

## 基于注意力的多阶段点云补全网络

尹溪洋<sup>1</sup>, 周佩<sup>1,2</sup>, 朱江平<sup>1,2\*</sup><sup>1</sup>四川大学计算机学院, 四川 成都 610065;<sup>2</sup>四川大学视觉合成图形图像技术重点学科实验室, 四川 成都 610065

**摘要** 点云补全指利用不完整点云数据重建完整三维模型的过程。现有的大多数点云补全方法受点云无序性和不规则性影响,难以有效地重建局部细节信息,进而影响补全精度。为解决这个问题,提出基于注意力的多阶段点云补全网络。设计了满足置换不变性的金字塔式点云特征提取器以建立局部内点间的依赖以及不同局部间的相关性,在提取全局特征信息的同时加强对局部特征信息的提取。在点云重建过程中,采用由粗到精的方式,首先生成一个低分辨率的种子点云,然后逐步丰富种子点云的局部细节,得到更加精细且稠密的点云。在公开数据集 PCN 下进行的对比实验结果证明了所提网络能够有效重建局部细节信息,与现有方法相比,在补全精度上提升了至少 5.98%。消融实验结果也进一步验证了所提注意力模块的有效性。

**关键词** 点云; 点云补全; 自注意力; 交叉注意力; 几何细节感知

**中图分类号** TP242 **文献标志码** A

**DOI:** 10.3788/LOP231758

## Attention-Based Multi-Stage Network for Point Cloud Completion

Yin Xiyang<sup>1</sup>, Zhou Pei<sup>1,2</sup>, Zhu Jiangping<sup>1,2\*</sup><sup>1</sup>College of Computer Science, Sichuan University, Chengdu 610065, Sichuan, China;<sup>2</sup>National Key Laboratory of Fundamental Science on Synthetic Vision, Sichuan University, Chengdu 610065, Sichuan, China

**Abstract** Point cloud completion refers to the process for reconstructing a complete 3D model using incomplete point cloud data. Most of the existing point cloud completion methods are limited by the point cloud disorder and irregularity, which makes it difficult to reconstruct the local detail information, thus affecting the completion accuracy. To solve this problem, an attention-based multi-stage network for point cloud completion is proposed. A pyramid feature extractor that satisfies the replacement invariance is designed to establish the dependence between points within a localization as well as the correlation between different localizations, so as to enhance the extraction of local information while extracting global feature information. In the point cloud reconstruction process, a coarse-to-fine completion method is adopted to first generate a low-resolution seed point cloud, and then gradually enrich the local details of the seed point cloud to obtain a finer and denser point cloud. Comparison results of the experiments conducted on the public dataset PCN demonstrate that the proposed network can effectively reconstruct the local detail information, and improves the completion accuracy by at least 5.98% over the existing methods. The ablation experimental results also further validate the effectiveness of the designed attention module.

**Key words** point cloud; point cloud completion; self-attention; cross-attention; geometric details perception

## 1 引言

点云作为三维物体的一种存储格式,由于其强大的三维表征能力,已被广泛应用于逆向工程<sup>[1-2]</sup>、精密

制造<sup>[3]</sup>和医疗<sup>[4-5]</sup>等领域。然而,通过激光雷达或传感器扫描直接采集得到的点云通常是稀疏的、有噪声的,或者由于视角有限以及遮挡等原因,部分区域存在缺失问题<sup>[6]</sup>,限制了它们的应用范围。点云补全就是为

收稿日期: 2023-07-19; 修回日期: 2023-08-31; 录用日期: 2023-10-09; 网络首发日期: 2023-10-23

基金项目: 国家自然科学基金(62101364,61901287)、四川省中央引导地方科技发展计划(22ZYD0111)、中国博士后科学基金(2021M692260)、四川省重大科技专项(2021YFG0195,2022YFG0053)

通信作者: \*zjp16@scu.edu.cn

了解决上述问题,尝试从不完整的三维物体模型中寻找或推测出完整且局部细节精细的三维形状。点云补全已经成为现实世界三维计算机视觉应用中的重要任务。

随着点云数据集的丰富<sup>[7]</sup>,基于深度学习的点云补全方法得到了进一步研究。由于点云数据本身是无序且不规则的,难以直接将二维图像上的卷积操作成功迁移到三维的点云数据上。一些工作<sup>[8-11]</sup>尝试将点云转换为规则的体素,然后对其使用三维卷积操作。然而,从点云到体素的转换存在量化问题,容易导致几何细节信息的丢失。Charles 等<sup>[12]</sup>提出 PointNet,首先利用多层感知机(MLP)分别提取每个点的特征,随后使用对称的池化操作聚合点云的特征信息。尽管池化操作对于输入来说满足了置换不变性,但是也会不可避免地损失部分特征信息。在 PointNet 之后,许多方法<sup>[13-22]</sup>直接利用点云数据进行预测,这些方法分为基于折叠的方法和基于由粗到精的方法。基于折叠的方法假设三维点云可以由其他形状转化而来。Liu 等<sup>[14]</sup>提出了两阶段点云生成方法,并假设三维点云可以由二维平面折叠而来。Tchapmi 等<sup>[13]</sup>提出的 TopNet 将点云的生成过程模拟为有根树的生长过程,即一个根节点的特征可以投影到多个子节点中。然而,这些方法生成的中间特征向量是隐式的,难以应用特定规则加以限制。不同于基于折叠的方法,基于由粗到精的方法采用可控的方式指引点云补全的方向。Yuan 等<sup>[6]</sup>提出两阶段的 PCN(point completion network),在第一阶段生成稀疏、粗糙的点云,在第二阶段逐步提高点云分辨率。Wang 等<sup>[19]</sup>提出 CRN(cascaded

refinement network),通过增加点云的上采样次数提高补全精度。然而,这些方法在提取特征部分时都采用 PointNet 式的特征提取器,着重于捕捉点云的全局形状信息,忽略了点云的局部几何和结构信息,进而影响到后续重建过程的局部细节质量。

为解决以上提到的问题,本文提出基于注意力的多阶段点云补全网络(AMCNet)。首先,设计了新型的金字塔式特征提取器。该特征提取器使用自注意力模块和交叉注意力模块提取点云的特征向量,注意力模块的置换不变性可以有效地解决点云无序性带来的问题,此外,注意力模块长距离依赖的建模能力也能帮助网络保留更多的局部几何信息和结构信息。然后,在点云重建的过程中,设计了一种倒 Transformer 结构<sup>[23]</sup>的精细点云生成器,用于多阶段的局部细节补全,以建立不同分辨率点云间局部上下文和空间上的联系,增强同一分辨率点云中不同块间的语义相关性,进而提高局部细节补全的质量。

## 2 基本原理

图 1 是所提 AMCNet 的整体框架,其中: $N$ 为输入点云分辨率大小; $C_i$ 为不同阶段特征向量的维度大小; $N_i$ 为不同阶段特征向量的尺度大小; $N_s$ 为种子点云的尺度大小; $\mu$ 为放大比例。该网络由金字塔式特征提取器、种子点云生成器以及精细点云生成器三部分组成。首先,通过金字塔式特征提取器捕捉输入点云数据的全局特征以及局部特征。然后,利用种子点云生成器根据全局特征生成一个具有完整轮廓的稀疏点云。最后,利用精细点云生成器逐步提高点云的分辨率。

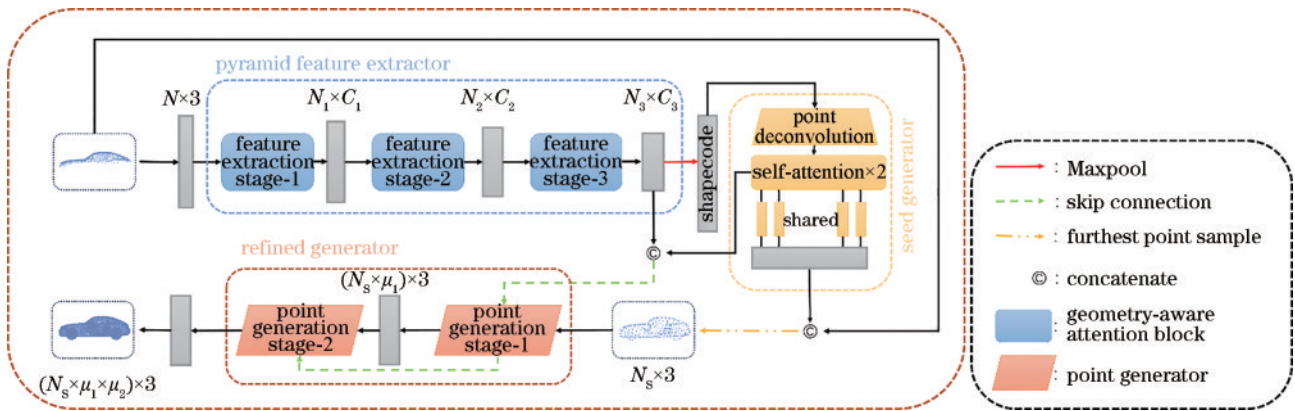


图 1 AMCNet 的总体结构

Fig. 1 Overall architecture of AMCNet

### 2.1 金字塔式特征提取器

金字塔式特征提取器的目标是提取包含全局形状特征和局部细节特征的形状码。PointNet<sup>[12]</sup>通过最大池化操作可以简单有效地聚合全局特征,然而会丢失很大一部分局部信息。Charles 等<sup>[24]</sup>提出 PointNet++ 分层融合方法,将点云划分为若干子集,并从每个子集中的点中提取特征,然后将这些特征组合起来形成全

局特征。虽然 PointNet++<sup>[24]</sup>在一定程度上解决了局部特征丢失的问题,但它忽略了局部特征之间的相关性。为充分利用输入点云的几何信息和结构信息,提出了一种基于注意力的金字塔式特征提取器,由三个几何感知注意力模块(GAB)组成,在提取输入点云的全局特征信息的同时增强点云局部特征之间的联系。在本实验中,输入点云只包含三维坐标,大小为

$P_{in} \in \mathbf{R}^{N \times 3}$ , 其中  $N = 2048$ 。在将点云输入金字塔式特征提取器前, 利用最远点采样和 K-近邻算法对输入点云进行分块, 共划分为  $N/\lambda$  块 ( $\lambda$  为分割后每个点云块的大小), 便于后续局部信息的聚合, 同时减少注意力模块的计算复杂度 (图 2)。分块后的点云首先通过一个包含两个全连接 (FC) 层、以 GeLU 作为激活函数的 MLP, MLP 将三维坐标  $P_{in} \in \mathbf{R}^{N \times 3}$  映射到高维特征空

间  $\mathbf{R}^{N \times 64}$ 。然后, 利用 GAB 建立点间和块间的相关性, 逐步下采样得到特征向量  $F \in \mathbf{R}^{128 \times 512}$ 。最后, 对特征向量使用全局最大池化得到关于原始点云的形状码  $F_g \in \mathbf{R}^{512 \times 1}$ , 计算公式表示为

$$F_g = \text{MP}\{\text{GAB}[\text{MLP}(P_{in})]\}, \quad (1)$$

式中:  $\text{MP}(\cdot)$  表示最大池化操作;  $\text{GAB}(\cdot)$  表示 GAB 执行的操作;  $\text{MLP}(\cdot)$  表示 MLP 操作。




图 2 金字塔式特征提取器中局部特征的聚合示意图

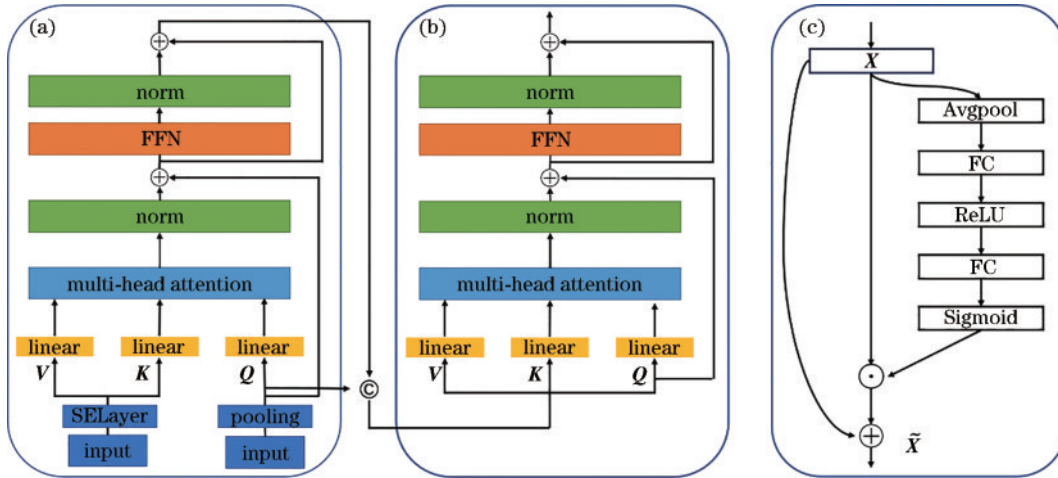
Fig. 2 Illustration of the aggregation of local features in pyramid feature extractor

GAB 的结构如图 3 所示。GAB 采用倒 Transformer 结构, 将交叉注意力模块置于自注意力模块之前。在下采样过程中, 首先使用交叉注意力模块建立不同阶段点云特征之间的相关性, 以实现特征自上而下的传递。然后, 使用自注意力模块增强点间和块间的长距离依赖, 以提高特征向量对局部信息的表征能力。同时为降低注意力模块的计算复杂度 (注意力模块的复杂度与输入序列长度的平方正相关), 在执行注意力模

块之前使用最大池化缩短序列长度并聚合局部信息。在金字塔式特征提取器中, 三个缩放因子  $\lambda_1$ 、 $\lambda_2$  和  $\lambda_3$  满足

$$\lambda_1 \times \lambda_2 \times \lambda_3 = \lambda. \quad (2)$$

由于交叉注意力模块和自注意力模块仅关注空间域上的信息, 因此在交叉注意力模块之前引入压缩激励层 (SELayer)<sup>[25]</sup>, 用于增强通道域上的关键特征。SELayer 的计算公式表示为



FC: fully connect; FFN: feed forward network

图 3 GAB。(a)改进交叉注意力模块;(b)自注意力模块;(c)通道注意力 SELayer 模块 ( $\oplus$  表示按位加,  $\odot$  表示哈达玛乘积)

Fig. 3 GAB. (a) Improved cross-attention module; (b) self-attention module; (c) channel attention SELayer module ( $\oplus$  denotes element-wise addition and  $\odot$  denotes Hadamard product)

$$\tilde{X} = X + X \times \text{Sigmoid}\{\text{MLP}[\text{AP}(X)]\}, \quad (3)$$

式中:  $X$  表示输入特征;  $\text{AP}(\cdot)$  表示全局平均池化操作;  $\text{Sigmoid}(\cdot)$  表示 Sigmoid 激活函数。改进后交叉注意力模块的计算公式为

$$(Q, K, V) = [\text{MP}(F) \times W_q, \text{SE}(F) \times W_k, \text{SE}(F) \times W_v], \quad (4)$$

$$\text{Attention}(Q, K, V) = \text{Softmax}(Q \cdot K^T) \cdot V, \quad (5)$$



$$\mathbf{Q} \in \mathbf{R}^{\frac{N}{k_i} \times C}, \mathbf{K}, \mathbf{V} \in \mathbf{R}^{N \times C}, \quad (6)$$

式中: $\mathbf{Q}, \mathbf{K}, \mathbf{V}$ 分别为查询向量、键向量和值向量; $\text{SE}(\cdot)$ 表示通道注意力模块执行的操作; $\text{Attention}(\cdot)$ 表示空间注意力模块执行的操作; $\text{Softmax}(\cdot)$ 表示 Softmax 函数; $\mathbf{W}_q, \mathbf{W}_k$ 和 $\mathbf{W}_v$ 表示可学习的线性投影矩阵。

## 2.2 种子点云生成器

种子点云生成器的任务是根据输入点云的形状码生成一个稀疏但具有完整轮廓的种子点云。种子点云生成器的结构如图 1 右边虚线框所示,由点的反卷积模块和自注意力模块组成。首先,通过一个具有三个 FC 层和 GeLU 激活函数的反卷积模块将输入点云形状码转换为粗糙点云的特征向量。然后,通过两个级联的自注意力模块逐步增强特征向量的表征能力。最后,将增强表征能力后的特征向量通过权值共享的 MLP 和 reshape 操作转换为粗糙点云 $\mathbf{P}_c \in \mathbf{R}^{128 \times 3}$ 。生成的粗糙点云存在几何信息缺失或密度分布不均等问题,为解决这些问题,将原始输入点云 $\mathbf{P}_m$ 与粗糙点云 $\mathbf{P}_c$ 进行融合,然后利用最远点采样法对融合后的点云进行采样,得到种子点云 $\mathbf{P}_s \in \mathbf{R}^{512 \times 3}$ ,并将其作为精细点云生成器的输入。

## 2.3 精细点云生成器

精细点云生成器的目的是逐步提高点云的分辨

率,在保持点云原有整体结构的基础上丰富局部细节。精细点云的生成分为两阶段,采用由粗到精的补全方式,由两个点云生成器组成,点云生成器的结构如图 4 所示。点云生成器的输入为上一层的输出点云 $\mathbf{P}_{i-1}$ 及其特征向量 $\mathbf{F}_{i-1}$ 。在第一阶段,输入特征向量会额外融合原始输入点云的特征向量,融合后的特征向量可以有效地表征完整点云的几何信息和结构信息。点云生成器的网络结构设计 with GAB 相似,都采用倒 Transformer 结构,而在点云生成器中移除交叉注意力模块前的池化操作,避免信息的损失。在细节上,输入点云 $\mathbf{P}_{i-1}$ 首先通过一个具有三个 FC 层、采用 GeLU 作为激活函数的 MLP,MLP 将三维坐标 $\mathbf{P}_{i-1} \in \mathbf{R}^{N_{i-1} \times 3}$ 映射到与输入特征向量相同的特征空间 $\mathbf{R}^{N_{i-1} \times C}$ ,生成当前阶段点云的特征向量 $\mathbf{F}_i$ 。随后,通过交叉注意力模块和自注意力模块分别完成不同阶段特征之间的信息交换和当前阶段特征的信息增强。最后得到更高分辨率的点云 $\mathbf{P}_i$ 。该过程表示为

$$\begin{cases} \mathbf{F}_i = \text{SA} \left\{ \text{CA} \left[ \text{MLP}(\mathbf{P}_{i-1}), \mathbf{F}_{i-1} \right] \right\}, \\ \mathbf{P}_i = \mathbf{P}_{i-1} + \text{MLP}(\mathbf{F}_i) \end{cases}, \quad (7)$$

式中: $\text{SA}(\cdot)$ 为自注意力模块中执行的操作; $\text{CA}(\cdot)$ 为交叉注意力模块中执行的操作。

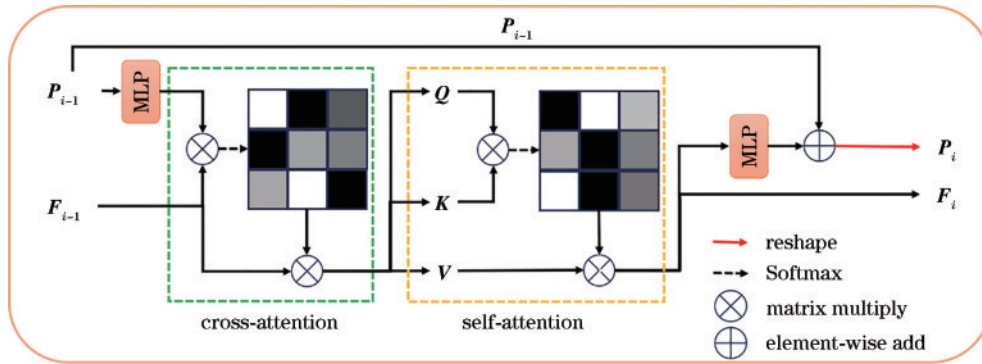


图 4 点云生成器结构

Fig. 4 Structure of the point generator

## 2.4 损失函数

使用倒角距离(CD)作为 AMCNet 的损失函数。CD 可以衡量两个点云的平均最短距离,表示为

$$d_{\text{CD}}(\mathbf{P}, \mathbf{T}) = \frac{1}{|\mathbf{P}|} \sum_{\mathbf{x} \in \mathbf{P}} \min_{\mathbf{y} \in \mathbf{T}} \|\mathbf{x} - \mathbf{y}\|_2^2 + \frac{1}{|\mathbf{T}|} \sum_{\mathbf{y} \in \mathbf{T}} \min_{\mathbf{x} \in \mathbf{P}} \|\mathbf{y} - \mathbf{x}\|_2^2, \quad (8)$$

式中: $\mathbf{P}$ 和 $\mathbf{T}$ 分别为预测点云和真值点云; $\|\cdot\|_2^2$ 表示二范数的平方。在点云重建时采用由粗到精的方式,对于每一个输入点云都分别生成三个分辨率大小为 512、2048、16384 的点云。AMCNet 的损失函数为三个生成点云与其对应大小真值点云的 CD 之和,表示为

$$\mathcal{L} = \sum_{i=1}^3 \alpha_i d_{\text{CD}}(\mathbf{P}_i, \mathbf{T}_i), \quad (9)$$

式中, $\alpha_i$ 表示 $\mathbf{P}_i$ 对应的权重系数,本文中 $\alpha_1 = \alpha_2 = \alpha_3 = 1$ 。

## 3 分析与讨论

### 3.1 数据集与实现细节

在 PCN 数据集<sup>[6]</sup>上验证所提网络的性能。PCN 数据集有 8 个类别,分别是飞机、橱柜、汽车、椅子、台灯、沙发、桌子和轮船,共 30974 个模型。其中,不完整点云是通过将完整模型投影到 8 个不同视图中生成得到的,每个不完整点云的分辨率小于 2048,对应的真值点云分辨率为 16384(通过对完整模型表面进行均匀采样而得)。为进行公平比较,实验沿用网络 PCN<sup>[6]</sup>中相同的数据分割方法,并利用 CD 值来评估补全结果,CD 值越小表明补全精度越高。

所提网络利用 PyTorch 1. 10. 1 实现, 在 NVIDIA RTX 3090 图形处理器(GPU)上进行训练。训练过程中, 使用 Adam 作为优化器, 初始学习率设置为 0. 001, 采用固定步长的方式调整学习率, 步长为 40, 衰减指数为 0. 7, 网络的迭代次数为 400 轮。

### 3. 2 实 验

为评估网络的性能, 在同一测试集上与以下点云补全网络进行定量和定性对比: FoldingNet<sup>[18]</sup>、PCN<sup>[6]</sup>、GRNet<sup>[11]</sup>、PMP-Net<sup>[15]</sup>、PoinTr<sup>[20]</sup>、SnowflakeNet<sup>[16]</sup>和 PointAttN<sup>[17]</sup>。定量结果如表 1 所示(将所有计算后的 CD 放大 1000 倍, 方便进行比较)。与其他网络相比, 所提网络在平均补全精度上取得了最好的结果。与排名第二的 PointAttN<sup>[17]</sup>相比, 所提网络的平均 CD 值减少了 0. 41, 相对减少了 5. 98%(6. 45 vs 6. 86)。同时, 所提网络在所有类别上的补全结果也都取得了最小的

CD 值, 表明所提网络在补全不同类别模型时具有更好的泛化性能。与 SnowflakeNet<sup>[16]</sup>和 PointAttN<sup>[17]</sup>这两种采用由粗到精点云补全方法的网络相比, 所提网络在 PCN 数据集上的补全精度更高, 表明 GAB 可以帮助网络提取原始输入点云的局部几何信息; 精细点云生成器中的倒 Transformer 结构通过建立不同阶段点云间的联系可以生成拥有更丰富局部细节的点云。图 5 为 8 个类别的可视化补全结果, 可以明显看出, 所提网络可以生成更精细的完整点云。例如: 在橱柜类别中, 使用所提网络生成的点云橱柜顶部更加平滑; 在船类中, 使用所提网络在桅杆处生成的点云具有更少的噪点。图 6 为椅子补全结果的局部放大图, 可以看出, 相比于 GRNet、SnowflakeNet 和 PointAttN, 所提 AMCNet 可以补全更多的几何细节信息, 比如: 棱角更加分明、噪点更少(实线框)、表面更加平滑(虚线框)。

表 1 在 PCN 数据集上的 CD 点云补全对比结果 (越小越好)

Table 1 Point cloud completion comparison on PCN dataset in terms of CD (lower is better)

Model	CD / 10 <sup>3</sup>								
	Average	Plane	Cabinet	Car	Chair	Lamp	Couch	Table	Boat
FoldingNet	14. 31	9. 49	15. 80	12. 61	15. 55	16. 41	15. 97	13. 65	14. 99
PCN	9. 64	5. 50	22. 70	10. 63	8. 70	11. 00	11. 34	11. 68	8. 59
GRNet	8. 83	6. 45	10. 37	9. 45	9. 41	7. 96	10. 51	5. 44	8. 04
PMP-Net	8. 73	5. 65	11. 24	9. 64	9. 51	6. 95	10. 83	8. 72	7. 25
PoinTr	8. 38	4. 75	10. 47	8. 68	9. 39	7. 75	10. 93	7. 75	7. 29
SnowflakeNet	7. 21	4. 29	9. 16	8. 08	7. 89	6. 07	9. 23	6. 55	6. 40
PointAttN	6. 86	3. 87	9. 00	7. 63	7. 43	5. 90	8. 68	6. 32	6. 09
Ours	<b>6. 45</b>	<b>3. 58</b>	<b>8. 74</b>	<b>7. 36</b>	<b>6. 86</b>	<b>5. 28</b>	<b>8. 32</b>	<b>5. 88</b>	<b>5. 69</b>




图 5 不同网络在 PCN 数据集上的补全结果可视化

Fig. 5 Visualization of completion results of different networks on PCN dataset




图 6 不同网络对椅子类别的补全结果可视化

Fig. 6 Visualization of completion results of different networks in terms of the chair class

为验证所提网络在点云分辨率改变的条件(尤其是在稀疏点云的条件下)是否具有鲁棒性,选取输入分辨率为 256、512、1024、2048 的点云分别进行实验。对于少于 2048 个点的点云,从输入点云中随机选取一定数量的点进行复制,组成 2048 个点。不同分辨率下的补全结果如表 2 所示,同时将不同分辨率下汽车和飞机的补全结果进行可视化,如图 7 所示。可以看出,

随着输入点云分辨率的改变,补全后的结果在定性和定量方面都无剧烈变化,说明所提网络在不同分辨率下具有鲁棒性。

表 2 输入点云分辨率大小的影响

Resolution	2048	1024	512	256
CD	6.45	6.54	6.66	7.23

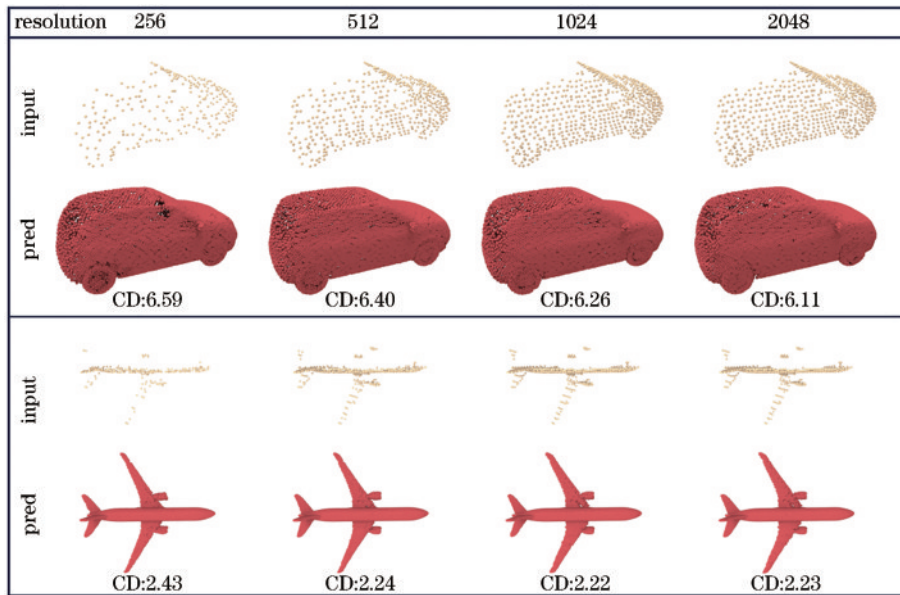


图 7 不同输入分辨率下的补全结果可视化

Fig. 7 Visualization of completion results at different resolutions of input

为评估不同点云分块大小对补全精度的影响,在分块大小为 16、32、64 的条件下进行实验,结果如表 3 所示。图 8 为可视化后的不同分块大小的点云补全结果。当分块大小  $K=16$  时,分块的划分不明显。 $K=32$  和  $K=64$  的划分结果相似,表明当  $K$  过大时,分块之间会发生重叠,影响后续的特征提取。

表 3 点云分块大小的影响

Table 3 Effect of point cloud block size

Size	$K=16$	$K=32$	$K=64$
CD	6.48	6.45	6.47

### 3.3 消融实验

最后,为 AMCNet 设计了三个变体模型用于评估注意力模块的有效性。1)模型 A 移除 GAB 中的通道




图 8 不同点云分块大小的补全结果可视化

Fig. 8 Visualization of completion results of different point cloud block size

注意力模块和补全阶段一中输入点云特征向量的跳跃连接;2)模型 B 只移除跳跃连接;3)模型 C 只移除通道注意力模块。定量结果如表 4 所示,可以看出:模型 B



表 4 注意力模块的影响

Table 4 Effect of attention module

Model	SELayer	Skip connection	CD
A			6.61
B	✓		6.58
C		✓	6.49
AMCNet	✓	✓	6.45

的补全精度低于模型 A,说明通道注意力模块有助于网络提取点云的几何特征与结构特征;同时,从模型 A 到模型 C,补全精度有着明显提升,说明结合跳跃连接,精细点云生成器可以生成具有更多局部细节的高分辨率点云。

## 4 结 论

针对点云补全难以恢复局部细节,影响补全精度的问题,提出了 AMCNet。通过金字塔式特征提取器,AMCNet 可以有效地捕捉输入点云中局部区域的潜在特征,并用于后续的点云重建。为生成更加平滑、棱角分明的点云,进一步提出精细点云生成器,在保持稀疏点云原有的全局特征的同时丰富其局部细节信息。实验结果表明,AMCNet 的补全结果就局部细节信息与补全精度而言优于其他现有方法。但是所提网络仍然存在不足之处,比如点云分块受密度分布的影响和注意力模块无法适用于大规模点云数据等问题,在未来工作中有望得到进一步解决。

## 参 考 文 献

- [1] Sun J K, Yang Z H, Li F F, et al. Projected feature assisted coarse to fine point cloud registration method for large-size 3D measurement[J]. *Optics Express*, 2023, 31(11): 18379-18398.
- [2] Chen B W, Shi S, Sun J, et al. Hyperspectral lidar point cloud segmentation based on geometric and spectral information[J]. *Optics Express*, 2019, 27(17): 24043-24059.
- [3] Feng W, Qu T, Gao J H, et al. 3D reconstruction of structured light fields based on point cloud adaptive repair for highly reflective surfaces[J]. *Applied Optics*, 2021, 60(24): 7086-7093.
- [4] Wang G, Le N M, Hu X H, et al. Semi-automated registration and segmentation for gingival tissue volume measurement on 3D OCT images[J]. *Biomedical Optics Express*, 2020, 11(8): 4536-4547.
- [5] Liang B Y, Wang S M, Shen F, et al. Acoustic impact of the human skull on transcranial photoacoustic imaging [J]. *Biomedical Optics Express*, 2021, 12(3): 1512-1528.
- [6] Yuan W T, Khot T, Held D, et al. PCN: point completion network[C]//2018 International Conference on 3D Vision (3DV), September 5-8, 2018, Verona, Italy. New York: IEEE Press, 2018: 728-737.
- [7] Chang A X, Funkhouser T, Guibas L, et al. ShapeNet: an information-rich 3D model repository[EB/OL]. (2015-12-09)[2023-06-05]. <https://arxiv.org/abs/1512.03012>.

- [8] Dai A, Charles R Q, Nießner M. Shape completion using 3D-encoder-predictor CNNs and shape synthesis [C]//2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), July 21-26, 2017, Honolulu, HI, USA. New York: IEEE Press, 2017: 6545-6554.
- [9] Han X G, Li Z, Huang H B, et al. High-resolution shape completion using deep neural networks for global structure and local geometry inference[C]//2017 IEEE International Conference on Computer Vision (ICCV), October 22-29, 2017, Venice, Italy. New York: IEEE Press, 2017: 85-93.
- [10] Sharma A, Grau O, Fritz M. VConv-DAE: deep volumetric shape learning without object labels[M]//Hua G, Jégou H. Computer vision-ECCV 2016 workshops. Lecture notes in computer science. Cham: Springer International Publishing, 2016, 9915: 236-250.
- [11] Xie H Z, Yao H X, Zhou S C, et al. GRNet: gridding residual network for dense point cloud completion[M]//Ferrari V, Hebert M, Sminchisescu C, et al. Computer vision-ECCV 2018. Lecture notes in computer science. Cham: Springer, 2020, 12345: 365-381.
- [12] 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 (CVPR), July 21-26, 2017, Honolulu, HI, USA. New York: IEEE Press, 2017: 77-85.
- [13] Tchapmi L P, Kosaraju V, Rezatofighi H, et al. TopNet: structural point cloud decoder[C]//2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), June 15-20, 2019, Long Beach, CA, USA. New York: IEEE Press, 2020: 383-392.
- [14] Liu M H, Sheng L, Yang S, et al. Morphing and sampling network for dense point cloud completion[J]. *Proceedings of the AAAI Conference on Artificial Intelligence*, 2020, 34(7): 11596-11603.
- [15] Wen X, Xiang P, Han Z Z, et al. PMP-Net: point cloud completion by learning multi-step point moving paths [C]//2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), June 20-25, 2021, Nashville, TN, USA. New York: IEEE Press, 2021: 7439-7448.
- [16] Xiang P, Wen X, Liu Y S, et al. SnowflakeNet: point cloud completion by snowflake point deconvolution with skip-transformer[C]//2021 IEEE/CVF International Conference on Computer Vision (ICCV), October 10-17, 2021, Montreal, QC, Canada. New York: IEEE Press, 2022: 5479-5489.
- [17] Wang J, Cui Y, Guo D Y, et al. PointAttN: You only need attention for point cloud completion[EB/OL]. (2022-03-16)[2023-04-05]. <https://arxiv.org/abs/2203.08485>.
- [18] Yang Y Q, Feng C, Shen Y R, et al. FoldingNet: point cloud auto-encoder via deep grid deformation[C]//2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition, June 18-23, 2018, Salt Lake City, UT, USA. New York: IEEE Press, 2018: 206-215.

- [19] Wang X G, Ang M H, Lee G H. Cascaded refinement network for point cloud completion[C]//2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), June 13-19, 2020, Seattle, WA, USA. New York: IEEE Press, 2020: 787-796.
- [20] Yu X M, Rao Y M, Wang Z Y, et al. PoinTr: diverse point cloud completion with geometry-aware transformers [C]//2021 IEEE/CVF International Conference on Computer Vision (ICCV), October 10-17, 2021, Montreal, QC, Canada. New York: IEEE Press, 2022: 12478-12487.
- [21] 高辉, 杨志景, 凌永权, 等. 基于多编码器和 Residual-Transformer 的点云补全网络[J]. 激光与光电子学进展, 2023, 60(2): 0210012.  
Gao H, Yang Z J, Ling Y Q, et al. Point cloud completion network based on multienoders and residual-transformer[J]. Laser & Optoelectronics Progress, 2023, 60(2): 0210012.
- [22] 罗开乾, 朱江平, 周佩, 等. 基于多分支结构的点云补全网络[J]. 激光与光电子学进展, 2020, 57(24): 241019.
- [23] Luo K Q, Zhu J P, Zhou P, et al. Point cloud completion network based on multibranch structure [J]. Laser & Optoelectronics Progress, 2020, 57(24): 241019.
- [23] 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, December 4-9, 2017, Long Beach, California, USA. New York: ACM, 2017: 6000-6010.
- [24] Charles R Q, Yi L, Su H, et al. PointNet++: deep hierarchical feature learning on point sets in a metric space [EB/OL]. (2017-06-07)[2023-05-06]. <https://arxiv.org/abs/1706.02413>.
- [25] Hu J, Shen L, Sun G. Squeeze-and-excitation networks [C]//2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition, June 18-23, 2018, Salt Lake City, UT, USA. New York: IEEE Press, 2018: 7132-7141.