

中图法分类号: TP37 文献标识码: A 文章编号: 1006-8961(2026)03-0686-33

论文引用格式: Zhan J, Xu F, Shi Y Z and Ma K G. 2026. Review of deep learning-based 3d point cloud upsampling algorithms. Journal of Image and Graphics, 31(3):0686-0718(詹杰, 徐帆, 时逸舟, 马凯光. 2026. 深度学习三维点云上采样算法综述. 中国图象图形学报, 31(3):0686-0718)
[DOI:10. 11834/jig. 250314]

深度学习三维点云上采样算法综述

詹杰, 徐帆*, 时逸舟, 马凯光

南京航空航天大学电子信息工程学院, 南京 211100

摘要: 随着3D扫描技术和激光雷达等设备的普及,点云数据在自动驾驶、机器人感知以及文化遗产数字化保存等领域得到广泛应用。然而,受测量设备分辨率、环境遮挡及材质反射特性等因素限制,原始点云数据通常存在密度不均、细节缺失等问题,严重制约了其在目标检测、语义分割等下游任务中的性能表现。点云上采样技术旨在通过智能算法将低分辨率点云数据重建为高密度、均匀分布的三维点云,以恢复物体表面的精细几何结构。深度学习技术的迅猛发展为点云上采样提供了新的解决方案,极大地提升了点云数据的质量和可用性。本文全面综述了基于深度学习的点云上采样技术,分析了传统几何方法的局限性,并提出一种层次化分类框架,将深度学习方法划分为监督式与无监督式两大类。监督式方法进一步细分为三段式、生成式、几何扩充—坐标优化及表面重建式4种主要范式;无监督式方法则从不同角度利用稀疏点云的内在信息或变换生成监督信号,摆脱了对配对密集点云的依赖。本文还系统整理了该领域的基准数据集与评估指标,并通过对比实验展示了代表性方法的性能表现。最后,总结了当前技术瓶颈,并对未来研究方向进行了展望,为三维视觉领域的研究者提供了重要参考。

关键词: 深度学习; 三维视觉; 点云上采样; 生成模型; 表面重建; 无监督学习

Review of deep learning-based 3D point cloud upsampling algorithms

Zhan Jie, Xu Fan*, Shi Yizhou, Ma Kaiguang

School of Electronic and Information Engineering, Nanjing University of Aeronautics and Astronautics, Nanjing 211100, China

Abstract: The widespread adoption of 3D scanning technologies and LiDAR systems has established point clouds as a critical data modality for mission-critical applications, including autonomous driving, robotic environmental perception, and digital archiving of cultural heritage. However, limitations in acquisition devices, combined with challenges such as environmental occlusion and surface material reflectivity, often result in sparse density, non-uniform distribution, and reduced geometric fidelity of raw point cloud data. These deficiencies significantly impair performance in downstream tasks, such as 3D object detection and semantic segmentation. Point cloud upsampling mitigates these challenges by employing advanced algorithms to transform low-resolution inputs into high-density, uniformly distributed 3D point sets, thereby restoring fine-grained geometric structures of object surfaces. Advancements in deep learning have significantly enhanced the quality and practical utility of point cloud data in this domain. This survey systematically reviews advancements in deep

收稿日期: 2025-07-21; 修回日期: 2025-09-30; 预印本日期: 2025-10-07

* 通信作者: 徐帆 xufan@nuaa.edu.cn

基金项目: 国家重大科研仪器研制项目(62427801); 江苏省前沿引领技术基础研究项目(BK20232030); 航空科学基金项目(2023Z019052001); 江苏省博士后科研资助计划项目(2021K087A)

Supported by: National Major Scientific Instruments and Equipment Development Project of NSFC(62427801); Frontier Leading Technology Basic Research Project of Jiangsu Province(BK20232030); Aeronautical Science Foundation of China(2023Z019052001); Jiangsu Planned Projects for Post-doctoral Research Funds(2021K087A)

learning-based point cloud upsampling methods from 2018 to mid-2025. We categorize existing deep learning approaches into two primary paradigms on the basis of their training methodology: supervised and unsupervised learning. Supervised methods rely on high-quality paired training datasets to enable end-to-end learning of dense point cloud representations. Within this supervised domain, we analyze four key methodological paradigms on the basis of their operational principles. The three-stage upsampling paradigm, pioneered by PU-Net, decomposes the task into sequential phases: feature extraction using architectures like PointNet, GCNs, or Transformers; feature expansion via techniques such as duplication/folding, PixelShuffle-inspired mechanisms such as NodeShuffle, or novel kernel-to-displacement approaches; and coordinate reconstruction through direct regression or offset prediction, often enhanced by geometric correction modules. This paradigm is straightforward and widely adopted but struggles with arbitrary upsampling ratios and limitations in coordinate prediction accuracy. The geometry expansion-coordinate optimization paradigm, exemplified by methods such as Grad-PU, TP-NoDe, and ND-PUFlow, decouples the process. It first increases the point count in the geometric space via midpoint interpolation or density-aware noise addition to achieve any desired upsampling ratio, producing an intermediate point set; a subsequent coordinate optimization network refines these points to align precisely with the target surface. This approach supports arbitrary ratios but requires careful handling of potential artifacts, such as abnormal points or surface shrinkage. Generative models, leveraging frameworks such as generative adversarial networks, normalizing flows, and diffusion models, focus on learning the underlying distribution of dense point clouds, offering greater flexibility in generating high-fidelity results, though often at the cost of increased computational complexity and intricate hyperparameter tuning. Surface reconstruction-based methods, such as PUGeo-Net, Neural Points, PU-SDF, and APU-LDI, conceptualize upsampling as a two-step process, first involving the reconstruction of a continuous surface representation explicitly through parametric surfaces or voxel grids or implicitly via neural fields, occupancy fields, signed distance field, or unsigned distance field from the sparse input and then resampling this surface to generate the dense output. This strategy typically ensures superior geometric consistency and surface fidelity. By contrast, unsupervised methodologies reduce reliance on large-scale, meticulously labeled datasets by exploiting the intrinsic geometric structure of the input point cloud to derive supervision signals or by designing sophisticated self-supervised learning tasks. We categorize these strategies into four classes on the basis of their core mechanisms for generating training guidance: utilizing sparse point cloud for supervision, exemplified by L2G-AE, SSAS, and SPU-PMD; transforming sparse point clouds for supervision, represented by SSPU-Net, PPU, and SPU-IMR; constructing training data via downsampling sparse inputs, such as SPU-Net and ZSPU; and unsupervised point cloud upsampling based on the twin-network structure, including UPU-SNet and S³U-PVNet. This survey details key benchmark datasets essential for training and evaluation, including PU-GAN, the larger-scale PU1K, PUGeo (notable for including ground-truth normals), and real-world scanned datasets such as ScanObjectNN and KITTI, highlighting their characteristics and relevance. Furthermore, it explains standard evaluation metrics used to rigorously quantify performance, such as Chamfer distance, Hausdorff distance, and point-to-surface distance, emphasizing their roles in assessing reconstruction accuracy, surface proximity, and distribution uniformity. Comparative experimental results across these benchmarks are presented to illustrate the quantitative performance of representative state-of-the-art techniques. Several compelling research directions deserve attention. A key challenge is the development of adaptive arbitrary upsampling strategies that dynamically adjust the upsampling ratio on the basis of localized point density and geometric complexity, enabling precise enhancement where needed. Additionally, improving adaptability to complex topological structures, such as intricate edges, thin surfaces, and fine details, is critical. This task may be achieved through advanced feature extraction techniques inspired by point cloud classification and segmentation or by integrating multimodal data fusion with complementary sources such as RGB images or depth sequences. Addressing computational efficiency and real-time performance constraints is essential for practical deployment in latency-sensitive scenarios, such as autonomous navigation, requiring innovations in network architecture optimization, model simplification, and lightweight design. Finally, advancing robust unsupervised and self-supervised learning frameworks promises to significantly reduce reliance on costly labeled data, leveraging inherent geometric properties and novel pretext tasks to improve model generalization across diverse and challenging real-world environments.

Key words: deep learning; 3D vision; point cloud upsampling; generative models; surface reconstruction; unsupervised learning

0 引言

点云作为三维空间离散采样的直接表征形式,通过无序点集精确记录物体表面的几何特征,已成为自动驾驶(陈妍妍等,2024)、机器人感知(刘坤等,2024)等领域的核心数据载体。然而,由于传感器分辨率限制、环境遮挡以及材质反光等因素,原始点云数据普遍存在密度稀疏、分布不均和细节缺失等固有缺陷。如图1所示,KITTI(Karlsruhe Institute of Technology and Toyota Technological Institute at Chicago)(Geiger等,2013)数据集中的典型室外道路场景点云(包含多角度扫描的车辆、行人及街道等目标)直观地展现了这些技术挑战。这些问题不仅降低了点云数据的表征精度,更严重制约了其在目标检测(贾明达等,2024)、语义分割(朱仲杰等,2024c)等下游任务中的性能表现。为此,点云上采样技术应运而生,该技术通过深度学习等智能算法,在保持原始几何特征的前提下,通过新增采样点的方式提升点云密度、优化点云分布,从而有效恢复物体表面的精细几何结构。这一技术突破不仅提升了点云数据的质量,更为下游任务的性能优化提供了关键支撑,在三维视觉领域具有重要的研究价值和应用前景。




图1 KITTI数据集的真实场景示例

Fig. 1 Real-world examples from the KITTI dataset

早期点云上采样研究主要依托几何先验与优化理论。Alexa等人(2003)提出移动最小二乘投影(moving least squares, MLS),通过局部多项式拟合构建隐式曲面,为点云重采样奠定了数学基础。Lipman等人(2007)引入局部最优投影算子(local optimal projection, LOP),利用中位数优化增强了上

采样过程中对噪声的鲁棒性。为解决非均匀上采样问题,Huang等人(2009)提出密度感知的LOP,通过自适应权重调整优化点分布的均匀性。尽管这些方法在特定场景下效果显著,但其假设下表面光滑的局限性限制了适用范围。为此,Huang等人(2013)进一步提出边缘感知重采样(edge-aware resampling, EAR),采用渐进式边缘检测与填充策略以增强复杂区域的特征保持能力。然而,该方法对点云法线准确性和参数调整的依赖性较高,限制了其鲁棒性。随后,Wu等人(2015)提出基于中轴约束的深度点云修复模型,通过表面与骨骼联合优化实现缺失区域补全,标志着传统方法向数据驱动范式的初步转变。尽管如此,传统方法仍普遍存在依赖手工特征、计算效率低以及对复杂拓扑适应性不足的问题,亟需突破。

近年来,深度学习技术在计算机视觉领域取得了巨大成功,特别是在二维图像处理方面。卷积神经网络(He等,2016)凭借其强大的特征提取能力,在图像分类(刘鸿达等,2025)、目标检测(邵延华等,2022)等任务中表现出色。其中,图像超分辨率技术(朱新峰和宋健,2024)通过深度学习模型实现了从低分辨率图像到高分辨率图像的高质量重建,为三维点云上采样提供了重要启示。然而,当研究者尝试将图像超分辨率的方法直接迁移到点云数据上时,遇到了显著的技术障碍。点云与二维图像存在本质差异:点云作为无序集合,点的排列顺序不影响表征的三维结构,与图像的规则像素网格排列截然不同;点云表征三维空间的连续表面,具有复杂几何流形特性,简单插值难以保持几何完整性;并且点云的密度分布受传感器视角、遮挡等影响往往不均匀,使得传统的局部感受野设计难以直接适用。这些根本差异导致图像处理范式无法直接适用于点云数据,迫切需要专门针对点云特性设计的深度学习新方法。

在这一背景之下,点云深度学习研究在2017年迎来了重要突破。Charles等人(2017a)提出了PointNet,首次实现了点云数据的端到端深度学习处理。该网络通过设计对称函数有效解决了点云数据无序性的问题,并采用多层感知机(multilayer perceptron, MLP)直接从点坐标中学习特征表示。在此基础上,Charles等人(2017b)进一步提出了PointNet++,通过引入层次化的特征聚合机制,显著增强

了对局部几何结构的建模能力。这一系列突破性进展为点云上采样技术开辟了新途径,使得基于深度学习的点云稠密化成为可能。与传统方法相比,深度学习驱动的点云上采样方法展现出四大显著优势:更强的复杂拓扑适应性、更优异的几何特征提取能力、更均匀的分布优化效果以及显著提升的噪声鲁棒性。这些优势极大地激发了研究者对深度学习点云上采样方法的持续探索热情。

基于此,本文系统梳理了深度学习驱动的点云上采样技术脉络,聚焦领域最新进展。其创新性贡献主要体现在以下3个方面:1)综述方法覆盖更全面。以下综述(韩冰等,2024)未包含2024—2025年的最新成果,如RepKPU(point cloud upsampling with kernel point representation and deformation)(Rong等,2024)和PUFM(point cloud upsampling via flow matching)(Liu等,2025),二者不仅在性能上代表了当前点云上采样的最高水平,而且在机理上各具独特性。本文不仅涵盖了这些最新进展,同时也纳入此前的代表性方法,使总结更完整、剖析更深入,并始终紧贴领域前沿。2)分类框架更清晰。相较于韩亚振等人(2025)等综述以模型类型(如卷积神经网络(convolutional neural network, CNN)、注意力机制、Transformer、生成式)为依据导致出现类别方法存在交叉的问题,本文首先按训练方式划分为监督式与无监督式两大类。对研究较为深入的监督式方法,依据上采样实现方式细分为三段式、生成式、几何扩充—坐标优化及表面重建式4种范式,并按核心机制进一步子分类;对无监督式方法,根据如何构建监督信号分为稀疏点云直接监督、稀疏点云变换监督、逆向构造监督及孪生网络关联监督4类(见图2)。此框架清晰揭示方法机理差异,显著提升分类的逻辑性与区分度。3)评估体系更完整。本文系统整理了该领域常用的基准数据集与评价指标,并通过对比实验直观展示了代表性方法的性能表现。

综上所述,本文首先阐述了深度学习驱动的点云上采样方法的重要意义,然后按照分类方法深入分析各个方法的核心创新点与固有局限性,同时整理了常用数据集与评价指标,并通过实验比较展示了部分先进方法的性能表现。最后,本文总结了当前研究成果,并对未来研究方向进行了展望。

1 基于深度学习的点云上采样方法

根据训练方式,基于深度学习的点云上采样方法可分为监督式和无监督式两大类。监督式方法依赖标签数据,通过端到端学习实现精确的点云稠密化;而无监督式方法则减少对标签数据的依赖,利用自监督或弱监督策略提升模型的泛化能力。本节将系统梳理这两类方法的代表性工作,分析其核心思想、网络架构及优化策略。

1.1 监督式点云上采样

监督式点云上采样算法通常采用基于合成数据集的训练方法。具体框架如图3所示,该方法首先从多样化的3D合成模型中采样得到密集的标签点云数据,然后通过下采样生成对应的稀疏点云样本,从而构建完整的稀疏—密集点云配对训练数据集。为适应不同密度的输入点云,大多数算法都采用分块处理策略,将输入点云块提取为包含256个点的局部块作为模型输入。在训练过程中,模型通过最小化预测上采样块与标签密集块之间的差异损失,逐步学习从稀疏到密集点云的空间映射关系。经过充分训练后,该模型能够在测试阶段对任意输入的稀疏点云进行高质量的上采样重建,生成具有良好细节保持能力的密集点云输出。

根据网络架构的不同,现有的监督式点云上采样方法可分为四大类:开创点云上采样范式的三段式上采样方法、先进行几何扩充再优化坐标的点云上采样方法、采用生成式网络的点云上采样方法以及先进行表面重建再重采样的点云上采样方法。下文将分别阐述各类方法的原理及优缺点。

1.1.1 三段式点云上采样

当前,三维点云上采样领域的主流研究方法普遍采用三段式架构,该架构由特征提取、特征扩展和坐标重建3个核心模块组成,如图4所示。具体而言,该方法的处理流程如下:输入数据为包含 N 个三维坐标点的稀疏点云($P_s: N \times 3$),首先,通过特征提取模块对每个点进行深度特征编码,得到高维点云特征($F_s: N \times C$, C 为特征维度);随后,特征扩展模块根据预设的上采样倍率 r 将点云特征扩展至目标维度($F_d: rN \times C$);最后,坐标重建模块将扩展后的高维特征映射回三维坐标空间,输出稠密点云($P_d: rN \times 3$)。在模型训练阶段,整个过程通过监督学习




Fig. 2 Classification framework diagram of deep learning-based point cloud upsampling methods




Fig. 3 Framework for supervised point cloud upsampling

的方式,利用标签数据与输出点云构建损失对模型的参数进行优化。
本研究将现有方法依据网络架构系统性地划分

为端到端单程式与多阶段渐进式上采样两大类。
1. 1. 1. 1 端到端单程式
作为深度学习点云上采样的开端范式,端到端




图 4 三段式点云上采样方法的框架图

Fig. 4 Framework diagram of three-stage point cloud upsampling method

单程式上采样方法通过单次端到端的流程完成特征提取、特征扩展和坐标重建,生成密集点云,强调高效、直接的点云稠密化。为了让读者更加了解该类方法的演进过程,本小节从特征提取模块优化、特征扩展模块优化、坐标重建模块优化和上采样倍率优化4个方面进行阐述。

1)特征提取模块的优化。特征提取模块是点云上采样网络中的核心组件,直接决定了点云特征表示的质量和上采样效果。特征提取模块优化的主要工作如表 1 所示。以下从基于 PointNet、图卷积网络 (graph convolutional network, GCN) 和 Transformer (Vaswani 等, 2017) 3 种主流方法出发,分析其特征提取模块的改进策略。

(1)基于 PointNet。PointNet 是点云处理领域的里程碑式工作,首次提出了一种直接处理无序点云的深度学习框架。它通过对每个点独立提取特征,

并利用对称函数有效解决了点云数据无序性的挑战。然而,PointNet 的局限在于其缺乏对局部几何结构的捕捉能力,这在复杂场景中限制了其表现。为弥补这一不足,PointNet++在 PointNet 的基础上引入了层次特征学习机制,通过递归划分点云为局部区域并提取多尺度特征,显著增强了对局部结构的建模能力。在此背景下,Yu 等人(2018)提出了 PU-Net(point cloud upsampling network),作为首个基于深度学习的点云上采样模型,开辟了该领域的新方向。PU-Net 构建了一个端到端的上采样框架,利用多尺度特征学习和层次化特征聚合,实现了几何感知特征的有效嵌入,从而在点云上采样任务中取得了显著的性能提升。在此基础上,Sharma 等人(2021)进一步拓展了这一研究方向。他们利用 PointNet 提取全局特征,同时借助 PointNet++提取局部特征,然后将两者进行融合,从而显著增强了特征

表 1 特征提取模块优化的主要工作

Table 1 Major advances in feature extraction module optimization

方法	方法分类	关键思想
PU-Net(Yu 等, 2018)	基于 PointNet	深度学习点云上采样,采用多尺度特征学习和层次化特征聚合,嵌入几何感知特征
Sharma 等人(2021)	基于 PointNet	融合 PointNet 全局与 PointNet++局部特征,增强点云上采样特征提取能力
Zeng 等人(2021)	基于 PointNet	多级局部特征聚合,SFE 块结合局部细节与全局语义,提升空间理解
AR-GCN(Wu 等, 2019)	基于 GCN	对抗残差图卷积,捕捉局部相似性,残差连接关联低、高分辨率点云
PU-GCN(Qian 等, 2021a)	基于 GCN	Inception DenseGCN 模块,多路径提取多尺度特征,融合局部与全局信息
PU-WGCN(Gu 等, 2022)	基于 GCN	加权图卷积融合中心点、邻域、距离和边界信息,自适应权重缓解特征同质化
PU-GACNet(Han 等, 2022)	基于 GCN	图注意力卷积,动态分配注意力权重,精准捕捉局部与全局特征
PU-Transformer(Qiu 等, 2022)	基于 Transformer	首个点云上采样 Transformer,位置融合模块+通道偏移注意力增强全局建模
PU-EdgeFormer(Kim 等, 2023)	基于 Transformer	EdgeConv 与自注意力结合,融合局部几何与全局结构特征
APUNet(Zhao 等, 2023a)	基于 Transformer	DisTransformer 模块,结合距离相关性与特征相似性,精准捕捉局部与全局特征
LET-UP(Zhu 等, 2024)	基于 Transformer	BiTransformer 模块通过二值化操作优化 Transformer,降低计算与存储需求,提高推理效率

提取能力。与此同时,Zeng 等人(2021)在 PointNet 和 PointNet++ 的框架内提出了一种多级空间局部特征聚合方法。该方法通过级联的空间特征提取器(spatial feature extractor, SFE),不仅提取每个点的特征,还考虑了点与局部空间的关系,为每个点分配不同的权重以表示局部几何形状的空间分布。此外,通过多级特征聚合模块,将不同层次的特征进行整合,结合局部细节和全局语义信息,极大地提升了网络在理解空间环境和学习层次化特征方面的能力。

(2) 基于 GCN。GCN(graph convolutional network)因其对非欧氏空间数据的建模能力,成为点云处理的理想选择。传统点云处理算法(如 PointNet)依赖全局特征池化,可能忽略局部几何关系。而 GCN 通过构建点云的局部图结构,显式建模点间的空间依赖关系,能够更有效地捕捉局部几何特征。Wu 等人(2019)提出的 AR-GCN(adversarial residual-GCN)是一种基于对抗残差图卷积网络的方法,通过图卷积捕捉点云的局部相似性,并利用残差连接和跳跃连接建立低分辨率与高分辨率点云间的关联。相比之下,Wang 等人(2019b)提出的动态图卷积神经网络(dynamic graph convolutional neural network, DGCNN)专为点云分类和分割任务设计,与传统 GCN 的固定图结构不同,DGCNN 在每层使用 EdgeConv 模块动态更新图结构,基于当前层特征空间重新计算最近邻图,而非依赖输入空间的固定图。这种动态更新机制根据语义接近性对点进行分组,促进了非局部信息的扩散。在 DGCNN 的基础上,Qian 等人(2021a)提出的 PU-GCN(point cloud upsampling using GCN)方法中,在特征提取部分引入 Inception DenseGCN 模块,该模块通过多路径并行结构高效提取点云的多尺度特征。该模块首先利用初始层压缩输入特征以减轻计算负担,随后将特征分送至两条密集连接的扩张图卷积路径,分别捕捉不同尺度的局部细节,并结合全局池化层融入整体上下文信息。最终,通过特征拼接融合,生成层次丰富、表达力强的多尺度特征表示。然而,PU-GCN 的特征提取方式存在两个主要局限性。一方面,由于 K 最近邻(K-nearest neighbors, KNN)算法选择的邻近点在空间上过于接近,导致特征提取后语义信息趋同,在处理物体孔洞区域时会产生过度填充问题;另一方面,该方法对所有邻域节点平等对待,缺乏对边界特征的特殊处理,导

致边界点云溢出和轮廓模糊,特别是在复杂结构处多次上采样会累积这种误差。针对这些问题,Gu 等人(2022)进一步提出了加权图卷积网络(weighted graph convolutional network, WGCN),该网络通过两项关键改进提升特征提取性能:首先,融合了中心节点特征、邻域信息、相对距离和边界特征 4 类关键信息,显著缓解了邻域节点特征相似性过高的问题;其次,引入基于余弦相似度的自适应权重机制,动态调整边界信息的权重分配。同样,Han 等人(2022)在特征提取中提出的图注意力卷积模块(graph attention convolution, GAC)通过同时计算邻域点与中心点之间的空间差异和特征差异,动态地为每个邻域点分配注意力权重,从而精准地捕获局部特征。

(3) 基于 Transformer。Transformer 架构最初在自然语言处理领域大放异彩,其独特的自注意力机制彻底改变了序列建模的方式。这种架构通过并行计算和全局注意力,能高效捕捉长距离语义依赖,为 BERT (bidirectional encoder representations from Transformer) (Devlin 等, 2019)、GPT (generative pre-trained Transformer) (Floridi 和 Chiriatti, 2020) 等大型语言模型奠定了基础。在计算机视觉领域,Vision Transformer (Dosovitskiy 等, 2021) 成功突破了传统 CNN 的局限。它将图像分割为小块序列进行处理,保留了 Transformer 的全局建模优势,同时通过创新的位置编码适应图像的空间特性。近年来,Transformer 的应用进一步扩展到三维点云处理领域。针对点云数据的无序性和稀疏性特点,研究人员开发了 Point Transformer (Zhao 等, 2021a) 等专用架构。这些模型通过精心设计的注意力机制,能够有效处理不同密度的点云数据,在分类、分割等任务中取得了突破性进展。在这样的背景下,Qiu 等人(2022)提出的 PU-Transformer 是首个将 Transformer 架构应用于点云上采样的工作。其特征提取部分包括一个位置融合模块和一个移位通道多头自注意(shifted channel multi-head self-attention, SC-MSA)模块。位置融合模块有效地将 3D 空间坐标合并到特征空间,增强了模型的空间理解和特征识别。而 SC-MSA 模块则在多头自注意力的基础上引入了通道偏移,进一步增强了点云特征的通道间关系,使得模型能够更有效地捕捉点云的全局结构信息。为了弥补 GCN 缺少捕捉全局特征的能力,Kim 等人(2023)提出的 PU-EdgeFormer 则结合了 EdgeConv 和自注意力

各自的优势,通过设计的级联 EdgeFormer 单元提取点云特征。该单元利用 EdgeConv 捕捉点云的局部几何结构,并通过多头自注意力机制捕捉全局结构信息,实现了局部与全局特征的有效融合。同样,Zhao 等人 (2023a) 提出的 APUNet (attention-guided point cloud upsampling network) 通过其设计的 Dis-Transformer 网络提取点云特征。该模块中的多头 DisAttention 模块不仅考虑了语义特征之间的相似性,还引入了点之间的距离相关性。通过将距离相关性与特征相似性相结合,计算出每个点的注意力权重,从而避免了远距离点之间的强相关性与无关区域之间的错误连接。尽管上述基于 Transformer 的上采样模型在长程相关性和全局结构建模方面表现优异,但是往往也具有很高的计算复杂度和内存开销。为此,Zhu 等人 (2024) 提出的 LET-UP (lightweight efficient binarized transformer for point cloud upsampling) 通过 BiTransformer 模块实现高效的特征提取。该模块通过二值化操作优化了 Transformer 的核心组件。

其中二值化 MLP 将实值权重和激活函数转换为二值形式,显著减少了计算和存储需求,二值化自注意力模块通过二值化和位操作提高了模型的推理速度。这种优化使得 LET-UP 在保持 Transformer 强大特征表示能力的同时,能够满足实时性的需求。

2) 特征扩展模块的优化。在三段式上采样中,特征扩展是实现高质量上采样的核心环节。高效的特征扩展不仅能丰富点云的几何细节,还能优化上采样点的分布均匀性,从而提升整体上采样质量。近年来,深度学习技术的快速发展推动了点云上采样领域特征扩展方法的持续创新,从早期简单的复制与折叠操作,到受 PixelShuffle (Shi 等, 2016) 启发的 NodeShuffle (Qian 等, 2021a), 再到融合 Transformer 架构,以及最新的核到位移上采样策略 (Rong 等, 2024), 这些方法在特征扩展方面取得了显著突破。特征扩展模块优化的主要工作如表 2 所示。以下将系统阐述这些方法在特征扩展部分的创新与改进,分析其技术优势与应用潜力。

表 2 特征扩展模块优化的主要工作
Table 2 Major advances in feature expansion module optimization

方法	方法分类	关键思想
PU-Net (Yu 等, 2018)	复制、折叠	多分支卷积复制点特征实现上采样,但新点易聚集在原始点附近
MPU (Wang 等, 2019c)	复制、折叠	在特征扩展中引入固定编码(± 1)作为位置变化,改善点分布多样性
PU-GAN (Li 等, 2019)	复制、折叠	采用规则二维网格提供位置变化,up-down-up 结构优化特征扩展
GC-PCU (Ding 等, 2021)	复制、折叠	学习几何特征生成扰动值,使新点分布与输入几何保持一致
PU-GCN (Qian 等, 2021a)	类 PixelShuffle	基于 GCN 的 NodeShuffle 模块重排特征,利用邻域信息提升细节
PU-GACNet (Han 等, 2022)	类 PixelShuffle	改进 NodeShuffle 模块,结合邻域特征增强边缘感知能力
UPU-SNet (Han 等, 2023)	类 PixelShuffle	用 Transformer 扩展特征,自注意力机制捕捉全局和局部关系
SPU (Li 等, 2023)	类 PixelShuffle	结合 PointShuffle 与预插值技术,增强上采样过程的稳定性
PU-Mask (Liu 等, 2024a)	引入 Transformer	将上采样视为局部填充任务,用虚拟掩码引导自编码器预测遮挡点
RepKPU (Rong 等, 2024)	引入 Transformer	核点变形范式,交叉注意力机制将核点查询转换为位移特征

PU-Net 率先将深度学习引入点云上采样任务,通过多分支卷积实现特征扩展。其核心思想是复制每个源点的特征,并在多个分支上独立使用卷积生成新特征,最后拼接在一起从而增加点云密度。这一方法为后续研究奠定了基础,但复制源点特征生成的新点往往集中于原始点附近,缺乏多样性。为解决这一聚集效应,后续研究尝试在点生成过程中引入位置变化,以优化点的分布。例如,FoldingNet

(Yang 等, 2018) 通过折叠解码器将全局特征与预定义的二维网格拼接,经两次连续变形操作映射回三维点云表面,生成更分散的点集。在此基础上,Wang 等人 (2019c) 提出的 MPU (patch-based progressive 3D point set upsampling) 进一步改进上采样单元,不仅复制源点特征,还引入固定值(+1 和-1)的一维编码作为位置变化,融入扩展特征中,以增强点分布的多样性。Li 等人 (2019) 提出的 PU-GAN

(point cloud upsampling generative adversarial network) 则采用规则二维网格提供的二维向量作为位置变化,并引入 up-down-up 结构优化特征扩展。该结构首先对点特征进行上采样,随后通过下采样计算上采样前后特征的差异,将差异信息反馈到上采样特征中,最后再次上采样生成最终点云。这一策略避免了烦琐的多步训练,显著提升了细粒度特征的生成能力。然而,将预定义的一维或二维编码向量在

映射至三维空间后,其点分布可能与底层几何表面不完全一致,导致折叠操作难以精确表达复杂几何形状。为解决这一问题,Ding 等人(2021)提出的 GC-PCU(geometry-consistent point cloud upsampling)受微分几何理论启发,提出通过学习潜在几何特征生成位置扰动值,并将其融入扩展特征,确保位置变化与输入点云的几何形状一致。复制、折叠方式的特征扩展示例框架如图5所示。




图5 复制和折叠方式的特征扩展示意图

Fig. 5 Feature expansion via duplication and folding ((a) PU-Net feature expansion method (replication); (b) MPU feature expansion method (adding one-dimensional encoding); (c) PU-GAN feature expansion method (adding two-dimensional encoding); (d) GC-PCU feature expansion method (adding positional perturbation values))

受图像超分辨率领域中 PixelShuffle 操作的启发,PU-GCN 采用了基于 GCN 的 NodeShuffle 模块进行特征扩展。该模块通过通道扩展和周期性重排操作生成新的点特征,利用图卷积操作编码点云的局部邻域信息,避免了简单复制原始点的问题,从而在上采样过程中保留更多细节信息,使上采样点云质量更高、结构更完整。在此基础上,PU-GACNet 进一步提出了边缘感知 NodeShuffle 模块。该模块通过复制源点特征并利用邻域特征构建高维度特征集,再经重排操作获得扩展特征。这一改进不仅能够精确生成新点特征,还能有效保留边缘特征,进而在上采样过程中更好地保持点云的局部几何细节。之后,Han 等人(2023)又在 UPU-SNet(siamese network for unsupervised point cloud upsampling)中提出了 TranShuffle 上采样模块。该模块采用 Transformer 对输入特征进行通道扩展。Transformer 利用其强大的自注意力机制,能有效捕捉点云中点间的长距离依赖与局部细节信息,结合全局与局部特征生成更具代表性的扩展特征,再通过重排操作实现点云稠密化。虽然 Shuffle 操作能够有效地增加点云的密度,

但在训练过程中可能会导致不稳定的结果。为此,Li 等人(2023)在提出的 SPU(semantic point cloud upsampling)框架中引入了一种增强上采样模块(enhanced upsampling module, EUM),该模块通过 PointShuffle 与最近邻预插值技术优化稳定性。具体而言,预插值先为稀疏点云提供大致形状轮廓,再将插值结果与 PointShuffle 生成的点逐元素相加,生成最终上采样点云,有效避免因缺乏全局形状信息导致的训练不稳定问题。类 PixelShuffle 方式的特征扩展示例框架如图6所示。

当前深度学习方法通常将点云上采样视为“无约束生成”问题,这可能导致上采样点出现在任意位置并产生随机伪影。点云上采样本质上是一个局部填充过程,需要在每个原始点邻域内插入特定数量的新点。受此启发,Liu 等人(2024a)提出的 PU-Mask 创新性地将点云上采样重新定义为“局部填充”任务。该方法的核心思想是:将稀疏输入点云视为原始密集点云被虚拟掩码局部遮挡后的结果。通过构建虚拟掩码引导的自编码器,PU-Mask 能够准确预测被遮挡区域的点云分布,从而生成具有良好




图6 类PixelShuffle方式的特征扩展示意图

Fig. 6 Feature expansion via PixelShuffle-inspired mechanism ((a) PU-GCN (NodeShuffle); (b) PU-GACNet (edge-aware NodeShuffle); (c) SPU (PointShuffle); (d) UPU-SNet (TranShuffle))

局部结构和细节保持能力的上采样结果,具体框架如图7(a)所示。Rong等人(2024)提出了一种名为RepKPU的新型点云上采样网络。其核心思想是通过改进形状表示和点生成策略提升上采样性能。如图7(b)所示,作者受KPConv(Thomas等,2019)启发,提出了一种名为RepKPoints(kernel point representation)的新型局部几何表示方法,它能够更好地捕捉局部几何信息,具有密度敏感性、大感受野和位置自适应性等特点,是一种更通用的局部形状表示形式。在点生成方面,作者提出了核到位移(kernel-to-displacement)生成范式,将点云上采样重新定义为核点的变形过程。具体而言,先提取具有预定义位置和学习特征的核点查询(kernel points queries, KP-Queries),然后利用RepKPoints作为交叉注意力模块的键(keys)和值(values),KP-Queries作为查询(queries),通过交叉注意力机制实现两者之间的交互,将KP-Queries转换为位移特征,最后将生成的位移与复制源点相加得到新生成的点。此外,文章还提出了一种无需重新训练即可将固定比例上采样方法扩展到任意比例上采样的参数无关策略,进一步提升了RepKPU的灵活性和实用性。

3)坐标重建模块的优化。坐标重建模块旨在将扩展特征重映射到3D点云坐标,这一过程不仅需要确保新生成点的空间位置准确,还要维持点云的几

何一致性和分布均匀性。为了实现这个目标,现有方法通常从坐标回归和几何校正两个层面进行优化:坐标回归负责生成初始点云结构,而几何校正则进一步优化点云的几何细节和分布质量。坐标重建模块中引入几何校正的主要工作如表3所示。下面将分别对这两个关键技术进行详细分析。

根据实现方式的不同,坐标回归可分为两类,如图8(a)(b)所示。第1类方法(Yu等,2018;Li等,2019;Zeng等,2021;Ding等,2021)将扩展特征直接回归到点云坐标,生成上采样点云,并通过真实点云与预测点云之间的差异计算损失来优化网络模型。该方法简单高效,适合快速生成初步点云结构,但其精度可能受限于特征表达能力,尤其在复杂几何区域表现欠佳。第2类方法(Qian等,2021a;Du等,2023;Wang等,2022;Rong等,2024)通过预测上采样点云的坐标偏移量调整点的位置。具体而言,该方法将稀疏输入点云复制若干倍后,与模型预测的坐标偏移量逐元素相加生成上采样点云,再利用真实点云与预测点云的差异计算损失以优化模型。由于深度学习网络擅长学习残差,这种方法通过精细偏移调整优化点云分布,在边缘和曲面等几何细节丰富的区域表现优异,显著提升上采样点云的质量。

为了确保上采样点云精准贴合目标表面并优化分布均匀性,研究者们普遍在坐标重建后引入几何




图7 PU-Mask 与 RepKPU 的特征扩展方式示意图
Fig. 7 Architecture diagrams for feature expansion in PU-Mask and RepKPU
((a) PU-Mask; (b) RepKPU)

表3 坐标重建模块中引入几何校正的主要工作

方法名称	关键思想
Dis-PU(Li 等, 2021a)	在坐标重建后增加空间细化器,融合局部与全局特征来微调粗点云位置
PU-Refiner(Liu 等, 2022a)	通过多头点偏移Transformer和残差块逐步微调粗点云位置
PC ² -PU(Long 等, 2022)	编码点间相对位置信息,调整粗点位置以维持局部一致性
SSPU-Net(Wang 等, 2023a)	多尺度膨胀邻域特征融合,提取层次化几何模式优化分布
PU-Mask(Liu 等, 2024a)	可学习的伪拉普拉斯算子自适应调整,平衡特征保持与噪声抑制




图8 坐标重建模块优化的3种方式示意图
Fig. 8 Three optimization strategies for coordinate reconstruction ((a) direct regression of expanded features;
(b) regression of expanded features to coordinate offsets; (c) introducing geometric correction to fine-tune coarse point clouds)

校正模块,通过对粗点云进行空间位置的精细化微调来实现这一目标,具体框架如图8(c)所示。Li 等人(2021a)提出的 Dis-PU(point cloud upsampling via disentangled refinement)是这一思路的代表,它通过空间细化器融合局部细节特征与全局结构特征,预

测每个粗点的坐标偏移量(ΔP),从而对粗点云进行整体性优化,显著提升了点云贴合表面和分布均匀的效果。在此基础上,Liu 等人(2022a)的 PU-Refiner 采用了渐进式细化策略,利用多头点偏移 Transformer 和残差块逐步“雕刻”点云的几何纹理,生成

更自然的高保真点云。Long 等人(2022)的 PC²-PU 则聚焦于点与点的空间关系建模,其点关联模块通过编码相对位置信息调整点的位置,有效维持局部空间一致性并恢复细粒度结构。Wang 等人(2023a)的 SSPU-Net (structure sensitive point cloud upsampling network)引入了多尺度感知机制,其校正模块利用膨胀策略捕捉不同尺度下的邻域特征,并通过 DenseGCN 和特征融合提取层次化几何模式,最终回归偏移量以优化点云分布。PU-Mask (Liu 等, 2024a)则创新性地提出了可学习的伪拉普拉斯算子,该算子利用映射函数和聚合函数,基于局部邻域

信息和全局特征自适应地计算并应用局部变化量,从而在有效校正点云结构、抑制噪声伪影的同时,提升均匀性和表面贴合度。

4)上采样倍率优化。在点云上采样领域,实现任意倍率上采样是一项兼具挑战性与应用价值的研究方向。传统方法通常针对固定倍率进行优化,难以适应实际场景中点云稀疏程度和上采样需求的多样性。这种局限性促使研究者探索更灵活的解决方案。上采样倍率优化的主要工作如表 4 所示。以下介绍几种基于不同理论与技术的任意倍率上采样方法。

表 4 上采样倍率优化的主要工作
Table 4 Major advances on upsampling ratio optimization

方法	关键思想
Flexible-PU(Qian 等, 2021b)	基于线性近似定理分解上采样过程,自适应学习插值权重,单次训练支持多倍率需求
PU-EVA(Luo 等, 2021)	利用边向量近似和泰勒展开误差优化,保留尖锐特征,通过多样化邻域组合适应任意倍率
Meta-PU(Ye 等, 2022)	元学习动态调整网络权重,实现任意倍率上采样,多倍率联合训练提升性能
APU-SMOG(Dell'Eva 等, 2022)	将点云映射为球面高斯混合分布后采样,结合 Transformer 实现任意倍率的高质量表面重建

Ye 等人(2022)提出的 Meta-PU 网络创新性地将元学习思想引入点云上采样任务,实现了任意倍率的上采样能力。该方法的核心在于构建了一个由主网络和元子网络组成的双分支架构:主网络采用残差图卷积(residual graph convolutional, RGC)块提取点云特征,而元子网络则根据输入的上采样倍率动态生成 RGC 块的权重参数。这种动态权重调整机制使网络能够自适应不同倍率的上采样需求。此外,网络通过最远点采样策略灵活控制输出点的数量,进一步增强了模型的适应性。值得注意的是,Meta-PU 在训练过程中采用多倍率联合学习策略,不仅实现了单一模型支持任意倍率上采样,还通过不同倍率任务间的知识共享显著提升了模型性能。

为了实现任意倍率上采样,有些方法基于线性近似定理,利用局部邻域信息生成新的点。具体而言,假设在一个局部邻域内,点云可以被近似为一个光滑的曲面,那么可以通过泰勒展开将局部曲面表示为一个线性函数加上高阶误差项。基于这一理论,新的点可以通过对局部邻域内的点进行加权组合来生成,其中权重由局部几何结构决定。这种方法不仅能够生成更接近目标表面的点,还能够通过控制高阶误差项提高上采样的精度。Qian 等人

(2021b)基于此定理,提出了一种轻量级的点云上采样框架 Flexible-PU。该方法将上采样问题分解为插值权重的确定和高阶误差的优化两部分,通过分析局部几何结构自适应学习统一且有序的插值权重,从而生成接近目标表面的新点。其创新点在于通过单次训练即可支持多种上采样倍率,训练过程中随机选择不同倍率优化,使插值权重自然适应多样化需求。这种设计兼顾了计算效率与上采样精度,特别适合资源受限的场景。另外,Luo 等人(2021)提出的 PU-EVA(edge-vector based approximation for flexible-scale point clouds upsampling)方法同样基于线性近似定理,通过边向量近似实现点云上采样。该方法利用局部邻域内的边向量进行插值生成新点,同时为了提升精度,PU-EVA 通过限制泰勒展开的二阶误差项优化点的位置,在训练中随机选择不同邻域点,学习多样化的邻域连接性组合。这一策略使插值权重在推理阶段能够灵活适应任意倍率需求。

另外,Dell'Eva 等人(2022)提出的 APU- SMOG (arbitrary point cloud upsampling with spherical mixture of Gaussians)模型基于 Transformer 架构,通过球面高斯混合分布(spherical mixture of Gaussians SMOG)实现任意倍率上采样。该方法首先利用神

经网络将输入点云映射到单位球面上的高斯混合模型,其中每个输入点特征对应一个高斯分布的权重、均值和协方差。随后,从该分布中采样任意数量的点,并通过 Transformer 解码器将采样点映射回目标表面,生成高分辨率点云。APU-SMOG 的核心优势在于将上采样过程分解为规范分布映射和表面重构两步,避免了为不同倍率重新训练模型的需求。

1. 1. 1. 2 多阶段渐进式上采样

渐进式点云上采样方法通过多阶段逐步细化,突破了传统单程上采样方法在处理复杂几何细节和高倍率上采样精度的不足。其核心优势在于分层优化几何特征,生成高质量点云,同时灵活适应多种上采样比例,满足不同应用场景的需求。多阶段渐进式点云上采样的主要工作如表 5 所示。

表 5 多阶段渐进式点云上采样的主要工作
Table 5 Major advances on multi-stage progressive point cloud upsampling

方法名称	关键思想
MPU(Wang 等, 2019c)	首创渐进式点云上采样,分阶段处理几何细节,避免单次上采样细节损失
PPU(Zhang 等, 2021)	基于可微渲染的渐进式框架,共享级联网络参数降低训练复杂度
BIMS-PU(Bai 等, 2022)	引入图像超分辨率的反向投影机制,构建双向多尺度特征金字塔
CFNet(Wang 等, 2023b)	采用跨层级反馈机制,迭代优化特征表达,增强重建精度
HFCI-PU(Tang 等, 2025)	动态补偿高频细节,在 Transformer 架构中保持点云结构与细节平衡

MPU 作为第 1 个引入该想法的工作,提出了一种基于补丁的渐进式 3D 点集上采样网络。其创新之处在于将上采样过程分解为多个步骤,每个步骤专注于不同级别的细节处理。网络通过逐步训练,将一个稀疏的点集逐步上采样到一个密集的点集,这种方法通过逐步细化点云,能够更好地处理复杂几何形状的上采样问题,避免了直接从稀疏点云到高分辨率点云的跳跃式上采样带来的细节丢失和噪声问题。基于此,后续也有相关工作(Wu 等, 2019; Du 等, 2023)亦以此种方式实现。虽然 MPU 等渐进式上采样模型保留了更好的细节,但是它在高维特征空间和三维空间之间的来回转换增加了计算复杂度和训练难度。

为此, Zhang 等人(2021)提出了一种基于可微渲染的渐进式点云上采样框架 PPU (progressive point cloud upsampling), 该方法的级联上采样网络参数共享,避免了复杂的训练。此外,该方法设计了一种混合损失函数,结合了多尺度重建损失和渲染损失。多尺度重建损失使每个子上采样网络都能生成更好的密集点云,而渲染损失将 3D 稀疏点云投影到 2D 图像空间,利用多视角渲染图像与真实投影之间的差异来优化点云结构。相比之下, Bai 等人(2022)提出的 BIMS-PU (bi-directional and multi-scale point cloud upsampling)方法创新性地将图像超分辨率中的反向投影机制(Irani 和 Peleg, 1993)引入

点云上采样任务。该方法通过构建双向上下采样路径的特征金字塔架构,实现了多尺度特征的并行提取与高效融合。具体实现上, BIMS-PU 将传统级联上采样过程分解为多个并行子步骤,每个子步骤处理较小的采样因子,不仅可以显著降低计算复杂度,还能通过并行化处理提升运算效率。

之后, Wang 等人(2023b)提出的 CFNet (cascaded feedback network)是一种基于级联反馈机制的点云上采样方法。该方法的核心创新在于通过反馈连接将高层特征传递至低层,实现跨层级的特征增强。网络采用参数共享的反馈上采样(feedback upsampling FU)模块结构,每个模块通过特征提取、融合、扩展和坐标生成 4 个处理阶段,在时间步迭代过程中逐步优化上采样结果。这种设计实现了高层语义信息对低层特征的指导作用,有效提升了点云重建质量。Tang 等人(2025)提出的 HFCI-PU (high-frequency compensation interpolation network for point cloud upsampling)网络创新性地解决了点云上采样中高频细节损失的难题。该方法采用多阶段渐进式处理,在每个上采样阶段引入动态补偿机制,通过高通图滤波器逐步恢复边缘和纹理等高频信息,有效提升点云的几何精度与细节表现。

三段式点云上采样构成了深度学习方法的主流范式,其核心流程清晰划分为特征提取、特征扩展和坐标重建 3 个串联模块。特征提取模块利用 Point-

Net、GCN 或 Transformer 等架构捕获点云的局部或全局几何信息;特征扩展模块通过复制折叠、类 PixelShuffle 操作或核点变形等技术增加点的数量;坐标重建模块则将扩展后的高维特征映射回三维空间,生成最终的密集点云坐标,常辅以几何校正模块优化点分布。这种方法的优势在于架构直观、易于实现,并通过模块化设计便于针对各环节进行独立优化,在固定倍率上采样任务中性能稳定。然而,特征扩展模块通常针对特定倍率设计,难以灵活实现任意倍率上采样。同时坐标预测或偏移回归的准确性直接受限于特征表达能力和网络拟合能力,易导致点位置不准确,出现异常点或整体点云收缩伪影

等问题,影响最终的上采样质量,尤其在处理复杂几何或高倍率任务时挑战更大。

1.1.2 几何扩充—坐标优化式点云上采样

三段式上采样方法通过特征扩展来生成新的点云,但存在两个关键局限性:一是固定倍率的特征扩展模块难以实现任意比例上采样;二是由于3D坐标或残差预测不准确导致异常点和收缩伪影。针对这些问题,一些研究提出先在稀疏输入点云($P_s: N \times 3$)的几何空间内增加点数得到任意倍率的中间点云($P_r: rN \times 3$),再通过坐标优化网络使点云逐渐贴合目标表面形成最终结果($P_D: rN \times 3$),如图9所示。




图9 几何扩充—坐标优化式点云上采样示意图

Fig. 9 Framework diagram of geometric expansion-coordinate optimization-based point cloud upsampling

根据实现方式的不同,这类方法可分为“插值—细化”和“加噪—滤波”两种典型范式。

1)“插值—细化”。插值—细化方法通过在几何空间中插值生成任意倍率的新点,随后优化这些点的位置,以提升点云的密度和质量。其核心在于初始密集点云的生成与点位置的优化策略。He 等人(2023)提出的 Grad-PU (arbitrary-scale point cloud upsampling via gradient descent with learned distance functions)方法首次将上采样解耦点生成与网络学习两个步骤,将上采样倍率控制与网络学习分离。在点生成阶段,通过在低分辨率点云中点与点之间插入中点生成初始高分辨率点云;在网络学习阶段,利用梯度下降和学习的距离函数迭代调整插值点的位置,使其尽量贴近真实高分辨率点云。在此基础上, Kim 等人(2024)提出的 PU-EdgeFormer++ 在网络学习阶段引入了先进的 EdgeFormer++ 模块,通过交叉注意力和密集连接整合特征。该方法首先采用非神经网络插值生成初始点云,再利用该网络进行特征提取和距离回归,实现点云的精细化。之后, Deng 等人(2025)提出的 GraphDAE-PU (graph denoising auto-encoder for arbitrary-scale point cloud upsampling)方法通过结合图表示和去噪自动编码器架构,

为任意尺度点云上采样提供了一种全新的解决方案。该方法首先利用中点插值将稀疏点云上采样到任意尺度,然后通过预训练的 GraphDAE-PU 模型利用预测的位移引导每个点移动点云表面。图表示使得模型能够在非欧几里得空间中捕捉复杂的几何结构,从而提高上采样点云的精度。同时,去噪自动编码器对噪声敏感的中点插值点云进行细化,使得在不同上采样率下生成的表面更加准确且对噪声具有鲁棒性。

2)“加噪—滤波”。加噪—滤波方法通过添加噪声点实现任意倍率的点云上采样,再利用滤波技术将噪声点移动到点云表面,从而生成高质量的密集点云。其关键在于噪声的添加方式以及滤波算法如何有效去除噪声并保留几何细节。Kumbar 等人(2023b)提出的 TP-NoDe (topology-aware progressive noising and denoising of point clouds towards upsampling)方法采用密度感知的 K 近邻算法添加局部拓扑噪声,根据点云局部密度动态调整噪声点的数量和分布。随后,通过基于分数的滤波算法(Luo 和 Hu, 2021b)将噪声扰动点逐步映射到点云表面上。该方法无需为不同上采样比例训练不同模型,具有较高的通用性和灵活性。Hu 等人(2023)提出的

ND-PUFlow (noising-denoising framework for arbitrary ratio upsampling via continuous normalizing flows) 方法创新性地构建了一个基于条件连续归一化流 (continuous normalizing flows, CNFs) 的噪声—去噪框架。该方法首先通过向输入点云添加高斯噪声生成密集噪声点,随后利用 CNFs 学习从噪声分布到目标表面分布的确定性变换过程。这一过程通过将噪声点沿概率密度梯度方向逐步优化,使其收敛到输入点云隐含的几何表面上,最终形成既保持几何细节又分布均匀的稠密点云。

几何扩充—坐标优化式点云上采样方法的核心思想是将上采样过程解耦为两个独立的阶段:几何扩充和坐标优化。首先,在几何空间内对输入稀疏点云进行扩充,通过中点插值或密度感知的局部加噪等策略,直接增加点的数量至目标倍率,生成一个

包含足够点数的中间点云。随后,利用一个专门设计的坐标优化网络对这个中间点云进行精细化处理,使其中的点逐渐贴合目标物体表面,最终输出高质量的密集点云。这种方法的最大优势在于其灵活性,能够轻松实现任意上采样倍率的需求,摆脱了固定倍率特征扩展的限制。其解耦设计也使得模型训练目标更明确。然而,其性能高度依赖于初始几何扩充点的质量和分布,若初始点过于偏离真实表面,会给后续优化带来巨大困难。同时,优化网络的设计的稳定性也直接影响最终点云的精度、均匀性以及能否有效避免引入新的异常点或伪影。因此,如何在保证任意倍率的同时,确保初始扩充点的合理性和优化过程的鲁棒性,是该类方法的关键挑战。几何扩充—坐标优化式点云上采样的主要工作如表6所示。

表6 几何扩充—坐标优化式点云上采样的主要工作
Table 6 Major advances in geometric expansion-coordinate optimization-based point cloud upsampling

方法	方法分类	关键思想
Grad-PU(He 等, 2023)	插值—细化	采用中点插值生成初始点云,结合梯度下降和基于学习的距离函数逐步优化点位置
PU-EdgeFormer++(Kim 等, 2024)	插值—细化	中点插值生成密集点云,利用 EdgeFormer++ 模块的进行点云位置优化
GraphDAE-PU(Deng 等, 2025)	插值—细化	中点插值后,通过图表示学习和去噪自动编码器优化点位置
TP-NoDe(Kumbar 等, 2023b)	加噪—滤波	根据局部密度自适应添加拓扑噪声,再通过基于分数的滤波算法将噪声点逐渐移动到点云下表面
ND-PUFlow(Hu 等, 2023)	加噪—滤波	添加高斯噪声后,利用连续归一化流逐步将噪声点移动到目标表面

1. 1. 3 生成式点云上采样

在二维图像超分辨率领域,生成对抗网络、流模型以及扩散模型等生成式模型已经得到广泛应用,并取得了显著的研究成果。受此启发,越来越多的研究者将这些生成式模型的理论与方法扩展到三维点云的上采样任务中。

1) 基于生成对抗网络的点云上采样。生成对抗网络 (generative adversarial network, GAN) 是由 Goodfellow 等人 (2014) 提出的突破性深度学习框架。该模型基于对抗训练机制,通过生成器 (generator) 和判别器 (discriminator) 的博弈过程实现数据生成。其中,生成器致力于合成逼真样本,而判别器则专注于区分生成数据与真实数据,二者相互促进直至生成样本达到以假乱真的效果。这种独特的对抗机制使 GAN 在图像、音频等多媒体数据生成领域展现出

卓越性能。GAN 在图像超分辨率领域的应用是其早期成功的重要案例之一。Ledig 等人 (2017) 提出的 SRGAN (super-resolution generative adversarial network) 首次将对抗训练引入超分辨率任务,通过结合感知损失和对抗损失,不仅提升了图像像素精度,更增强了视觉真实感。此后,ESRGAN (enhanced super-resolution generative adversarial network) (Wang 等, 2019a) 和 Real-ESRGAN (Wang 等, 2021) 等改进模型进一步优化了细节生成质量,推动了该技术在图像处理领域的广泛应用。这些发展充分展现了 GAN 框架在解决复杂视觉任务方面的强大潜力。

在此基础上,PU-GAN (Li 等, 2019) 首次将 GAN 引入到点云上采样,同时结合 up-down-up 扩展单元和自注意力单元,实现了高质量的点云上采样。该网络的核心在于其对抗学习机制,生成器负责将稀

疏点云转换为密集点云,而判别器则负责区分生成的点云和标签点云,生成器和判别器通过不断地竞争和学习,使得生成的点云逐渐逼近标签分布,具体如图10(a)所示。此外,还设计了一种复合损失函数,包括对抗损失、均匀性损失和重建损失,以鼓励判别器学习更多的潜在模式,并增强输出点分布的均匀性。

Li 等人(2021b)提出了 CM-Net (circular multi-frequency network),在GAN的生成器中引入循环排列模块捕捉空间几何关系,多频池化模块提取不同层次特征以及正多边形编码模块确保点均匀分布,训练过程中结合重建、排斥、均匀和对抗4种损失函数优化性能,提高上采样性能。

与此同时,Liu 等人(2022b)提出了 PUFA-GAN (a frequency-aware generative adversarial network for 3D point cloud upsampling),一种基于频率感知判别器的上采样模型,旨在生成均匀分布且高频区域清晰的高分辨率点云。该模型的生成器采用动态图残差聚合单元捕获多尺度的点特征,同时利用层次残差块来丰富上采样特征的细节表达,从而生成具有自然几何纹理的点云。在判别器设计方面,PUFA-GAN 创新性地引入了图滤波器来提取高频特征点,

使网络能够同时学习点云的全局分布特性和局部高频细节。这种频率感知机制使模型特别擅长处理边缘、角点等高频区域,有效避免了传统方法在这些区域容易产生噪声的问题。

随后,Li 等人(2022b)提出的 PU-CycGAN 创新性地将在点云上采样问题建模为最优传输任务,通过循环对抗网络架构实现非配对点云的弱监督学习。该方法的核心在于双向转换机制:密集点云生成器(densifier)负责上采样转换,稀疏点云生成器(spar-sifier)实现下采样映射,二者协同双判别器构建完整对抗训练框架。同时引入二次 Wasserstein 距离增强训练稳定性,设计循环一致性损失确保稀疏-稠密转换闭环特性,并采用自约束损失强化生成点云的几何结构保持能力。这种基于最优传输理论的弱监督学习范式,为点云上采样任务提供了新的解决方案。

2)基于流模型的点云上采样。流模型(normalizing flows)最初源于概率密度估计领域,其核心思想是通过一系列可逆变换将简单分布逐步映射到复杂数据分布。Rezende 和 Mohamed(2015)的开创性工作奠定了理论基础,通过雅可比行列式计算实现精确的概率密度建模。随着研究的深入,流模型在




图10 生成式点云上采样框架图

Fig. 10 Framework diagram of generative point cloud upsampling ((a) GAN-based point cloud upsampling; (b) reversible flow model-based point cloud upsampling; (c) diffusion model-based point cloud upsampling)

生成任务中展现出独特优势,特别是在需要精确密度估计的领域。在图像超分辨率方向,SRFlow (super-resolution flow) (Lugmayr 等, 2020) 首次将条件流模型成功应用于超分辨率任务,通过最大化似然估计直接学习从低分辨率到高分辨率的映射关系,避免了传统 GAN 方法常见的伪影问题。这种基于可逆变换的方法很快被拓展到更具挑战性的三维点云处理领域。PointFlow (Yang 等, 2019) 作为先驱工作,首次证明了流模型在无序点云生成中的有效性,通过分层式流结构实现了潜在空间到三维点云的精确映射。

在此技术积累的基础上,流模型在点云上采样任务中取得了突破性进展。Mao 等人 (2022) 提出的 PU-Flow 通过归一化流构建了欧氏空间与潜在空间之间的可逆映射,并采用自适应权重预测的插值方法在潜在空间进行上采样。具体而言,该方法首先通过流模型的双射变换将输入点云映射到潜在空间,然后基于学习到的特征相似性动态预测插值权重,最后通过逆向映射生成稠密点云,具体框架如图 10(b) 所示。然而,这类方法需要严格约束网络架构以保证可逆性,限制了模型的表达能力。为突破这一限制,后续提出的 PU-INN (Mao 等, 2023) 转而采用可逆残差网络 (invertible residual neural network, INN) 框架。相比于流模型,INN 通过 Lipschitz 约束而非结构约束来保证可逆性,使网络架构设计获得更大自由度。PU-INN 在保留潜在空间插值优势的基础上,通过条件注入器动态融合多层次几何特征,并引入基于语义相似度的自适应插值策略,显著增强了特征变换能力。

3) 基于扩散模型的点云上采样。扩散模型 (diffusion model) 最早由 Sohl-Dickstein 等人 (2015) 在 2015 年提出,通过模拟数据的正向加噪和反向去噪过程,从随机噪声生成逼真的数据分布。2020 年,Ho 等人 (2020) 提出的去噪扩散概率模型 (denoising diffusion probabilistic model, DDPM) 优化了扩散模型的理论框架,使其在图像生成任务中展现出与生成对抗网络媲美的性能,凭借稳定的训练过程和生成结果的高质量,在多样性和细节真实性方面具有显著优势。扩散模型在图像处理领域的首次重要应用是图像超分辨率, Li 等人 (2022a) 提出的 SRDiff (super-resolution with diffusion models) 开创性地将扩散模型应用于单幅图像超分辨率任务,利用去噪扩

散概率模型的正向加噪和反向去噪机制,以低分辨率图像为条件逐步重建高分辨率图像,相比传统生成对抗网络方法,SRDiff 在生成多样性和细节真实性上表现优异,尤其擅长处理复杂纹理和边缘细节,奠定了扩散模型在超分辨率领域的应用基础,并推动了后续研究的发展。随着扩散模型在图像领域的成功,其应用扩展到三维点云处理领域,为点云生成、补全和上采样等任务提供了新方案。例如, Luo 和 Hu (2021a) 首次将扩散模型应用于三维点云生成,通过迭代去噪从随机噪声生成高质量点云。Lyu 等人 (2021) 提出了 PDR (point diffusion-refinement) 范式,首次将条件扩散模型用于点云补全,以不完整点云为条件从噪声中生成完整点云,并在公开数据集上实现高精度的补全效果。

在此技术背景下,扩散模型被进一步开发用于点云上采样任务。Qu 等人 (2024) 提出的 PUDM (a conditional denoising diffusion probability model for point cloud upsampling) 创新性地条件去噪扩散概率模型应用于点云上采样任务。该方法通过双映射范式迭代学习密集点云与噪声的转换关系,以稀疏点云作为条件输入,同时引入倍率建模增强了模型对不同上采样尺度的适应能力,具体框架如图 10(c) 所示。然而, PUDM 方法仍存在两个关键局限:一方面,从随机噪声分布出发的生成过程导致计算效率较低,单次推理耗时较长;另一方面,该方法未能充分利用输入稀疏点云中蕴含的几何结构信息。为此, Liu 等人 (2025) 提出的 PUFM 采用了全新思路,直接学习稀疏点云和密集点云之间的最优传输映射,而不是从噪声分布开始生成点云。这种方法的核心在于利用稀疏点云中已经存在的几何信息,直接建模从稀疏到密集转换过程,从而显著提高了模型的效率和生成质量。具体而言, PUFM 首先通过中点插值对稀疏点云进行稠密化,以解决稀疏点云和密集点云之间的密度差异问题。然后引入了一种基于 EMD (earth mover's distance) 优化的预对齐方法,通过最小化稀疏点云和密集点云之间的 EMD,找到两者之间的最佳匹配路径,从而减少学习过程中的歧义,加快模型训练收敛。这种预对齐方法在训练阶段使用,而在推理阶段则不需要,这使得 PUFM 在实际应用中更加高效。

生成式点云上采样方法借鉴了图像生成领域的成功经验,利用生成模型强大的分布学习能力来合

成高密度、均匀分布的点云。这类方法主要包含三大范式:基于生成对抗网络(GAN)、基于流模型和基于扩散模型。GAN 方法(如 PU-GAN, PUFA-GAN)通过生成器与判别器的对抗训练,促使生成器产生逼真的密集点云,其优势在于能生成视觉上均匀且细节丰富的点云,但训练过程可能不稳定且难以控制。流模型方法(如 PU-Flow, PU-INN)通过构建输入点云与潜在空间之间的可逆映射,在潜在空间进行插值或变换后再映射回三维空间,该方法在数学层面具备严谨的理论基础,且可实现精确的概率密度估计,但其网络结构通常需满足可逆性要求,限制

了模型的表达能力。扩散模型方法(如 PUDM, PUFM)则通过模拟噪声添加(前向过程)和基于条件的迭代去噪(反向过程)生成目标点云,是目前性能最优越的生成方法,尤其在生成质量和细节保真度上表现出色,但其主要缺点是推理过程迭代进行,计算开销巨大,实时性较差。总体而言,生成式方法在生成高保真、均匀分布的点云方面潜力巨大,尤其是扩散模型,但其普遍面临模型复杂、训练和推理成本高、超参数调整烦琐等问题,限制了其在资源受限或实时性要求高的场景的应用。生成式点云上采样的主要工作如表 7 所示。

表 7 生成式点云上采样的主要工作
Table 7 Major advances in generative point cloud upsampling

方法	方法分类	关键思想
PU-GAN(Li 等, 2019)	基于 GAN	首个将 GAN 引入点云上采样的模型,通过对抗学习生成均匀分布的高质量点云
CM-Net(Li 等, 2021b)	基于 GAN	在 GAN 框架中引入循环排列和多频池化模块,优化点分布均匀性和几何特征提取
PUFA-GAN(Liu 等, 2022b)	基于 GAN	基于频率感知判别器,增强高频细节保留能力,生成清晰边缘和角点的点云
PU-CycGAN(Li 等, 2022b)	基于 GAN	将上采样建模为最优传输问题,通过循环对抗网络实现弱监督学习
PU-Flow(Mao 等, 2022)	基于流模型	利用归一化流进行潜在空间插值,但受限于架构约束,表达能力有限
PU-INN(Mao 等, 2023)	基于流模型	采用可逆残差网络,放宽可逆性约束,结合条件注入器提升非线性变换能力
PUDM(Qu 等, 2024)	基于扩散模型	采用条件去噪扩散概率模型,以稀疏点云为条件,通过双映射范式生成任意尺度点云
PUFM(Liu 等, 2025)	基于扩散模型	直接学习稀疏到密集的映射,利用 EMD 优化预对齐,提高生成效率和质量

1. 1. 4 表面重建式点云上采样

如图 11 所示,点云上采样同样可以视为先对稀疏点云($P_s: N \times 3$)进行表面重建,后在此表面上进行重采样获得上采样点云($P_d: rN \times 3$)。本文根据重建表面的形式将所有方法分类为基于显式表面和基于隐式表面两类。

1)基于显式表面重建的点云上采样。显式表面重建方法通过直接构建可计算的几何结构(如参数化曲面、三角网格或局部基元)来恢复点云的表面信息。这类方法的核心在于将离散点云映射为显式定义的几何元素,例如利用局部切平面、多项式函数或体素化表示,并通过预测几何参数或优化拓扑连接来生成密集点云。下面详细介绍各类方法的实现机制与技术特点。

Qian 等人(2020)提出的 PUGeo-Net 创新性地将

离散微分几何理论引入点云上采样任务。具体实现上,PUGeo-Net 首先将输入点的局部特征参数化为二维域,再利用学习到的线性变换矩阵将二维参数域映射到三维切平面,最后通过计算法线位移将点投影到目标曲面。这种方法不仅能生成高质量的高密度点云,还能同时输出精确的点法线,为后续表面重建提供了重要支持。然而,该方法对点法线准确性具有较强依赖性,且需要依赖真实法线数据进行网络训练,这在实际应用中存在明显局限。

针对这一问题,Cai 等人(2023)提出的 PSCU(parametric surface constrained upsampler)方法通过引入显式参数化表面函数约束,成功摆脱了对真实法线的依赖。PSCU 将局部曲面表示为双三次函数和旋转函数构成的参数化表面,确保生成点严格位于底层曲面内,有效抑制了噪声点和异常点的产生。




图11 表面重建式点云上采样框架图

Fig. 11 Framework diagram of surface reconstruction-based point cloud upsampling

为了预测这些参数化函数的参数,PSCU设计了一个包含空间特征提取器、表面参数估计器和子点生成器的网络架构。空间特征提取器负责从输入点云中提取局部几何信息;表面参数估计器预测表面参数;子点生成器则根据这些参数生成新的点云。与不同的是,Du等人(2024)提出的PU-VoxelNet通过预测体素网格内的点密度分布,实现任意比例的点云上采样。该方法利用体素表示的完整性和规则性优势,首先将输入点云转换为多尺度体素网格,再通过分层3D卷积神经网络聚合体素特征并预测各网格单元的点密度分布。为提升采样精度,PU-VoxelNet设计了密度引导的网格重采样策略,融合密度预测与网格几何先验,从而精准筛选接近目标表面的网格单元并有效规避异常采样。

2)基于隐式表面重建的点云上采样。基于隐式表面重建的点云上采样方法在提升点云密度、均匀性和几何细节捕捉能力方面取得了显著进展。这类方法通过神经场、符号距离场(signed distance field, SDF)、无符号距离场(unsigned distance field, UDF)或局部占用场等技术,有效克服了传统方法在处理复杂几何形状、保持局部一致性和实现均匀分布等方面的局限性。以下对几种代表性方法的原理、特点及优势进行梳理。

在传统点云表示方法中,每个点仅能表示三维空间中的一个离散位置或简单的局部平面,这种高度离散化的表达方式严重限制了点云的几何表达能力。针对这一局限,Feng等人(2022)创新性地提出了一种基于神经场的点云表示新范式Neural Points,该方法通过神经场为每个点赋予局部连续几何形状的表达能力。具体框架包括3个关键步骤:首先利用深度神经网络提取点云的局部几何特征;随后基于这些特征构建局部同构映射,将二维参数域与三维局部曲面块建立对应关系,并通过MLP对该映射进行隐式建模,从而形成局部神经场以表征连续几

何结构;最后将多个局部神经场通过加权融合策略进行平滑整合,构建出全局一致的隐式曲面表示,确保重建表面的连续性与一致性。基于这一表征框架,该方法支持在二维参数域中任意采样,并通过映射至三维空间,实现任意比例的高质量点云上采样。

局部占用场是一种创新的点云表示方法,它通过将三维空间划分为局部区域并学习每个区域的几何特征,来精确描述点云的表面分布。与传统的全局表示不同,局部占用场能够更好地捕捉复杂几何细节,尤其擅长处理开放表面和薄壁结构等具有挑战性的三维形状。基于这一创新性技术,Kumbar等人(2023a)提出了ASUR3D(arbitrary scale upsampling and refinement of 3D point clouds)方法,实现了点云数据的任意比例上采样与精细化处理。该方法的核心流程包括两个关键步骤:首先,将输入点云分割为多个局部区域块,并通过向每个区域块注入高斯噪声点构建训练样本,以此学习局部几何特征的占用场表示;随后,利用Marching Cube算法(Mescheder等,2019)从学习到的占用场中提取均匀分布的点集,最终生成高质量的上采样结果。

SDF通过定义空间中任意点到目标表面的有符号最短距离来隐式描述物体形状。正值表示点在物体外部,负值表示点在物体内部,零值则精确对应物体表面。基于这一原理,Pan等人(2024)提出的PU-SDF方法创新性地实现了点云的任意比例均匀上采样。该方法包含两个核心模块:基于局部特征的SDF估计网络和三维网格查询点生成模块。前者通过分析输入点云的局部特征,预测查询点到潜在表面的有符号距离,建立隐式几何表示;后者则在稀疏体素空间中生成均匀分布的查询点,确保上采样点云的全局一致性和均匀性。

UDF同样用于定义空间中任意点到目标表面的最短距离,但不同于SDF,UDF不区分物体的内外区域,因此特别适用于描述开放或非闭合的几何表面。

为了解决传统方法中存在合成数据与真实数据的域依赖和固定倍率问题, Lim 等人(2024)提出的 PU-Ray 结合光线步进 ray marching 和 UDF 实现了任意倍率上采样。传统方法依赖全局形状编码, 容易受限于训练数据的分布, 而 PU-Ray 采用局部隐式表面建模, 利用 UDF 描述点云块的几何特征, 避免了对整体结构的依赖, 从而提升跨域泛化能力。该方法的关键在于光线步进, 即模拟光线在隐式表面上的步进过程, 逐步逼近交点。具体而言, 给定一条查询光线, 网络通过迭代预测其与隐式表面的最近距离, 并沿光线方向更新位置, 最终结合偏移补偿得到精确的深度值。这一过程类似于计算机图形学中的 Sphere tracing (Hart, 1996), 但 PU-Ray 将其适配到点云数据, 通过 Point Transformer 和交叉注意力动态融合局部几何信息, 使深度预测更加鲁棒。在控制上采样行为方面, PU-Ray 摆脱了传统固定倍率的限制, 允许用户自由定义光线数量和方向, 从而灵活调整输出密度或聚焦特定区域。此外, 该方法支持自监督训练, 可直接从稀疏输入点云中提取伪真值, 减少对高密度标注数据的依赖。

传统基于分块处理的点云上采样方法通常将稀疏点云分割为多个局部块进行独立处理, 再合并结果。然而, 这种“分块—合并”范式由于缺乏全局一致性约束, 往往导致最终点云出现孔洞、离群点及分布不均等问题。针对这一局限性, Li 等人(2024)提出的 APU-LDI 方法创新性地采用隐式神经表示框架, 通过构建连续的 UDF 实现全局一致性上采样。该方法采用两阶段学习策略: 首先训练基于注意力机制的局部距离指示器 (local distance indicator LDI) 来预测查询点到局部隐式表面的距离; 随后利用 LDI 作为先验指导全局隐式函数学习。在推理阶段, 通过梯度下降将查询点投影至隐式场的零水平集, 实现任意比例的上采样。在 APU-LDI 的基础上, Kim 等人(2025)提出 PLATYPUS (progressive local surface estimator for arbitrary-scale point cloud upsampling) 方法, 进一步优化了复杂几何结构区域的上采样效果。该方法的核心是渐进式局部表面估计器 (progressive local surface estimator PLSE), 通过基于曲率的层次化采样策略, 选择性聚焦高曲率区域以增强局部特征提取能力。此外, PLATYPUS 创新性地引入课程学习

策略, 根据点云曲率分布自动评估样本难度, 采用从易到难的渐进训练方式, 显著提升了网络对复杂结构的学习能力。

小结: 表面重建式点云上采样方法将上采样任务重新定义为先恢复目标物体的连续表面表示, 再在该表面上进行重采样的过程。根据重建表面形式的不同, 分为显式重建和隐式重建两类。显式方法 (如 PUGeo-Net、PSCU、PU-VoxelNet) 旨在直接构建参数化曲面、三角网格或体素化表示等可计算的几何结构。隐式方法 (如 Neural Points、ASUR3D、PU-SDF、PU-Ray、APU-LDI、PLATYPUS) 通过神经场、符号距离场 (SDF)、无符号距离场 (UDF) 或局部占用场等技术, 学习一个连续的函数来表示点云所隐含的表面。这类方法的最大优势在于其表达的灵活性和连续性, 能够优雅地处理复杂拓扑 (如开放表面、薄结构)、实现任意比例上采样, 且通常能获得更高的几何精度和表面光滑性 (如 APU-LDI 构建全局连续 UDF 避免分块合并缺陷)。然而, 隐式方法通常计算成本较高 (如需要求解零水平集、光线行进或 marching cubes), 训练过程可能更复杂, 且对网络学习隐式场的能力要求极高。表面重建式点云上采样的主要工作如表 8 所示。

1.2 无监督式点云上采样

传统监督学习方法在点云上采样任务中取得了显著成效, 但其依赖于大规模配对的稀疏—密集点云数据作为监督信号。这种数据在实际应用中往往难以获取, 尤其是在处理真实场景扫描数据时, 获取配对数据的成本高昂且耗时。为克服这一瓶颈, 无监督上采样方法应运而生。这些方法利用输入点云本身的内在结构和几何特性, 无需外部监督信号, 通过优化目标函数直接从数据中学习上采样模式, 或通过精心设计的预训练任务生成自监督信号指导学习过程, 从而摆脱对标注数据的依赖。无监督方法在降低数据获取成本的同时, 为点云上采样技术在实际场景中的推广和深化开辟了新路径。本文针对近年来的无监督上采样方法, 依据构建监督信号的方式将其分类为稀疏点云直接监督、稀疏点云变换监督、逆向构造监督以及孪生网络结构关联监督 4 类方法, 如图 12 所示。这些方法分别从不同角度利用稀疏点云的内在信息或变换生成监督信号, 摆脱了对配对密集点云的依赖。

表 8 表面重建式点云上采样的主要工作
Table 8 Major advances in surface reconstruction-based point cloud upsampling

方法	方法分类	关键思想
PUGeo-Net(Qian 等, 2020)	显式	离散微分几何建模局部几何, 二维参数化映射后法线位移生成点云, 不过依赖真实法线
PSCU(Cai 等, 2023)	显式	通过双三次函数与旋转函数参数化局部曲面, 摆脱真实法线依赖, 生成低噪声点云
PU-VoxelNet(Du 等, 2024)	显式	多尺度体素特征融合来预测网格内部点云密度分布, 密度引导重采样实现任意比例上采样
Neural Points(Feng 等, 2022)	隐式(神经场)	利用神经场表示点云局部连续几何, 构建二维参数域映射三维表面来实现任意比例上采样
ASUR3D(Kumbar 等, 2023a)	隐式(占用场)	点云分块学习局部占用场, 添加高斯噪声构建训练样本, Marching Cube 算法实现重采样
PU-SDF(Pan 等, 2024)	隐式(SDF)	采用 SDF 隐式描述表面, 均匀查询点生成实现任意比例和均匀上采样
PU-Ray(Lim 等, 2024)	隐式(UDF)	基于 UDF, 通过射线行进动态逼近表面, 支持自监督训练与任意密度控制
APU-LDI(Li 等, 2024)	隐式(UDF)	构建全局连续 UDF 隐式场, 结合局部距离指示器实现零水平集投影, 避免分块合并缺陷
PLATYPUS(Kim 等, 2025)	隐式(UDF)	采用曲率感知的渐进式学习, 通过层次化采样增强局部表面估计器对复杂结构的适应性




图 12 无监督式点云上采样框架的 4 种形式

Fig. 12 Four forms of unsupervised point cloud upsampling framework ((a) direct supervision from sparse point clouds; (b) supervision from transformed sparse point clouds; (c) reverse-constructed supervision; (d) supervision via twin network association)

1. 2. 1 稀疏点云直接监督

稀疏点云直接监督就是利用稀疏点云本身直接

提供监督信息, 如图 12(a)所示。其中, Liu 等人 (2019)提出的 L2G-AE(local-to-global auto- encoder)

方法以重建为核心思路,将点云上采样任务转化为局部到全局的自编码过程,旨在从稀疏输入中恢复完整结构。在该方法中,模型首先通过自编码机制重建一个分辨率更高的稠密点云,随后通过下采样操作从重建结果中提取目标数量的点,作为上采样输出。该过程中不依赖任何真实标签,而是通过重建误差构建自监督信号,引导网络学习点云的局部几何特征与整体空间分布。作为首个采用深度学习实现无监督上采样的框架,L2G-AE在方法上具有探索性意义。然而,由于其本质上是重建任务设计,未引入明确的上采样机制或结构优化策略,在保留细节与控制均匀性方面仍存在一定局限,导致在部分场景下表现不如专门设计的监督方法。针对上述局限,Zhao等人(2023b)提出了SSAS(self-supervised arbitrary-scale implicit point clouds upsampling)方法,将上采样任务重新定义为从稀疏点云附近生成种子点,并将其投影到隐式表面上的问题。该方法利用两个隐式函数分别预测投影方向与距离,从而引导种子点向表面靠近,得到更准确的稠密点云分布。整个训练过程中依赖于输入点云的局部几何关系构建自监督信号,无需显式标签,同时通过引入异常值修正策略,有效去除了偏离表面的错误投影点,提升了生成点的质量与鲁棒性。

为了进一步拓展无监督上采样的思路,Liu等人(2024b)提出的SPU-PMD(self-supervised point cloud upsampling via progressive mesh deformation)引入了拓扑变形的视角。该方法将点云上采样视为基于初始拓扑网格进行渐进式变形以生成稠密点集的过程。其核心流程包含网格插值和级联的网格变形器两个关键阶段。首先,利用输入稀疏点云构建初始三角网格,并通过在网格面中心插入新点实现初步的稠密化;随后,级联的变形器模块通过编码网格节点特征、利用循环特征聚合(recurrent feature aggregation RFA)融合时空形变信息、进行特征引导的节点运动估计,逐步优化网格拓扑和点分布。整个训练过程同样仅需稀疏点云作为输入,通过定义在输入点云与中间结果上的重建损失和均匀性损失提供自监督信号,驱动模型学习如何通过网格变形生成均匀且保留细节的稠密点云。

1.2.2 稀疏点云变换监督

稀疏点云变换监督通过变换稀疏点云生成监督信息。例如,Zhao等人(2021b)提出的SSPU-Net引

入可微渲染技术实现自监督上采样。该方法包含邻居扩展单元(neighbor expansion unit, NEU)和可微渲染单元(differentiable rendering unit, DRU)。NEU利用点云局部几何结构自适应学习插值权重以扩展稀疏点云;DRU则将输入输出点云均渲染为多视图图像,再计算图像一致性损失,如图12(b)所示。模型通过形状一致性和图像一致性损失的联合优化实现上采样,无需密集点云真值,显著提升了上采样质量。同时可微渲染损失也被用到PPU(Zhang等, 2021)中来保持点云整体结构。Nie等人(2025)提出的一种通过迭代掩码恢复网络实现自监督的任意尺度点云上采样方法SPU-IMR(self-supervised arbitrary-scale point cloud upsampling via iterative mask-recovery network),其核心思想是将输入点云划分为多个补丁,然后通过掩码操作移除一些补丁,仅留下可见的点云补丁。最后,通过自定义设计的神经网络迭代地利用可见部分补全缺失的点云部分。在测试阶段,通过选择不同的掩码序列,可以恢复不同的完整补丁,通过合并所有完成的补丁可以获得足够密集的上采样点云。

1.2.3 逆向构造监督

逆向构造监督通过下采样稀疏输入点云构建训练数据,实现自监督上采样,具体框架如图12(c)所示。Liu等人(2022c)提出的SPU-Net采用局部块级下采样—重建策略,将输入点云分割为多个局部块后,对每个块独立下采样生成粗粒度子块,再通过特征提取和分层折叠上采样重建原始块,从而学习点分布规律。该方法通过自投影损失优化生成点的几何分布,减少噪声。相比之下,Zhou等人(2022)提出的ZSPU(“zero-shot” point cloud upsampling)则采用整体零样本学习,直接对完整点云进行下采样生成低分辨率副本作为训练对,利用GAN架构渐进上采样,避免了分块方法中参数敏感和拓扑失真的问题。两种方法均依赖输入点云自身的下采样数据,但SPU-Net侧重局部规律学习,而ZSPU强调整体形状保持。

1.2.4 孪生网络关联监督

孪生网络关联监督依托孪生神经网络的对称结构与权重共享机制,无需依赖稀疏—密集点云的成对监督数据,通过双路径信息流捕捉几何结构的内在一致性,并利用路径间输出的对比差异进行自监督优化,有效应对真实密集点云难以获取的挑战。

UPU-SNet(Han 等, 2023)首次将孪生架构引入无监督上采样任务,其核心包括两条协同分支:一条重建原始点云以生成粗糙输出;另一条在共享特征提取模块的基础上进行特征扩展以生成稠密点云,如图 12(d)所示。该架构通过形状对比损失强化稀疏点云与粗糙重建之间的分布一致性,利用重建损失引导密集输出贴合输入点云所蕴含的曲面结构,并引入排斥损失以提升点的分布均匀性,从而在完全无标签的条件下实现端到端训练。

在后续工作 S³U-PVNet(Han 等, 2024)中,该团队进一步拓展了孪生架构的表达能力,使其适用于任意尺度的上采样任务。该方法设计了“下采样—上采样”(down-up)与“上采样—下采样”(up-down)两条路径。前者通过对稀疏输入下采样生成种子点云,再上采样得到密集种子点云;后者则直接将原始输入上采样至最大尺度,再下采样至目标尺度。两条路径在训练中通过相似性损失对齐输出结构,同时辅以重建损失约束密集种子点云与原始输入之间的几何一致性,从而实现尺度自适应的无监督建模。这两项工作充分展示了孪生网络在无监督点云上采样中的潜力,通过对称分支间的交叉监督机制构建强几何约束,使网络在缺乏真实密集标签的情况下,依然能够生成结构保真且分布均匀的高质量上采样结果。

1.2.5 小结

无监督式点云上采样方法核心理念是摆脱成对稀疏—密集点云数据的依赖,利用输入稀疏点云自身蕴含的结构信息或通过特定策略构造自监督信号来驱动模型学习上采样规律。其动机源于真实场景中获取高质量密集点云真值的困难。这类方法主要探索了多种自监督机制:1)利用稀疏输入本身(如 L2G-AE 通过自编码重建一下采样,SSAS 向隐式表面投影);2)对稀疏输入进行变换(如 SSPU-Net、PPU 通过可微渲染计算图像一致性损失,SPU-IMR 通过掩码恢复);3)对稀疏输入进行下采样以构造伪训练对(如 SPU-Net 分块下采样—重建、ZSPU 整体下采样);4)利用孪生网络架构(如 UPU-SNet、S³U-PVNet)构建对称路径,通过路径间输出的对比、重建或下采样一致性等损失进行约束。无监督方法的显著优点是大幅降低了对标注数据的依赖,提高了模型在真实无标签数据上的适用性,并激发了对点云内在几何特性的深入挖掘。然而,其主要缺点在于其性能通常仍难以超越精心设计的监督方法,尤其是在细节恢复和严格几何精度方面;同时,设计的自监督任务(如渲染损失、掩码恢复、孪生对比)的有效性和泛化能力仍需进一步验证和提升。无监督式点云上采样的主要工作如表 9 所示。

表 9 无监督式点云上采样的主要工作
Table 9 Major advances on unsupervised point cloud upsampling

方法	方法分类	关键思想
L2G-AE(Liu 等, 2019)	稀疏点云直接监督	通过局部到全局自编码器重建局部区域得到稠密点云再下采样至目标分辨率,实现无监督点云上采样
SSAS(Zhao 等, 2023b)	稀疏点云直接监督	利用隐式函数预测投影方向与距离,引导种子点向隐式表面靠近,结合异常修正提升稠密点质量
SPU-PMD(Liu 等, 2024b)	稀疏点云直接监督	通过网格插值与级联变形优化节点,基于输入输出点云的重建损失与均匀性损失进行自监督学习
SSPU-Net(Zhao 等, 2021b)	稀疏点云变换监督	通过可微渲染将稀疏密集点云转为多视图图像,利用图像一致性损失自监督优化上采样
SPU-IMR(Nie 等, 2025)	稀疏点云变换监督	将点云分块并掩码移除部分,设计迭代网络利用可见块预测缺失块,合并所有恢复块获得上采样结果
SPU-Net(Liu 等, 2022c)	逆向构造监督	分割点云为局部块,独立下采样后重建原始块来学习上采样规律,并通过自投影损失来减少噪声
ZSPU(Zhou 等, 2022)	逆向构造监督	采用零样本学习,整体下采样输入点云获得配对数据,避免分块来强调整体一致性
UPU-SNet(Han 等, 2023)	孪生网络关联监督	孪生双分支架构,一路重建稀疏点云,一路生成稠密点云,通过对比/重建/排斥损失实现无监督训练
S ³ U-PVNet(Han 等, 2024)	孪生网络关联监督	设计“下采样—上采样”和“上采样—下采样”双分支路径,通过相似性与重建损失自监督,对齐输出结果,并实现任意尺度点云上采样

2 常用数据集与评估指标

2.1 常用数据集

为了评价模型点云上采样的性能,本文采用PU-GAN(Li等,2019)、PU1K(point cloud upsampling 1K)(Qian等,2021a)和PUGeo(point cloud upsampling geometry dataset)(Qian等,2020)这3个公开数据集作为主要评估标准。此外,为了进一步验证模型在真实场景中的泛化能力和实用性,引入了ScanObjectNN(Uy等,2019)和KITTI(Geiger等,2013)两个使用激光雷达实际采集的点云数据集作为补充,具体示例图如图13所示。

2.1.1 合成数据集

1)PU-GAN数据集。于2019年由同名论文提出,它包含147个3D模型,其中120个用于训练,剩余27个用于测试。在训练阶段,遵循了原始论文中概述的流程。在测试阶段,由于PU-GAN数据集仅提供3D网格文件,通过在原始网格上应用泊松圆盘采样的方法生成输入点云和真实点云。其中,输入点云的点数设定为2 048点,真实点云的点数则为8 192点或32 768点,分别对应于4×和16×的上采样倍率。

2)PU1K数据集。由PU-GCN于2021年提出,与PU-GAN相比,PU1K数据集规模更大,包含1 147个

3D模型,其中1 020个用于训练,127个用于测试。在训练阶段,同样遵循了原始论文中的数据处理流程。在测试阶段,PU1K直接提供了测试输入点云和4×上采样倍率的真实点云数据,而对于16×的上采样倍率的真实值,在原始3D网格文件上应用泊松圆盘采样进行生成。

3)PUGeo数据集。由PUgeo-Net于2020年提出,特点是包含真实法线信息,可用于点云上采样的法线监督。该数据集从Sketchfab精选90个高分辨率3D网格构建训练集,13个模型构建测试集,采用泊松圆盘采样生成点云数据($N = 5\ 000$, $R = 4/8/12/16$),并随机裁剪为256点的小块进行训练。训练阶段应用统一的数据增强策略(随机缩放、旋转和点扰动),而测试阶段则使用干净数据且不依赖稀疏输入的法线信息。

2.1.2 实测数据集

与合成数据集不同,实测数据集通过激光雷达扫描获取,不附带密集点云标签,因此无法直接用于模型训练,也难以对上采样后的点云进行定量评估,一般仅能通过可视化方法进行定性比较。

1)ScanObjectNN。是一个包含约15 000个室内扫描点云对象的数据集,涵盖15个类别共计2 902个独立实例。每个点云对象均包含全局/局部坐标、法线、颜色属性以及语义标签信息。

2)KITTI数据集。由同名论文于2019年提出,




图13 点云上采样常用数据集示例图

Fig. 13 Examples of common datasets for point cloud upsampling
((a) PU-GAN; (b) PU1K; (c) PUGeo; (d) ScanObjectNN; (e) KITTI)

是计算机视觉与自动驾驶领域广泛使用的权威数据集之一。其点云数据采集自真实街道场景,通过车载激光雷达扫描得到,共包含 14 999 帧点云,每帧平均包含约 10^5 个点。

2.2 评估指标

点云上采样方法主要采用倒角距离(chamfer distance, CD)(Fan 等, 2017)、豪斯多夫距离(Hausdorff distance, HD)(Berger 等, 2013)和点到表面的距离(point-to-surface distance, P2F)(Low, 2004)作为评价指标。这些指标的值越低,表示上采样性能越好。上述评价指标可以表示如下:

1)倒角距离(CD)。倒角距离(CD)是一种用于评估两个点云集合之间整体相似性的度量方法。其核心思想是双向最近邻匹配。对于第 1 个点云中的每一个点,它会在第 2 个点云中寻找距离最近邻点,并计算它们之间的欧氏距离,然后将所有这些距离求和取平均。为了确保评估的对称性和公平性,该计算会反过来再进行一次(即从第 2 个点云到第 1 个点云)。最终距离是这两个方向上的平均距离之和。CD 值越小,说明两个点云在形状和空间分布上越接近。具体的计算式为

$$CD(S_1, S_2) = \frac{1}{|S_1|} \sum_{x \in S_1} \min_{y \in S_2} \|x - y\|_2^2 + \frac{1}{|S_2|} \sum_{y \in S_2} \min_{x \in S_1} \|y - x\|_2^2 \quad (1)$$

式中, S_1 表示预测的点云, S_2 表示真实的点云。 x 是属于 S_1 的某个点, y 是属于 S_2 的某个点, $\|\cdot\|_2^2$ 表示平方欧几里得范数。 $|S_1|$ 、 $|S_2|$ 分别表示 S_1 和 S_2 的总点数。 $\min_{y \in S_2} \|x - y\|_2^2$ 计算点 x 到点云 S_2 中所有点的欧氏距离,并取其中的最小值。 $\min_{x \in S_1} \|y - x\|_2^2$ 计算点 y 到点云 S_1 中所有点的欧氏距离,并取其中的最小值。

2)豪斯多夫距离(HD)。豪斯多夫距离(HD)衡量的是两个点云集合之间的最大不匹配程度。与 CD 关注整体平均距离不同,HD 寻找的是两个点云中“离得最远”的那个点。具体而言,它先计算从一个点云中所有点到另一个点云中点的最近距离,并取这些最近距离中的最大值,然后再反过来计算一次。最终的 HD 值是这两个最大值中的最大者。因此,HD 对异常值和局部大的误差非常敏感,常用于评估上采样质量的“最坏情况”。具体的计算式为

$$HD(S_1, S_2) =$$

$$\max \left\{ \sup_{x \in S_1} \inf_{y \in S_2} \|x - y\|_2, \sup_{y \in S_2} \inf_{x \in S_1} \|y - x\|_2 \right\} \quad (2)$$

式中, S_1 表示预测的点云, S_2 表示真实的点云。 $\sup$ 表示取最大值, $\inf$ 表示取最小值。 $\sup_{x \in S_1} \inf_{y \in S_2} \|x - y\|_2$ 的含义是,对于 S_1 中的每一个点 x , 计算该点到 S_2 中所有点 y 的距离,并取其中的最小值,即得到点 x 到 S_2 的最近距离 $\inf_{y \in S_2} \|x - y\|_2$, 随后在 S_1 中所有点对应的“到 S_2 的最近距离”里,取其中的最大值,最终结果即为 $\sup_{x \in S_1} \inf_{y \in S_2} \|x - y\|_2$ 。

3)点到平面的距离(P2F)。点到平面的距离(P2F)是一种用于衡量点云与真实表面之间几何偏差的度量方法。CD 和 HD 只计算点到点的距离,而 P2F 计算的是预测点云中的点到目标网格表面的垂直距离(即点到三角形面的法向距离)。这更能反映点云在几何表面上的贴合精度,因为点间距离较大并不一定意味着几何偏差大,例如某点可能远离其他点但仍贴近目标表面,其误差也可能很小。P2F 值越小,说明预测点云与目标表面贴合得越好。具体计算为

$$P2F(P_i, \Delta ABC) = \frac{|(P_i - A) \cdot n_i|}{\|n_i\|} \quad (3)$$

式中, P_i 表示预测点云中的第 i 个点, ΔABC 表示目标网格的一个三角形面片,由顶点 A, B, C 构成, n_i 表示三角形面片 ΔABC 的法向量,公式(3)表示点 P_i 到三角形所在平面的垂直距离。

3 部分算法性能比较

3.1 实验设置

为了客观评估各类点云上采样方法的性能,本文在 PU1K 和 PU-GAN 两个标准数据集上开展了全面的实验分析。实验中,所有原始点云均按照单块包含 256 个点的输入规格分割为若干个点云块,后续的训练与测试流程均基于该规格的点云块进行,以适配模型输入要求。所有实验均在统一硬件与软件环境中完成,确保实验条件的一致性:硬件方面配备一张 NVIDIA GeForce RTX 3080 GPU;软件方面采用 Ubuntu 20.04 LTS 操作系统,深度学习框架为 PyTorch 1.11.0 或者 tensorflow 1.15 (PU-Net、MPU、

PU-GCN), CUDA 版本为 10.8, 训练与测试流程均在此环境下执行。模型优化采用 Adam 优化器, 总训练周期设为 100 轮, 批大小(batch size)设置为 32; 初始学习率为 0.001, 训练过程中采用逐步衰减策略, 最终降至 0.000 1, 以平衡前期收敛速度与后期精度提升。为进一步增强模型泛化能力, 训练阶段引入了由 Qian 等人(2021a)提出的数据增强策略, 以降低过拟合风险。

通过系统性的实验对比, 本文综合评估了近年来主流点云上采样方法在 4 倍与 16 倍上采样任务中

的性能, 同时对比了各模型的参数量与计算规模(见表 10 与表 11)。评价指标涵盖前文所提到的 CD、HD 以及 P2F。

3.2 结果分析

在三段式点云上采样范式中, PU-Net(Yu 等, 2018)作为开创性工作, 奠定了特征提取、特征扩展和坐标重建的框架。其多尺度特征学习和层次化特征聚合为后续研究提供了基础, 但在 PU-GAN 和 PU1K 数据集上的表现较为一般, 因特征扩展采用简单的复制和折叠操作, 新生成点易聚集于原始点附

表 10 在 PU1K 数据集上代表性方法实验结果对比
Table 10 Experimental results comparison of representative methods on PU1K dataset

代表方法	4×			16×		
	CD/×10 ⁻³	HD/×10 ⁻³	P2F/×10 ⁻³	CD/×10 ⁻³	HD/×10 ⁻³	P2F/×10 ⁻³
PU-Net(Yu 等, 2018)	1.155	15.170	4.834	1.512	24.125	7.296
MPU(Wang 等, 2019c)	0.935	13.327	3.551	1.184	22.120	5.263
PU-GAN(Li 等, 2019)	0.667	9.197	2.877	0.821	14.075	4.025
Dis-PU(Li 等, 2021a)	1.135	14.570	3.602	1.282	19.378	4.991
PU-GCN(Qian 等, 2021a)	0.585	7.577	2.499	0.842	14.538	3.631
Grad-PU(He 等, 2023)	0.404	3.732	1.474	0.343	4.239	1.618
PU-Flow(Mao 等, 2022)	<u>0.361</u>	<u>3.102</u>	1.324	0.267	3.672	1.416
APU-LDI(Li 等, 2024)	0.371	3.197	<u>1.111</u>	<u>0.244</u>	<u>3.400</u>	<u>1.239</u>
RepKPU(Rong 等, 2024)	0.327	2.774	0.933	0.217	3.050	0.985

注: 加粗、下划线字体表示各列最优、次优结果。

表 11 在 PU-GAN 数据集上代表性方法实验结果对比
Table 11 Experimental results comparison of representative methods on PU-GAN dataset

代表方法	4×			16×			参数量/KB	模型规模/MB
	CD/×10 ⁻³	HD/×10 ⁻³	P2F/×10 ⁻³	CD/×10 ⁻³	HD/×10 ⁻³	P2F/×10 ⁻³		
PU-Net(Yu 等, 2018)	0.542	4.476	4.953	0.528	7.007	6.352	812	10.1
MPU(Wang 等, 2019c)	0.298	4.062	2.712	0.177	5.530	3.023	76.2	6.2
PU-GAN(Li 等, 2019)	0.268	5.590	1.942	0.209	6.689	2.555	684.2	9.57
Dis-PU(Li 等, 2021a)	0.277	6.804	2.015	0.167	7.652	2.261	1 047	13.2
PU-GCN(Qian 等, 2021a)	0.282	2.853	2.530	0.180	4.252	2.654	<u>76</u>	<u>1.8</u>
PUFA-GAN(Liu 等, 2022b)	<u>0.250</u>	7.774	1.929	0.130	9.032	2.141	4 935	11.6
PU-Flow(Mao 等, 2022)	0.285	3.572	1.982	0.128	2.669	2.385	806	3.22
Grad-PU(He 等, 2023)	0.245	2.369	<u>1.893</u>	<u>0.108</u>	<u>2.338</u>	2.127	67.1	0.392
RepKPU(Rong 等, 2024)	0.259	<u>2.751</u>	1.872	0.095	1.808	<u>2.130</u>	1 013.3	4.2

注: 加粗、下划线字体表示各列最优、次优结果。

近,导致分布均匀性较差,且无法灵活支持任意倍率上采样。MPU(Wang等,2019c)通过渐进式上采样显著提升性能,在PU-GAN和PU1K数据集上均优于PU-Net,其分阶段处理能够有效减少细节丢失,但两阶段训练增加了训练负担。Dis-PU(Li等,2021a)在坐标重建阶段引入几何校正模块,融合局部与全局特征优化粗糙点云,试图解决点分布不均和异常点问题,但在PU1K数据集上的精度提升有限,部分指标甚至低于MPU,且参数量和推理时间较高,显示出仅依赖后处理优化的局限性。

PU-GCN(Qian等,2021a)通过引入InceptionDenseGCN和NodeShuffle模块显著优化三段式方法,在PU-GAN数据集四倍上采样下表现出色,精度大幅提升,同时参数量和推理时间显著降低,展现出高效的局部几何感知能力。然而,其仍受限于固定倍率设计,且坐标预测精度不足,在高倍率任务中易产生收缩伪影。

生成式方法通过学习点云潜在分布生成高保真点云。PU-GAN(Li等,2019)作为首个基于生成对抗网络的点云上采样模型,在PU-GAN和PU1K数据集上优于同期MPU,其up-down-up特征扩展策略增强细节生成,均匀性损失优化点云分布,但参数量较大且训练不稳定。PUFA-GAN(Liu等,2022b)引入频率感知机制,通过优化高频细节进一步提升性能,在PU-GAN数据集上展现出优异分布均匀性和细节恢复能力,但异常点抑制能力不足,且高参数量和长推理时间限制了实时应用。PU-Flow(Mao等,2022)基于归一化流模型,在PU-GAN和PU1K数据集上显示出较好的精度,异常点抑制能力优于PUFA-GAN,凸显归一化流的潜力,但计算开销仍较高。

Grad-PU(He等,2023)代表几何扩充—坐标优化范式,在PU-GAN和PU1K数据集上表现突出,接近或达到最优。其插值—细化策略通过中点插值生成任意倍率中间点云,并利用梯度下降和学习距离函数优化点位置,有效避免异常点和收缩伪影。相比三段式和生成式方法,Grad-PU在精度和轻量化上优势显著,特别适合任意倍率场景,但分块处理可能导致点云孔洞和不均匀分布。

APU-LDI(Li等,2024)作为表面重建式方法的代表,利用隐式距离场引导点投影,在PU1K数据集上全面优于Grad-PU,恢复整体几何形状能力卓越,但需先后训练局部距离指示器和全局隐式函数,训

练复杂度较高。

RepKPU(Rong等,2024)在三段式框架上引入核点变形范式,在PU-GAN和PU1K数据集的多个倍率和指标上均取得最优或次优成绩,综合性能最强。其通过交叉注意力机制将核点查询转换为位移特征,结合RepKPoints表示增强复杂拓扑适应性,并借鉴Grad-PU实现任意倍率上采样。然而,其参数量和推理时间较Grad-PU高,实时性仍需优化。

不同方法在PU-GAN和PU1K数据集上的性能差异反映了其泛化能力的不同。PU-GAN数据集以基础合成模型为主,点云分布较为均匀,而PU1K包含更多复杂几何和非均匀分布的点云,对模型泛化能力要求更高。PU-Net在两个数据集上的表现较为稳定但精度较低,反映出其简单架构的局限性。MPU和PU-GAN在PU1K上的性能优于PU-GAN数据集,显示出渐进式和生成式方法对复杂点云的较好适应性。Grad-PU和RepKPU在PU1K上的表现显著优于PU-GAN数据集,表明插值—细化和核点变形策略对非均匀点云的强大泛化能力。PUFA-GAN在PU-GAN数据集上的异常点抑制能力较弱,可能因训练数据分布差异导致过拟合。APU-LDI在PU1K上的优异表现凸显了表面重建式方法在复杂拓扑上的泛化优势,但高训练复杂度可能限制其在多样化场景中的应用。总体来看,几何扩充—坐标优化和表面重建式方法在泛化能力上优于三段式和生成式方法,未来需进一步优化模型对真实场景点云(如KITTI)的适应性,以提升跨数据集的鲁棒性。

4 结 语

本文全面回顾了基于深度学习的点云上采样技术的研究进展。从早期以PU-Net为代表的监督式方法,到逐渐兴起的自监督与无监督方法,深度学习通过数据驱动的特征学习突破了传统几何优化方法的局限性,显著提升了点云密度、均匀性和几何细节的恢复能力。监督式方法通过三段式、渐进式和生成式等多种架构实现了高效的点云稠密化,尤其在固定倍率上采样任务中表现出色。无监督方法则通过利用点云内在几何特性或自监督信号,降低了数据标注依赖,推动了真实场景应用的可能。此外,基于表面重建的方法通过显式或隐式表面建模,进一步提升了点云的几何一致性与灵活性。然而,尽管

当前方法在点云上采样中获得了巨大进展,但仍然存在一些局限性。针对这些局限性,本文提出以下展望:

1)自适应任意倍率上采样策略。当前的点云上采样技术大多聚焦于固定的上采样倍率进行优化。虽然已有部分方法能够实现任意倍率的上采样,但这些方法多以整个点云为处理对象,采用统一的上采样倍率。然而,在实际应用场景中,点云的稀疏程度在不同区域存在显著差异,这就导致不同区域可能需要不同的上采样倍率。例如,在物体边缘及细节丰富的区域,通常需要更高的上采样倍率来精准恢复精细的几何结构;而在相对平坦的区域,则可采用较低的上采样倍率,以减轻计算负担。鉴于此,未来的研究方向可以着重探索更为灵活的上采样策略,使模型能够依据点云中不同区域的稀疏度,智能地调整上采样倍率。

2)对点云复杂拓扑结构的适应性。深度学习驱动的点云上采样技术依赖于有效的特征提取方法来获取关键信息,这些特征对于后续的上采样和坐标优化至关重要。然而,复杂拓扑结构的特征提取一直是该领域的关键挑战。目前,大多数方法主要基于 PointNet、DGCNN 和 Transformer 等基础模型进行特征提取。尽管这些模型在处理简单结构时表现出色,但在面对复杂拓扑结构时,如尖锐边缘、细粒度细节和非均匀分布,它们的性能往往会受到限制。为了更好地应对这一挑战,未来的研究可以借鉴点云分类与分割领域中先进的网络架构和特征提取技术。例如,引入更复杂的图卷积网络(GCN)结构,能够更有效地捕捉点云中的局部几何关系;采用 Transformer 架构的变体,通过增强的注意力机制更好地处理长距离依赖和全局结构信息。此外,未来可深入探索多模态融合技术,通过整合 RGB 图像的纹理信息、深度图的空间线索或视频的时序特征,提升点云上采样的质量与鲁棒性。这些技术可以为点云上采样提供更丰富的上下文信息,从而更好地处理复杂拓扑结构。

3)实时性点云上采样。当前,大多数基于深度学习的点云上采样方法由于网络结构复杂,难以满足现实场景中实时处理的需求。尤其是基于生成模型的点云上采样方法,虽然在上采样性能上表现出色,但往往伴随着网络复杂度高、训练不稳定等问题。这些问题严重限制了这些方法在实时性要求较

高的应用场景中的实用性。为了克服这些挑战,未来的研究需要着重探索在保证上采样质量的同时,降低模型复杂度和提高推理速度的方法。

4)深化无监督点云上采样方法。现有的点云上采样方法大多依赖合成数据集训练,与真实场景点云的分布差异显著,限制了实际应用效果。无监督学习通过挖掘点云内在几何特性或设计自监督任务,能够有效降低对标注数据的依赖。未来的研究可以探索更鲁棒的无监督点云上采样框架,以提升模型对真实点云的适应性。

参考文献(References)

- Alexa M, Behr J, Cohen-Or D, Fleishman S, Levin D and Silva C T. 2003. Computing and rendering point set surfaces. *IEEE Transactions on Visualization and Computer Graphics*, 9(1): 3-15 [DOI: 10.1109/TVCG.2003.1175093]
- Bai Y C, Wang X G, Ang Jr M H and Rus D. 2022. BIMS-PU: bi-directional and multi-scale point cloud upsampling. *IEEE Robotics and Automation Letters*, 7(3): 7447-7454 [DOI: 10.1109/lra.2022.3183932]
- Berger M, Levine J A, Nonato L G, Taubin G and Silva C T. 2013. A benchmark for surface reconstruction. *ACM Transactions on Graphics (TOG)*, 32(2): #20 [DOI: 10.1145/2451236.2451246]
- Cai P P, Wu Z Y, Wu X Y and Wang S. 2023. Parametric surface constrained upsampler network for point cloud//*Proceedings of the 38th AAAI Conference on Artificial Intelligence*. Washington, USA: AAAI: 250-258 [DOI: 10.1609/aaai.v37i1.25097]
- Charles R Q, 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]
- Charles R Q, 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
- Chen Y Y, Tian D X, Lin C M and Yin H B. 2024. Survey of end-to-end autonomous driving systems. *Journal of Image and Graphics*, 29(11): 3216-3237 (陈妍妍, 田大新, 林椿昝, 殷鸿博. 2024. 端到端自动驾驶系统研究综述. *中国图象图形学报*, 29(11): 3216-3237) [DOI: 10.11834/jig.230787]
- Dell'Eva A, Orsingher M and Bertozzi M. 2022. Arbitrary point cloud upsampling with spherical mixture of Gaussians//*Proceedings of 2022 International Conference on 3D Vision*. Prague, Czech Republic: IEEE: 465-474 [DOI: 10.1109/3DV57658.2022.00058]

- Deng Y Z, Su Z H, Shang P H, Liu D Z, Wu D, Zou J X, et al. 2025. GraphDAE-PU: graph denosing auto-encoder for arbitrary-scale point cloud upsampling//Proceedings of 2025 IEEE International Conference on Acoustics, Speech and Signal Processing. Hyderabad, India: IEEE: 1-5 [DOI: 10.1109/ICASSP49660.2025.10890792]
- Devlin J, Chang M W, Lee K and Toutanova K. 2019. BERT: pre-training of deep bidirectional transformers for language understanding//Proceedings of 2019 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies. Minneapolis, Minnesota, USA: Association for Computational Linguistics: 4171-4186 [DOI: 10.18653/v1/N19-1423]
- Ding D D, Qiu C, Liu F C and Pan Z G. 2021. Point cloud upsampling via perturbation learning. IEEE Transactions on Circuits and Systems for Video Technology, 31(12): 4661-4672 [DOI: 10.1109/TCSVT.2021.3099106]
- Dosovitskiy A, Beyer L, Kolesnikov A, Weissenborn D, Zhai X H, Unterthiner T, et al. 2021. An image is worth 16 × 16 words: Transformers for image recognition at scale//Proceedings of the 9th International Conference on Learning Representations. [s. l.]: OpenReview.net
- Du H, Yan X J, Wang J J, Xie D and Pu S L. 2023. Point cloud upsampling via cascaded refinement network//Proceedings of the 16th Asian Conference on Computer Vision. Macao, China: Springer: 510686-122 [DOI: 10.1007/978-3-031-26319-4_7]
- Du H, Yan X J, Wang J J, Xie D and Pu S L. 2024. Arbitrary-scale point cloud upsampling by voxel-based network with latent geometric-consistent learning//Proceedings of the 38th AAAI Conference on Artificial Intelligence. Vancouver, Canada: AAAI: 1626-1634 [DOI: 10.1609/aaai.v38i2.27929]
- 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]
- Feng W Q, Li J, Cai H R, Luo X N and Zhang J Y. 2022. Neural points: point cloud representation with neural fields for arbitrary upsampling//Proceedings of 2022 IEEE/CVF Conference on Computer Vision and Pattern Recognition. New Orleans, USA: IEEE: 18612-18621 [DOI: 10.1109/cvpr52688.2022.01808]
- Floridi L and Chiriatti M. 2020. GPT-3: its nature, scope, limits, and consequences. Minds and Machines, 30(4): 681-694 [DOI: 10.1007/s11023-020-09548-1]
- Geiger A, Lenz P, Stiller C and Urtasun R. 2013. Vision meets robotics: the KITTI dataset. The International Journal of Robotics Research, 32(11): 1231-1237 [DOI: 10.1177/0278364913491297]
- Goodfellow I J, Pouget-Abadie J, Mirza M, Xu B, Warde-Farley D, Ozair S, et al. 2014. Generative adversarial nets//Proceedings of the 28th International Conference on Neural Information Processing Systems. Montreal, Canada: MIT Press: 2672-2680
- Gu F, Zhang C L, Wang H Y, He Q and Huo L Z. 2022. PU-WGCN: point cloud upsampling using weighted graph convolutional networks. Remote Sensing, 14(21): #5356 [DOI: 10.3390/rs14215356]
- Han B, Deng L X, Zheng Y and Ren S. 2023. UPU-SNet: siamese network for unsupervised point cloud upsampling based on spatial-aware transformers. Computers and Graphics, 115: 484-499 [DOI: 10.1016/j.cag.2023.07.037]
- Han B, Deng L X, Zheng Y and Ren S. 2024. S³U-PVNet: arbitrary-scale point cloud upsampling via point-voxel network based on siamese self-supervised learning. Computer Vision and Image Understanding, 239: #103890 [DOI: 10.1016/j.cviu.2023.103890]
- Han B, Deng L X, Zheng Y and Ren S. 2024. Survey of 3D point clouds upsampling methods. Computer Science, 51(7): 167-196 (韩冰, 邓理想, 郑毅, 任爽. 2024. 三维点云上采样方法研究综述. 计算机科学, 51(7): 167-196) [DOI: 10.11896/j.sjkk.230900110]
- Han B, Zhang X Y and Ren S. 2022. PU-GACNet: graph attention convolution network for point cloud upsampling. Image and Vision Computing, 118: #104371 [DOI: 10.1016/j.imavis.2021.104371]
- Han Y Z, Yin M X, Yang F and Zhong C. 2025. Survey of point cloud upsampling based on deep learning. Journal of Chinese Computer Systems, 46(3): 645-654 (韩亚振, 尹梦晓, 杨锋, 钟诚. 2025. 深度学习驱动的点云上采样研究综述. 小型微型计算机系统, 46(3): 645-654) [DOI: 10.20009/j.cnki.21-1106/TP.2024-0377]
- Hart J C. 1996. Sphere tracing: a geometric method for the antialiased ray tracing of implicit surfaces. The Visual Computer, 12(10): 527-545 [DOI: 10.1007/s003710050084]
- He K M, Zhang X Y, Ren S Q and Sun J. 2016. Deep residual learning for image recognition//Proceedings of 2016 IEEE Conference on Computer Vision and Pattern Recognition. Las Vegas, USA: IEEE: 770-778 [DOI: 10.1109/cvpr.2016.90]
- He Y, Tang D H, Zhang Y D, Xue X Y and Fu Y W. 2023. GRAD-PU: arbitrary-scale point cloud upsampling via gradient descent with learned distance functions//Proceedings of 2023 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Vancouver, Canada: IEEE: 5354-5363 [DOI: 10.1109/CVPR52729.2023.00518]
- Ho J, Jain A and Abbeel P. 2020. Denoising diffusion probabilistic models//Proceedings of the 34th Conference on Neural Information Processing Systems. Vancouver, Canada: NeurIPS: 6840-6851
- Hu X, Wei X and Sun J. 2023. A noising-denoising framework for point cloud upsampling via normalizing flows. Pattern Recognition, 140: #109569 [DOI: 10.1016/j.patcog.2023.109569]
- Huang H, Li D, Zhang H, Ascher U and Cohen-Or D. 2009. Consolidation of unorganized point clouds for surface reconstruction. ACM Transactions on Graphics (TOG), 28(5): 1-7 [DOI: 10.1145/1618452.1618522]
- Huang H, Wu S H, Gong M L, Cohen-Or D, Ascher U and Zhang H. 2013. Edge-aware point set resampling. ACM Transactions on Graphics (TOG), 32(1): #9 [DOI: 10.1145/2421636.2421645]

- Irani M and Peleg S. 1993. Motion analysis for image enhancement: resolution, occlusion, and transparency. *Journal of Visual Communication and Image Representation*, 4 (4) : 324-335 [DOI: 10.1006/jvci.1993.1030]
- Jia M D, Yang J M, Meng W L, Guo J W, Zhang J G and Zhang X P. 2024. Survey on the fusion of point clouds and images for environmental object detection. *Journal of Image and Graphics*, 29 (6) : 1765-1784 (贾明达, 杨金明, 孟维亮, 郭建伟, 张吉光, 张晓鹏. 2024. 融合点云与图像的环境目标检测研究进展. *中国图象图形学报*, 29(6): 1765-1784) [DOI: 10.11834/jig.240030]
- Kim D, Kwon H, Kim Y and Hwang S J. 2025. Platypus: progressive local surface estimator for arbitrary-scale point cloud upsampling// *Proceedings of the 39th AAAI Conference on Artificial Intelligence*. Philadelphia, USA: AAAI: 4239-4247 [DOI: 10.1609/aaai.v39i4.32445]
- Kim D, Shin M and Paik J. 2023. PU-edgeformer: edge transformer for dense prediction in point cloud upsampling//*Proceedings of 2023 IEEE International Conference on Acoustics, Speech and Signal Processing*. Rhodes Island, Greece: IEEE: 1-5 [DOI: 10.1109/icassp49357.2023.10095541]
- Kim D, Shin M, Ryu J, Lim H and Paik J. 2024. Pu-edgeformer++: an advanced hierarchical edge transformer for arbitrary-scale point cloud upsampling using distance fields//*Proceedings of 2024 IEEE International Conference on Acoustics, Speech and Signal Processing*. Seoul, Korea (South) : IEEE: 6230-6234 [DOI: 10.1109/ICASSP48485.2024.10446941]
- Kumbar A, Anvekar T, Tabib R A and Mudanagudi U. 2023a. ASUR3D: arbitrary scale upsampling and refinement of 3D point clouds using local occupancy fields//*Proceedings of 2023 IEEE/CVF International Conference on Computer Vision Workshops*. Paris, France: IEEE: 1644-1653 [DOI: 10.1109/ICCVW60793.2023.00180]
- Kumbar A, Anvekar T, Vikrama T A, Tabib R A and Mudanagudi U. 2023b. TP-NoDe: Topology-aware progressive noising and denoising of point clouds towards upsampling//*Proceedings of 2023 IEEE/CVF International Conference on Computer Vision Workshops*. Paris, France: IEEE: 2264-2274 [DOI: 10.1109/ICCVW60793.2023.00241]
- Ledig C, Theis L, Huszár F, Caballero J, Cunningham A, Acosta A, et al. 2017. Photo-realistic single image super-resolution using a generative adversarial network//*Proceedings of 2017 IEEE Conference on Computer Vision and Pattern Recognition*. Honolulu, USA: IEEE: 105-114 [DOI: 10.1109/CVPR.2017.19]
- Li H Y, Yang Y F, Chang M, Chen S Q, Feng H J, Xu Z H, et al. 2022a. SRDiff: single image super-resolution with diffusion probabilistic models. *Neurocomputing*, 479: 47-59 [DOI: 10.1016/j.neucom.2022.01.029]
- Li R H, Li X Z, Fu C W, Cohen-Or D and Heng P A. 2019. PU-GAN: a point cloud upsampling adversarial network//*Proceedings of 2019 IEEE/CVF International Conference on Computer Vision*. Seoul, Korea (South) : IEEE: 7202-7211 [DOI: 10.1109/iccv.2019.00730]
- Li R H, Li X Z, Heng P A and Fu C W. 2021a. 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]
- Li S J, Zhou J S, Ma B R, Liu Y S and Han Z Z. 2024. Learning continuous implicit field with local distance indicator for arbitrary-scale point cloud upsampling//*Proceedings of the 38th AAAI Conference on Artificial Intelligence*. Vancouver, Canada: AAAI: 3181-3189 [DOI: 10.1609/aaai.v38i4.28102]
- Li X M, Own C M, Wu K Z and Sun Q. 2021b. CM-Net: a point cloud upsampling network based on adversarial neural network//*Proceedings of 2021 International Joint Conference on Neural Networks*. Shenzhen, China: IEEE: 1-8 [DOI: 10.1109/IJCNN52387.2021.9533464]
- Li Z Z, Li G, Li T H, Liu S and Gao W. 2023. Semantic point cloud upsampling. *IEEE Transactions on Multimedia*, 25: 3432-3442 [DOI: 10.1109/TMM.2022.3160604]
- Li Z Z, Wang W M, Lei N and Wang R. 2022b. Weakly supervised point cloud upsampling VIA optimal transport//*Proceedings of 2022 IEEE International Conference on Acoustics, Speech and Signal Processing*. Singapore, Singapore: IEEE: 2564-2568 [DOI: 10.1109/ICASSP43922.2022.9746972]
- Lim S, El-Basyouny K and Yang Y H. 2024. PU-Ray: domain-independent point cloud upsampling via ray marching on neural implicit surface. *IEEE Transactions on Intelligent Transportation Systems*, 25 (10) : 14600-14610 [DOI: 10.1109/TITS.2024.3388276]
- Lipman Y, Cohen-Or D, Levin D and Tal-Ezer H. 2007. Parameterization-free projection for geometry reconstruction. *ACM Transactions on Graphics (ToG)*, 26(3) : #22-es [DOI: 10.1145/1276377.1276405]
- Liu H, Yuan H, Hamzaoui R, Gao W and Li S. 2022a. PU-Refiner: a geometry refiner with adversarial learning for point cloud upsampling//*Proceedings of 2022 IEEE International Conference on Acoustics, Speech and Signal Processing*. Singapore, Singapore: IEEE: 2270-2274 [DOI: 10.1109/icassp43922.2022.9746373]
- Liu H, Yuan H, Hamzaoui R, Liu Q and Li S. 2024a. PU-Mask: 3D point cloud upsampling via an implicit virtual mask. *IEEE Transactions on Circuits and Systems for Video Technology*, 34(7) : 6489-6502 [DOI: 10.1109/tesvt.2024.3370001]
- Liu H, Yuan H, Hou J H, Hamzaoui R and Gao W. 2022b. PUFA-GAN: a frequency-aware generative adversarial network for 3D point cloud upsampling. *IEEE Transactions on Image Processing*, 31: 7389-7402 [DOI: 10.1109/TIP.2022.3222918]
- Liu H D, Sun X H, Li Y B, Han L and Zhang Y. 2025. Review of deep learning models for image classification based on convolutional neu-

- ral networks. *Computer Engineering and Applications*, 61(11): 1-21 (刘鸿达, 孙旭辉, 李沂滨, 韩琳, 张宇. 2025. 基于卷积神经网络的图像分类深度学习模型综述. *计算机工程与应用*, 61(11): 1-21) [DOI: 10.3778/j.issn.1002-8331.2411-0196]
- Liu K, Wang X and Zhu Y F. 2024. Visual perception method for cotton-picking robots based on fusion of multi-view 3D point clouds. *Transactions of the Chinese Society for Agricultural Machinery*, 55(4): 74-81 (刘坤, 王晓, 朱一帆. 2024. 基于多视角三维点云融合的采棉机器人视觉感知方法. *农业机械学报*, 55(4): 74-81) [DOI: 10.6041/j.issn.1000-1298.2024.04.007]
- Liu X H, Han Z Z, Wen X, Liu Y S and Zwicker M. 2019. L2G auto-encoder: Understanding point clouds by local-to-global reconstruction with hierarchical self-attention//*Proceedings of the 27th ACM International Conference on Multimedia*. Nice, France: ACM: 989-997 [DOI: 10.1145/3343031.3350960]
- Liu X H, Liu X C, Liu Y S and Han Z Z. 2022c. SPU-Net: self-supervised point cloud upsampling by coarse-to-fine reconstruction with self-projection optimization. *IEEE Transactions on Image Processing*, 31: 4213-4226 [DOI: 10.1109/TIP.2022.3182266]
- Liu Y Z, Chen R, Li Y S, Li Y X and Tan X H. 2024b. SPU-PMD: self-supervised point cloud upsampling via progressive mesh deformation//*Proceedings of 2024 IEEE/CVF Conference on Computer Vision and Pattern Recognition*. Seattle, USA: IEEE: 5188-5197 [DOI: 10.1109/cvpr52733.2024.00496]
- Liu Z S, He C H and Li L. 2025. Efficient point clouds upsampling via flow matching [EB/OL]. [2025-07-10]. <https://arxiv.org/pdf/2501.15286.pdf>
- Long C, Zhang W X, Li R H, Wang H, Dong Z and Yang B S. 2022. PC²-PU: patch correlation and point correlation for effective point cloud upsampling//*Proceedings of the 30th ACM International Conference on Multimedia*. Lisboa, Portugal: ACM: 2191-2201 [DOI: 10.1145/3503161.3547777]
- Lowe K L. 2004. *Linear Least-Squares Optimization for Point-to-Plane ICP Surface Registration*. University of North Carolina
- Lugmayr A, Danelljan M, Van Gool L and Timofte R. 2020. SRFlow: learning the super-resolution space with normalizing flow//*Proceedings of the 16th European Conference on Computer Vision*. Glasgow, UK: Springer: 715-732 [DOI: 10.1007/978-3-030-58558-7_42]
- Luo L Q, Tang L L, Zhou W Y, Wang S Z and Yang Z X. 2021. PU-EVA: an edge-vector based approximation solution for flexible-scale point cloud upsampling//*Proceedings of 2021 IEEE/CVF International Conference on Computer Vision*. Montreal, Canada: IEEE: 16188-16197 [DOI: 10.1109/ICCV48922.2021.01590]
- Luo S T and Hu W. 2021a. Diffusion probabilistic models for 3d point cloud generation//*Proceedings of 2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition*. Nashville, USA: IEEE: 2836-2844 [DOI: 10.1109/cvpr46437.2021.00286]
- Luo S T and Hu W. 2021b. 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]
- Lyu Z Y, Kong Z F, Xu X D, Pan L and Lin D H. 2021. A conditional point diffusion-refinement paradigm for 3D point cloud completion//*Proceedings of the 10th International Conference on Learning Representations*. [s.l.]: OpenReview.net: #2022
- Mao A H, Du Z H, Hou J H, Duan Y Q, Liu Y J and He Y. 2022. PU-Flow: a point cloud upsampling network with normalizing flows. *IEEE Transactions on Visualization and Computer Graphics*, 29(12): 4964-4977 [DOI: 10.1109/TVCG.2022.3196334]
- Mao A H, Duan Y Q, Wen Y H, Du Z H, Cai H M and Liu Y J. 2023. Invertible residual neural networks with conditional injector and interpolator for point cloud upsampling//*Proceedings of the 32nd International Joint Conference on Artificial Intelligence*. Macao, China: ijcai.org: 1267-1275 [DOI: 10.24963/ijcai.2023/141]
- Mescheder L, Oechsle M, Niemeyer M, Nowozin S and Geiger A. 2019. Occupancy networks: learning 3D reconstruction in function space//*Proceedings of 2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition*. Long Beach, USA: IEEE: 4455-4465 [DOI: 10.1109/CVPR.2019.00459]
- Nie Z M, Wu Q, Lyu C L, Quan S W, Qi Z S, Wang M Z, et al. 2025. SPU-IMR: self-supervised arbitrary-scale point cloud upsampling via iterative mask-recovery network//*Proceedings of the 39th AAAI Conference on Artificial Intelligence*. Philadelphia, USA: AAAI: 6236-6244 [DOI: 10.1609/aaai.v39i6.32667]
- Pan S H, Xu Y and Xu R T. 2024. PU-SDF: arbitrary-scale uniformly upsampling point clouds via signed distance functions//*Proceedings of 2024 International Conference on 3D Vision*. Davos, Switzerland: IEEE: 1320-1329 [DOI: 10.1109/3DV62453.2024.00119]
- Qian G C, Abualshour A, Li G H, Thabet A and Ghanem B. 2021a. PU-GCN: point cloud upsampling using graph convolutional networks//*Proceedings of 2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition*. Nashville, USA: IEEE: 11678-11687 [DOI: 10.1109/cvpr46437.2021.01151]
- Qian Y, Hou J H, Kwong S and He Y. 2020. PUGeo-Net: a geometry-centric network for 3D point cloud upsampling//*Proceedings of the 16th European Conference on Computer Vision*. Glasgow, UK: Springer: 752-769 [DOI: 10.1007/978-3-030-58529-7_44]
- Qian Y, Hou J H, Kwong S and He Y. 2021b. Deep magnification-flexible upsampling over 3D point clouds. *IEEE Transactions on Image Processing*, 30: 8354-8367 [DOI: 10.1109/TIP.2021.3115385]
- Qiu S, Anwar S and Barnes N. 2022. PU-transformer: point cloud upsampling transformer//*Proceedings of the 16th Asian Conference on Computer Vision*. Macao, China: Springer: 326-343 [DOI: 10.1007/978-3-031-26319-4_20]
- Qu W T, Shao Y T, Meng L W, Huang X S and Xiao L. 2024. A conditional denoising diffusion probabilistic model for point cloud upsam-

- pling//Proceedings of 2024 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Seattle, USA: IEEE: 20786-20795 [DOI: 10.1109/cvpr52733.2024.01964]
- Rezende D and Mohamed S. 2015. Variational inference with normalizing flows//Proceedings of the 32nd International Conference on Machine Learning. Lille, France: JMLR.org: 1530-1538
- Rong Y, Zhou H R, Xia K, Mei C, Wang J H and Lu T. 2024. Rep-KPU: point cloud upsampling with kernel point representation and deformation//Proceedings of 2024 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Seattle, USA: IEEE: 21050-21060 [DOI: 10.1109/cvpr52733.2024.01989]
- Shao Y H, Zhang D, Chu H Y, Zhang X Q and Rao Y B. 2022. Review of YOLO object detection based on deep learning. *Journal of Electronics and Information Technology*, 44(10): 3697-3708 (邵延华, 张铎, 楚红雨, 张晓强, 饶云波. 2022. 基于深度学习的YOLO目标检测综述. *电子与信息学报*, 44(10): 3697-3708) [DOI: 10.11999/JEIT210790]
- Sharma R, Schwandt T, Kunert C, Urban S and Broll W. 2021. Point cloud upsampling and normal estimation using deep learning for robust surface reconstruction//Proceedings of the 16th International Joint Conference on Computer Vision, Imaging and Computer Graphics Theory and Applications. [s. l.]: SciTePress: 70-79 [DOI: 10.5220/0010211600700079]
- Shi W Z, Caballero J, Huszár F, Totz J, Aitken A P, Bishop R, et al. 2016. Real-time single image and video super-resolution using an efficient sub-pixel convolutional neural network//Proceedings of 2016 IEEE Conference on Computer Vision and Pattern Recognition. Las Vegas, USA: IEEE: 1874-1883 [DOI: 10.1109/cvpr.2016.207]
- Sohl-Dickstein J, Weiss E, Maheswaranathan N and Ganguli S. 2015. Deep unsupervised learning using nonequilibrium thermodynamics//Proceedings of the 32nd International Conference on Machine Learning. Lille, France: JMLR.org: 2256-2265
- Tang X L, Shao F, Chai X L, Chen H W, Jiang Q P, Meng X C, et al. 2025. HFCI-PU: high-frequency compensation interpolation network for point cloud upsampling. *IEEE Transactions on Instrumentation and Measurement*, 74: #5004314 [DOI: 10.1109/TIM.2024.3500074]
- Thomas H, Qi C R, Deschaud J E, Marcotegui B, Goulette F and Guibas L. 2019. KPConv: flexible and deformable convolution for point clouds//Proceedings of 2019 IEEE/CVF International Conference on Computer Vision. Seoul, Korea (South): IEEE: 6410-6419 [DOI: 10.1109/iccv.2019.00651]
- Uy M A, Pham Q H, Hua B S, Nguyen D and Yeung S K. 2019. Revisiting point cloud classification: a new benchmark dataset and classification model on real-world data//Proceedings of 2019 IEEE/CVF International Conference on Computer Vision. Seoul, Korea (South): IEEE: 1588-1597 [DOI: 10.1109/ICCV.2019.00167]
- Vaswani A, Shazeer N, Parmar N, Uszkoreit J, Jones L, Gomez A N, et al. 2017. Attention is all you need//Proceedings of the 31st International Conference on Neural Information Processing Systems. Long Beach, USA: Curran Associates Inc.: 6000-6010
- Wang J, Chen J D, Shi Y H, Ling N and Yin B C. 2023a. SSPU-Net: a structure sensitive point cloud upsampling network with multi-scale spatial refinement//Proceedings of the 31st ACM International Conference on Multimedia. Ottawa, Canada: ACM: 1546-1555 [DOI: 10.1145/3581783.3613807]
- Wang X, Li Y, Wang L N and Lu L. 2023b. CFNet: point cloud upsampling via cascaded feedback network//Proceedings of the 32nd International Conference on Artificial Neural Networks. Heraklion, Greece: Springer: 317-329 [DOI: 10.1007/978-3-031-44207-0_27]
- Wang X T, Xie L B, Dong C and Shan Y. 2021. Real-ESRGAN: training real-world blind super-resolution with pure synthetic data//Proceedings of 2021 IEEE/CVF International Conference on Computer Vision. Montreal, Canada: IEEE: 1905-1914 [DOI: 10.1109/ICCVW54120.2021.00217]
- Wang X T, Yu K, Wu S X, Gu J J, Liu Y H, Dong C, et al. 2019a. ESRGAN: enhanced super-resolution generative adversarial networks//Proceedings of 2019 European Conference on Computer Vision. Munich, Germany: Springer: 63-79 [DOI: 10.1007/978-3-030-11021-5_5]
- Wang Y, Sun Y B, Liu Z W, Sarma S E, Bronstein M M and Solomon J M. 2019b. Dynamic graph CNN for learning on point clouds. *ACM Transactions on Graphics (ToG)*, 38(5): #146 [DOI: 10.1145/3326362]
- Wang Y F, Wu S H, Huang H, Cohen-Or D and Sorkine-Hornung O. 2019c. Patch-based progressive 3D point set upsampling//Proceedings of 2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Long Beach, USA: IEEE: 5951-5960 [DOI: 10.1109/cvpr.2019.00611]
- Wang Y R, Wang S Y and Sun L H. 2022. Point cloud upsampling via a coarse-to-fine network//Proceedings of the 28th International Conference on Multimedia Modeling. Phu Quoc, Vietnam: Springer: 467-478 [DOI: 10.1007/978-3-030-98358-1_37]
- Wu H K, Zhang J G and Huang K Q. 2019. Point cloud super resolution with adversarial residual graph networks [EB/OL]. [2025-07-10]. <https://arxiv.org/pdf/1908.02111.pdf>
- Wu S H, Huang H, Gong M L, Zwicker M and Cohen-Or D. 2015. Deep points consolidation. *ACM Transactions on Graphics (ToG)*, 34(6): #176 [DOI: 10.1145/2816795.2818073]
- Yang G D, Huang X, Hao Z K, Liu M Y, Belongie S and Hariharan B. 2019. PointFlow: 3D point cloud generation with continuous normalizing flows//Proceedings of 2019 IEEE/CVF International Conference on Computer Vision. Seoul, Korea (South): IEEE: 4540-4549 [DOI: 10.1109/ICCV.2019.00464]
- Yang Y Q, Feng C, Shen Y R and Tian D. 2018. FoldingNet: point cloud auto-encoder via deep grid deformation//Proceedings of 2018

- IEEE/CVF Conference on Computer Vision and Pattern Recognition. Salt Lake City, USA; IEEE: 206-215 [DOI: 10.1109/cvpr.2018.00029]
- Ye S Q, Chen D D, Han S F, Wan Z Y and Liao J. 2022. Meta-PU: an arbitrary-scale upsampling network for point cloud. *IEEE Transactions on Visualization and Computer Graphics*, 28(9): 3206-3218 [DOI: 10.1109/TVCG.2021.3058311]
- Yu L Q, Li X Z, Fu C W, Cohen-Or D and Heng P A. 2018. PU-Net: point cloud upsampling network//*Proceedings of 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition*. Salt Lake City, USA; IEEE: 2790-2799 [DOI: 10.1109/cvpr.2018.00295]
- Zeng G, Li H S, Wang X C and Li N. 2021. Point cloud up-sampling network with multi-level spatial local feature aggregation. *Computers and Electrical Engineering*, 94: #107337 [DOI: 10.1016/j.compeleceng.2021.107337]
- Zhang P P, Wang X, Ma L, Wang S Q, Kwong S and Jiang J M. 2021. Progressive point cloud upsampling via differentiable rendering. *IEEE Transactions on Circuits and Systems for Video Technology*, 31(12): 4673-4685 [DOI: 10.1109/TCSVT.2021.3100134]
- Zhao H S, Jiang L, Jia J Y, Torr P and Koltun V. 2021a. Point transformer//*Proceedings of 2021 IEEE/CVF International Conference on Computer Vision*. Montreal, Canada; IEEE: 16239-16248 [DOI: 10.1109/ICCV48922.2021.01595]
- Zhao T M, Li L F, Tian T, Ma J Y and Tian J W. 2023a. APUNet: Attention-guided upsampling network for sparse and non-uniform point cloud. *Pattern Recognition*, 143: #109796 [DOI: 10.1016/j.patcog.2023.109796]
- Zhao W B, Liu X M, Zhai D M, Jiang J J and Ji X Y. 2023b. Self-supervised arbitrary-scale implicit point clouds upsampling. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 45(10): 12394-12407 [DOI: 10.1109/TPAMI.2023.3287628]
- Zhao Y F, Hui L and Xie J. 2021b. SSPU-Net: self-supervised point cloud upsampling via differentiable rendering//*Proceedings of the 29th ACM International Conference on Multimedia*. Virtual Event, China; ACM: 2214-2223 [DOI: 10.1145/3474085.3475381]
- Zhou K Y, Dong M and Arslanturk S. 2022. "Zero-shot" point cloud upsampling//*Proceedings of 2022 IEEE International Conference on Multimedia and Expo*. Taipei, China; IEEE: 1-6 [DOI: 10.1109/ICME52920.2022.9859662]
- Zhu X F and Song J. 2024. Review of research on lightweight image super-resolution. *Computer Engineering and Applications*, 60(16): 49-60 (朱新峰, 宋健. 2024. 轻量级图像超分辨率研究综述. *计算机工程与应用*, 60(16): 49-60) [DOI: 10.3778/j.issn.1002-8331.2403-0230]
- Zhu Y R, Zhang Z Y, Liu R Y, Zhang J H, Cheng X and Chen S Y. 2024. LET-UP: a lightweight, efficient binarized transformer for point cloud upsampling. *IEEE Transactions on Instrumentation and Measurement*, 73: #5037114 [DOI: 10.1109/tim.2024.3476569]
- Zhu Z J, Zhang R, Bai Y Q, Wang Y E and Sun J M. 2024. Bilateral cross enhancement with self-attention compensation for semantic segmentation of point clouds. *Journal of Image and Graphics*, 29(8): 2388-2398 (朱仲杰, 张荣, 白永强, 王玉儿, 孙嘉敏. 2024. 结合双边交叉增强与自注意力补偿的点云语义分割. *中国图象图形学报*, 29(8): 2388-2398) [DOI: 10.11834/jig.230430]

作者简介

詹杰,男,硕士研究生,主要研究方向为计算机视觉与机器学习。E-mail:jiezhao0928@nuaa.edu.cn

徐帆,通信作者,男,副教授,主要研究方向为计算成像、图像处理、信号处理、机器学习。E-mail:xufan@nuaa.edu.cn

时逸舟,男,硕士研究生,主要研究方向为计算机视觉与机器学习。E-mail:shiyizhou@nuaa.edu.cn

马凯光,男,新加坡工程院院士,主要研究方向为图像与视频处理、数字信号处理、计算机视觉、人工智能与机器学习。

E-mail:kkma23@nuaa.edu.cn