang University (Engineering Science), 2022, 56 (11): 2251-2259.
- [26] LIU X H, LIU X C, LIU Y S, et al. SPU-Net: Self-Supervised Point Cloud Upsampling by Coarse-to-Fine Reconstruction With Self-Projection Optimization[J]. IEEE Transactions on Image Processing, 2022, 31:4213-4226.
- [27] CHANG A X, FUNKHOUSER T, GUIBAS L, et al. ShapeNet: An Information-Rich 3D Model Repository [J]. arXiv: 1512.03012, 2015.
- [28] WIEMANN T, MITSCHKE I, MOCK A, et al. Surface Reconstruction from Arbitrarily Large Point Clouds[C]//2018 Second IEEE International Conference on Robotic Computing (IRC). 2018:278-281.
- [29] HOPPE H. Poisson surface reconstruction and its applications [C]//Solid and Physical Modeling. 2008.



XIAO Xiao, born in 1999, postgraduate. His main research interests include three-dimensional reconstruction and 3D point cloud upsampling.



BAI Zhengyao, born in 1967, Ph.D, professor, master supervisor. His main research interests include signal processing, image processing, pattern recognition and machine learning, etc.

(责任编辑:何杨)