



基于深度学习的点云去噪方法综述

王兴涛, 代梦丽, 于嘉阔, 李文瑞, 满珩玉, 范晓鹏

引用本文:

王兴涛, 代梦丽, 于嘉阔, 等. 基于深度学习的点云去噪方法综述[J]. 智能系统学报, 2026, 21(4): 849–863.

WANG Xingtao, DAI Mengli, YU Jiakuo, et al. A review of deep learning-based point cloud denoising methods[J]. *CAAI Transactions on Intelligent Systems*, 2026, 21(4): 849–863.

在线阅读 View online: <https://dx.doi.org/10.11992/tis.202511005>

您可能感兴趣的其他文章

改进Faster R-CNN的汽车仪表指针实时检测

Improved Faster R-CNN vehicle instrument pointer real-time detection algorithm
智能系统学报. 2021, 16(6): 1056–1063 <https://dx.doi.org/10.11992/tis.202011003>

一种基于2D时空信息提取的行为识别算法

A behavioral recognition algorithm based on 2D spatiotemporal information extraction
智能系统学报. 2020, 15(5): 900–909 <https://dx.doi.org/10.11992/tis.201906054>

基于级联宽度学习的多模态材质识别

Cascade broad learning for multi-modal material recognition
智能系统学报. 2020, 15(4): 787–794 <https://dx.doi.org/10.11992/tis.201908021>

图神经网络推荐研究进展

Research advances in graph neural network recommendation
智能系统学报. 2020, 15(1): 14–24 <https://dx.doi.org/10.11992/tis.201908034>

多标记学习自编码网络无监督维数约简

Unsupervised dimensionality reduction of multi-label learning via autoencoder networks
智能系统学报. 2018, 13(5): 808–817 <https://dx.doi.org/10.11992/tis.201804051>

高斯核函数卷积神经网络跟踪算法

Convolutional neural network tracking algorithm accelerated by Gaussian kernel function
智能系统学报. 2018, 13(3): 388–394 <https://dx.doi.org/10.11992/tis.201612040>

DOI: 10.11992/tis.202511005

网络出版地址: <https://link.cnki.net/urlid/23.1538.TP.20260407.1012.004>

基于深度学习的点云去噪方法综述

王兴涛^{1,2}, 代梦丽¹, 于嘉阔¹, 李文瑞¹, 满珩玉¹, 范晓鹏^{1,2}

(1. 哈尔滨工业大学 计算学部, 黑龙江 哈尔滨 150001; 2. 哈尔滨工业大学 苏州研究院, 江苏 苏州 215000)

摘要: 点云作为重要的三维数据载体, 广泛应用于自动驾驶、具身智能及虚拟现实等领域。然而, 受传感器误差、环境干扰与重建算法缺陷等因素影响, 原始点云常含有噪声, 导致几何结构失真并降低下游任务性能。针对该问题, 大量基于深度学习的点云去噪方法不断涌现。本文系统梳理了近 8 年该领域的最新进展, 构建了基于深度学习的点云去噪五大分类体系, 涵盖 PointNet 主干网络、卷积神经网络 (convolutional neural network, CNN)、Transformer 网络、非传统网络以及无监督学习策略, 并深入剖析了各类算法的核心机制与演进脉络; 对比了主流算法在合成与真实数据集上的性能; 总结了当前技术面临的泛化能力弱与数据稀缺等挑战, 并对全能模型研发、自适应噪声建模等未来发展趋势进行了展望。本文分析结果可为深度学习点云去噪方法的分类理解、性能评估及后续算法改进提供参考。

关键词: 三维数据; 点云; 去噪; 深度学习; 神经网络; 特征提取; 监督学习; 图神经网络

中图分类号: TP391 **文献标志码:** A **文章编号:** 1673-4785(2026)04-0849-15

中文引用格式: 王兴涛, 代梦丽, 于嘉阔, 等. 基于深度学习的点云去噪方法综述 [J]. 智能系统学报, 2026, 21(4): 849-863.

英文引用格式: WANG Xingtao, DAI Mengli, YU Jiakuo, et al. A review of deep learning-based point cloud denoising methods[J]. CAAI transactions on intelligent systems, 2026, 21(4): 849-863.

A review of deep learning-based point cloud denoising methods

WANG Xingtao^{1,2}, DAI Mengli¹, YU Jiakuo¹, LI Wenrui¹, MAN Hengyu¹, FAN Xiaopeng^{1,2}

(1. Faculty of Computing, Harbin Institute of Technology, Harbin 150001, China; 2. Suzhou Research Institute, Harbin Institute of Technology, Suzhou 215000, China)

Abstract: Point clouds, as an important carrier of 3D data, are widely applied in autonomous driving, embodied intelligence, virtual reality, and other fields. However, raw point clouds are often corrupted by sensor errors, environmental interference, and reconstruction algorithm defects, resulting in noise, geometric structure distortion, and degraded performance in downstream tasks. To address these issues, numerous deep learning-based point cloud denoising methods have been proposed. This paper systematically reviews developments in this field over the past eight years. First, a five-category taxonomy for deep learning-based point cloud denoising is established, encompassing PointNet-based backbones, convolutional neural network(CNN), Transformer networks, nontraditional networks, and unsupervised learning strategies. The core mechanisms and evolutionary trajectories of these algorithms are analyzed in depth. Second, the performance of mainstream algorithms is evaluated and compared on both synthetic and real-world datasets. Finally, current challenges, such as limited generalization ability and data scarcity, are summarized, and future research directions, including the development of all-in-one models and adaptive noise modeling, are discussed. The analysis presented in this paper provides a reference for the taxonomy, performance evaluation, and future improvement of deep learning-based point cloud denoising methods.

Keywords: 3D data; point clouds; denoising; deep learning; neural networks; feature extraction; supervised learning; graph neural networks

收稿日期: 2025-11-04. 网络出版日期: 2026-04-07.

基金项目: 国家自然科学基金项目 (62402138, 62502116, 624B-2049).

通信作者: 范晓鹏. E-mail: fxp@hit.edu.cn.

©《智能系统学报》编辑部版权所有

三维点云作为物体表面几何信息的离散采样表示, 广泛应用于自动驾驶、具身智能、增强现实/虚拟现实 (augmented reality/virtual reality, AR/VR)^[1]

等领域。然而,受传感器精度限制、环境干扰及重建算法缺陷的影响,原始点云往往带有噪声^[2]。这不仅破坏点云的几何与拓扑结构,还会显著降低下游任务的精度与鲁棒性^[3]。

点云去噪旨在保留原始几何特征的同时消除噪声。由于对真实几何结构的先验未知,从含噪声数据中无法获得唯一、真实的几何结构,因而该任务是不适定的。针对这个问题,传统方法依赖人工设计特征与先验假设,由于假设的先验在处理复杂噪声分布或非均匀采样场景时泛化能力有限,此类方法难以平衡噪声抑制与几何特征保留之间的冲突。近年来,基于深度学习的点云去噪方法通过数据驱动的学习机制,直接学习噪声分布与几何结构的映射关系,在动态特征捕捉、泛化能力及无监督学习等方面展现出显著优势^[4]。

近年来,已有若干研究对点云去噪方法进行了系统梳理。文献[5]构建了滤波器、优化方法和深度学习的3级分类体系,但受限于发表时间,对深度学习算法的总结不够全面;文献[6]从优化思想和深度学习两个维度对点云去噪方法进行分类,分析了基于移动最小二乘、局部最优投影、稀疏低秩等传统算法以及早期深度学习模型,提出了算法对比框架,但未涵盖近3年涌现的突破性成果;文献[7]是综合性的点云处理综述,虽涉及去噪任务,但仅将其作为子任务简要讨论。总体而言,现有综述多侧重于传统优化算法或早期深度学习模型,缺乏对Transformer网络、无监督策略等最新深度学习技术范式的系统性梳理。

基于上述背景,本文致力于呈现兼具时效性与技术深度的综述。文章系统梳理了近8年基于深度学习的点云去噪方法,构建了包含PointNet主干网络、卷积神经网络(convolutional neural network, CNN)、Transformer网络、非传统网络以及无监督学习策略的5大分类体系。特别地,针对当前显著的架构融合趋势(如在图卷积网络中嵌入注意力模块^[8-9],或在Transformer中引入局部卷积^[10-11]),对于有监督学习方法依据其特征提取的核心算子进行界定。对于无监督学习方法,鉴于其核心创新在于设计无需真值的损失函数或训练流程,均归入无监督学习策略进行讨论,以突显其在数据依赖性上的突破。本文深入剖析了各类方法的核心机制与演进脉络,并对比了主流算法在合成与真实数据集上的性能,最后总结了泛化能力弱与数据稀缺等挑战,对全能模型研发、自适应噪声建模等未来发展趋势进行了展望。

1 分类表述

点云作为三维空间中的离散点集,核心特性在于点的无序性,要求深度学习模型具备置换不变性,使同一对象以不同顺序输入时,去噪结果保持一致。同时,点云描述的几何结构具有空间不变性,意味着网络需要对旋转、平移等刚性变换具有不变性。

根据网络结构类别的不同,基于深度学习的点云去噪方法可分为基于PointNet主干网络、卷积神经网络、Transformer模型、无监督学习策略以及非传统网络框架5大类。基于PointNet的方法关注噪声点云中点的空间坐标,主要利用点的位置,忽略了其他可能的属性或上下文信息;基于卷积神经网络和图神经网络(graph neural network, GNN)的方法通过卷积操作或图结构建模,捕捉点云中局部邻域的空间相关性及其几何特征,从而区分噪声与真实表面信号;基于Transformer架构的方法,利用自注意力机制建模点云的长距离依赖与全局结构关系^[12],同时通过结构创新适配点云的无序性与几何特性;无监督学习通过挖掘点云自身的分布规律或结构先验,无需依赖干净点云的监督标签即可实现噪声抑制,通过设计自适应的学习目标,使模型能够从含噪点云中自动分离出噪声与真实几何特征。除了上述主流方法外,点云去噪领域还存在一些探索性较强或在特定应用场景下的方法,通过非传统架构或跨领域技术突破固有范式。对现有基于深度学习的三维点云去噪方法的分类如图1所示。

1.1 基于PointNet主干网络的方法

基于PointNet^[13]主干网络(如图2所示)的点云去噪方法以直接处理原始无序点云数据为核心,利用多层感知机(multilayer perceptron, MLP)逐点学习高维特征,通过置换不变函数提取全局特征,突破了传统方法对结构化数据的依赖,奠定端到端深度学习框架基础。首先,输入点云被分割为局部块(patch)或直接作为整体输入;接着,利用MLP对每个点进行独立的高维特征映射,该过程共享权重以保证置换不变性;随后,通过最大池化等对称函数聚合出反映几何结构的全局或局部特征向量;最后,解码器网络将这些特征拼接到逐点特征上,通过回归网络预测每个点到潜在干净表面的位移向量,从而实现去噪。后续的改进工作主要围绕如何增强特征提取器对局部几何细节的感知能力展开。




图1 基于深度学习的三维点云去噪方法的分类

Fig. 1 Classification of deep learning-based methods for 3D point cloud denoising




图2 PointNet 模型的网络架构

Fig. 2 The network structure of PointNet

1.1.1 基础框架的奠基与演进

点云的无序性与非结构化特征对传统几何处理方法构成根本性挑战^[14]。Qi 等^[15]提出的 PointNet 开创性地通过对称函数最大池化实现置换不变性，首次构建了端到端的点云深度学习框架。为了捕获点之间的局部结构信息；Qi 团队进一步提出 PointNet++^[15]，通过分层采样与局部特征聚合策略实现多尺度上下文感知。Guerrero 等^[16]在 PointNet 架构基础上进行扩展提出 PCPNet，提出了单尺度和多尺度两种架构，网络对输入点云的局部点云块进行编码，学习一系列非线性函数来描述块内的点分布，从而估计出局部形状属性，为了提高鲁棒性，多尺度架构通过输入不同半径的点云块，使网络能够关注点云中不同大小的区域。

在上述网络架构的基础上，研究者们开始探索局部几何约束与深度学习框架的协同优化。为了解决边缘特征易被平滑的问题，Yu 等^[17]提出了边缘感知网络 EC-Net，将边缘感知机制集成到深度学习框架中。通过提取局部点云块，利用改

进的 PointNet++^[15] 编码几何特征，并设计了边缘感知联合损失函数，在特征扩展和坐标回归中显式约束输出点靠近真实表面及锐利边缘，但该方法受限于固定尺寸的局部块处理机制，对大规模缺失或极小结构的重建效果有限。Duan 等^[18]提出的神经投影去噪方法 (neural projection denoising, NPD) 将深度学习与传统投影算法结合，借鉴 PointNet 的共享 MLP 和全局最大池化结构融合局部与全局特征，预测噪声点对应的局部参考平面参数，并通过一次投影将噪声点校正到估计平面上。

1.1.2 去噪性能的迭代优化

随着任务复杂度的提升，基于 PointNet 的方法逐步向精细化方向发展。在改进的 PCPNet 架构基础上，Rakotosaona 等^[19]提出两阶段深度学习框架 (point clean net, PCN)。第一阶段通过分类网络识别并剔除离群点；第二阶段通过位移向量回归网络将噪声点投影至潜在表面，并设计双阶段联合损失函数，结合迭代优化机制提升去噪稳

定性。然而, EC-Net^[17]和PCN^[19]等方法存在特征保持与泛化能力的权衡问题, 过度平滑导致尖锐几何特征退化, 或受限于训练数据分布而泛化性能受限。为此, Zhang等^[20]提出Pointfilter, 构建编码器-解码器架构, 通过改进的PointNet++提取多尺度几何特征; 设计融合法线相似性约束与空间邻近性权重的双边投影损失函数, 显式保证去噪表面的几何保真; 引入点排斥正则化项, 有效改善点云分布的均匀性。Huang等^[21]提出MODNet(multi-offset point cloud denoising network), 引入基于PointNet的低级特征提取器与半软邻域选择机制, 使网络能依据局部几何复杂度自动选择最优尺度信息, 从而在保留尖锐特征的同时有效去除噪声。

将传统滤波方法与深度学习相结合能够有效提升点云去噪的鲁棒性与几何特征保持能力, 为此, Wang等^[22]提出PointFilterNet将滤波系数预测与邻域坐标优化结合, 并借鉴人类视觉系统, 设计包含粗粒度恢复和细粒度恢复两个子网络的去噪器, 分别学习平滑表面和细节纹理的滤波系

数, 逐步优化去噪结果。而后为了解决深度学习点云去噪方法中特征噪声污染导致梯度振荡的问题, Wang等^[23]又提出FCNet(feature clean network), 将师生学习范式引入点云去噪, 通过教师网络从含干净邻域信息的输入中提取无噪声特征, 指导学生网络学习。

1.1.3 基于PointNet主干网络的方法讨论

基于PointNet网络的方法主要经历了从全局特征映射到局部感知的演进。PointNet++、PCPNet及Pointfilter等方法的共性在于利用MLP逼近几何函数, 并通过对称函数解决无序性问题。此类方法计算效率高且置换不变性强, 不再依赖体系化网格。表1总结了本节中讨论的基于PointNet主干网络的方法。然而, 此类方法的瓶颈是MLP对局部拓扑结构的捕捉能力弱于卷积网络, 难以充分理解点与点之间的相对空间关系, 导致在处理尖锐边缘时容易出现过平滑。此外, 大多算法严重依赖固定的Patch采样尺度, 半径过大引入冗余噪声、过小则丢失上下文, 这种对超参数的高度敏感性限制了其在非均匀采样场景下的自适应能力。

表1 基于PointNet主干网络的点云去噪方法
Table 1 Point cloud denoising methods based on PointNet backbone

方法简称	核心思想
EC-Net ^[17] (2018)	集成边缘感知机制, 改进PointNet++编码几何特征, 设计联合损失函数约束表面和边缘。
NPD ^[18] (2019)	通过共享MLP和全局特征聚合预测噪声点的局部参考平面, 并采用一次投影完成点位置校正。
PCN ^[19] (2018)	两阶段框架: 分类网络剔除离群点, 位移回归网络投影噪声点至表面。
Pointfilter ^[20] (2020)	编码器-解码器架构结合特征感知损失, 回归位移向量并设计双边投影损失。
MODNet ^[21] (2022)	依托PointNet提取浅层特征, 通过半软邻域机制自适应选取最优尺度, 实现去噪并保留细节。
PFN ^[22] (2022)	滤波系数预测与邻域优化结合, 分粗粒度和细粒度恢复子网络逐步优化。
FCNet ^[23] (2023)	引入师生学习范式, 教师网络提取无噪声特征指导学生网络。

1.2 基于卷积神经网络的方法

受启发于卷积网络在二维图像去噪、超分辨率等任务中的卓越表现, 研究者开始探索如何将这一优势迁移至三维点云去噪领域。然而, 点云数据的无序性是卷积神经网络应用的一大挑战, 需要进行额外的处理来解决点云的无序性问题。随着卷积神经网络在众多图像视觉任务中的成功应用以及点云处理深度学习技术的快速发展, 设计能够灵活应对各种场景及非理想样本条件的点云去噪网络^[24]已成为当前重要的研究方向。如PointProNets^[25]通过高度图映射将局部点云转换为二维规则网格; GPDNet^[26]、GPOD^[27]和Geo-GCN^[28]等方法利用图卷积网络融合局部与非局部特征; IterativePFN^[29]算法通过级联模块模拟真实迭代过程; PN-Internet^[30]通过两个交互式的图

卷积网络联合解决点云去噪和法线估计问题。此类方法的出现标志着点云处理从基于规则的设计向数据驱动范式的转变。

1.2.1 基于CNN的方法

CNN架构本身依赖于具有固定拓扑结构的规则网格数据, 而点云本质上是空间中无序、不规则的离散点集。因此, 基于CNN的方法通常不直接处理三维点云, 而是采用一种“投影为先”的策略(如图3所示)。首先将输入的无序点云局部块(local patch)通过特定的映射函数转换为规则的二维栅格化表示, 从而将三维几何信息编码为类似图像的结构, 例如高度图(height map)或法线图(normal map)。一旦点云的几何特征被映射为二维图像, 便可利用在图像处理任务中表现成熟的CNN架构如U-Net、ResNet等对其进行特征提

取与噪声滤除。最后, 通过反投影或坐标更新机制, 将网络输出的干净二维表示的结果应用回原始的三维点云。




图3 基于CNN的去噪范式

Fig. 3 CNN-based denoising paradigm

Roveri 等^[25]提出 PointProNets 方法, 将无序点云局部块转换为规则二维高度图, 从而把卷积神经网络引入局部点云巩固任务。该方法设计了可微分的高度图生成网络 (heightmap generation network, HGN) 和高度图去噪网络 (heightmap denoising network, HDN), 前者通过局部参考框架估计与点投影将稀疏含噪点云 patch 映射为高度图; 后者利用 CNN 对高度图进行去噪和几何细节恢复, 随后通过反投影生成稠密、去噪后的点云。与基于体素网格化 (voxelization) 的三维 CNN 方法相比, PointProNets 降低了存储与计算开销, 并在点云去噪、重采样和表面细节恢复方面取得了较好的效果。Lu 等^[31]提出的特征保持方法, 也是通过将点云先投影为高度图, 再利用分类和回归两个 CNN 网络分别处理特征点与非法特征点来实现去噪。为进一步解决去噪过程中锐利几何特征易被平滑的挑战, Wei 等^[32]提出了几何支撑双卷积神经网络 (geometry-supporting dual convolutional neural network, GeoDualCNN), 用于含噪点云的法线估计与去噪。该方法基于分片光滑表面假设, 通过张量投票引导的相对总变分 (tensor voting guided relative total variations, TVG-RTV) 为每个点搜索不跨越锐利边缘或不连续区域的同质邻域 (homogeneous neighborhood, HoNe)。在此基础上, 构建编码点位置信息的同质高度图 (homogeneous height map, HoHM) 和编码点法线信息的同质法线图 (homogeneous normal map, HoNM) 两种规则化几何描述符。GeoDualCNN 将 HoHM 和 HoNM 分别输入两个并行 CNN 分支, 前者侧重噪声抑制, 后者侧重几何特征保持, 并通过学习从含噪局部描述符到真实法线的映射优化点法线。最终, 该方法利用估计法线更新点坐标, 从而在去除噪声的同时较好地保持尖锐特征和局部几何细节。

1.2.2 基于 GNN 的方法

GNN 以点云的邻接图为基础, 通过消息传递机制在节点之间传播信息, 从而捕获节点之间的依赖关系^[33]。在点云去噪中, EdgeConv 是一种典

型的图神经网络模块, 它通过计算相邻点之间的特征差异, 将其作为边的特征, 然后通过多层图卷积操作来更新节点特征, 实现点云的去噪和特征提取 (如图 4 所示)。GNN 能够自然地处理点云的非规则数据结构, 有效地捕捉点云的局部和全局几何信息^[34], 在处理复杂形状和多样化噪声的点云时具有较好的性能表现。




图4 基于图卷积的去噪范式

Fig. 4 Graph convolution-based paradigm

Wang 等^[35]构建了适用于点云分类、分割等高阶任务的动态图卷积神经网络模型, 为后续将图卷积引入点云去噪领域奠定基础。受此启发, Pistilli 等^[26]提出 GPDNet 模型, 通过在网络的不同层级中动态更新特征空间内的邻域图结构, 并利用自适应的权重机制来聚合邻域信息。随着网络对特征的逐层提炼, 在高维特征空间中构建的邻接关系比在原始噪声三维空间中构建的图更能反映点云真实的几何结构。而后提出的 GPOD^[27]扩展了该方法, 引入共享特征提取模块联合处理去噪与异常点检测, 采用动态图卷积和加权交叉熵损失, 实现端到端的噪声与异常点同步去除。两者均利用特征相似性动态构建图结构, 增强模型对噪声的鲁棒性。针对高噪声环境下点云去噪任务中收敛效率与精度提升问题, De silva 等^[29]提出 IterativePFN 算法, 构建了基于多迭代模块堆叠的图卷积网络架构。该架构的每个迭代模块内部采用动态边卷积操作处理点云图结构数据, 通过设计自适应目标损失函数驱动噪声点逐步向潜在降噪表面收敛。区别于 PCN^[19]等仅在推理阶段执行迭代操作的位移估计或概率建模方法, IterativePFN 在训练阶段通过级联模块模拟真实去噪迭代过程, 每个模块对应不同噪声尺度的自适应目标点云, 迫使网络学习迭代间的噪声衰减规律。但是该方法依赖基于欧氏距离的 K 近邻 (K-nearest neighbors, KNN) 构建邻域图。在直角或锐角边缘处, KNN 算法倾向于跨越几何不连续面, 导致聚合后的特征向量成为了两个平面的“加权平均”, 从而拉平了尖锐棱角。另外其损失函数主要关注整体点云的 Chamfer 距离, 这种全局平均的优化目标缺乏对高频几何特征的显式惩罚权重, 导致网络优先优化占绝大多数的平坦区域, 而牺牲了稀疏的边缘点。Li 等^[8]提出了一种单阶

段点云清洗网络 (single-stage point cloud cleaning network, SSPCN), 以端到端方式同时完成离群点去除与点云去噪, 避免了传统两阶段流程中独立离群点检测和位移回归带来的训练与使用复杂性。该方法首先通过密度约束的最远点采样 (density based farthest point sampling, DBFPS) 获得预过滤点云子集, 降低稀疏离群点对采样结果的影响; 随后利用由多尺度动态图卷积和自注意力机制组成的特征补偿模块增强局部与长程上下文特征, 并通过上采样和坐标重建模块生成与输入规模一致的清洗点云, 从而在单一网络中实现噪声抑制与离群点去除。

沿着显式几何重建的思路, Luo 等^[36]的 DM-RDenoise 方法通过动态图卷积网络 (dynamic graph convolutional neural network, DGCNN) 提取特征, 并利用可微分池化操作筛选出关键点, 进而重建局部流形以生成去噪点云, 但其在处理高频几何细节时仍存在明显的过平滑效应, 因为可微池化本质上是一种有损压缩。后来他们将去噪问题重新定义为一个概率优化过程, 提出了基于分数匹配的去噪范式 Score-Based^[37], 该方法不再显式重建流形, 而是让网络学习估计干净点云分布的概率梯度, 并通过梯度上升将噪声点迭代地移至该分布的高似然区域, 该方法同样采用 DGCNN 作为特征提取器, 以捕捉估计局部梯度场所需的复杂几何上下文。Li 等^[38]进一步扩展该方法, 引入多尺度动态图卷积融合噪声、边缘及密度特征, 与 DMRDenoise 依赖固定噪声先验不同, 该工作设计了基于联合偏移函数的梯度上升策略, 通过聚合邻域点的噪声偏移均值来增强模型对未知噪声分布的适应性。Wang 等^[39]提出了基于随机筛选的特征聚合网络, 结合图卷积网络, 通过随机筛选局部点块的特征, 分两次将密集点的全局几何信息融合至稀疏子块中, 利用级联特征增强模块提升对噪声和非均匀采样的适应性。与传统的单次特征拼接或多尺度融合方法不同, 该算法通过随机采样策略动态调整局部几何信息的传递路径, 并结合加权回归机制抑制无关点的影响。

在图卷积基础上, 引入联合优化策略, 将法线估计、几何约束等先验信息与图卷积特征融合, 能够增强模型的去噪能力。Yang 等^[40]提出的全局特征引导去噪将图卷积的动态特征提取机制与全局特征引导策略融合, 基于点网结构的全局特征编码器捕获点云整体形态特征, 将其作为调制因子通过缩放平移操作动态调整图卷积网络提取的多尺度特征。Mao 等^[41]提出了基于图卷积与

可逆神经网络的潜在空间点云去噪框架 (point cloud denoising in latent space, PD-LTS), 该方法利用多级图卷积网络 (multi-level graph convolution, MLGC) 提取从局部到全局的多尺度几何结构特征, 并将其融合到由可逆单调算子建模的可逆神经网络中, 将点云从欧氏空间双射映射到潜在空间。在该潜在空间中, 噪声因素与干净几何成分被分离到不同维度, 通过掩蔽噪声相关维度并执行逆变换恢复干净点云。进一步地, Chen 等^[28]提出的几何双域图卷积网络 (geometric dual-domain graph convolution network, GeoGCN) 融合了全局几何先验, 定义真实法线 (real normal, RN) 和虚拟法线 (virtual normal, VN) 分别建模局部与全局几何信息, 首先利用空间域图卷积网络 (spatial-domain graph convolution network, S-GCN) 在 VN 损失约束下回归初始去噪点云, 以保持整体形状; 随后基于初始去噪结果通过主成分分析 (principal component analysis, PCA) 估计 RN, 并输入法线域图卷积网络 (normal-domain graph convolution network, N-GCN) 回归精细法线, 最终借助法线更新点坐标以恢复局部几何细节。PN-Internet^[30]同时解决点云去噪和法线估计这两个高度相关的问题, 通过两个交互式的图卷积网络, 分别是点到法线网络和法线到点网络, 捕捉点位置与法线之间的几何依赖关系, 采用从粗到细的学习范式逐步优化结果。其中, 点到法线网络利用 MLP 模块提升法线估计的质量, 而法线到点网络通过基于法线约束的无参数投影模块进一步精细化点的位置。Wang 等^[9]提出一种基于混合注意力机制与分数匹配的点云去噪算法, 通过设计通道注意力与空间注意力的并行模块, 特征提取单元采用动态图卷积层结合注意力模块输出的鲁棒特征, 输入分数估计模块构建局部化分数函数, 通过梯度上升法更新点位置, 使噪声点向潜在干净表面的分布模式移动。

1.2.3 基于卷积神经网络的方法讨论

本节涵盖了解决点云非结构化特性的基于 CNN 的投影变换与基于 GNN 的拓扑构建两条主流路径, 表 2 总结了本节中讨论的方法。CNN 类方法试图通过降维利用成熟的 2D 图像去噪算子; 而 GNN 类方法则通过在非欧空间构建邻接图, 利用消息传递机制聚合邻域特征。然而 CNN 类方法基于投影的方法在 3D 到 2D 的转换过程中, 不可避免地伴随几何信息的丢失或畸变, 特别是在处理复杂曲面或遮挡区域时, 反投影容易产生接缝伪影。GNN 类方法在强噪声干扰下,

基于欧氏距离的近邻搜索往往会将噪声点误认为邻居, 导致“垃圾进, 垃圾出”的错误信息传递, 且

大规模 KNN 搜索带来的高计算开销也限制了其实时性应用。

表 2 基于卷积网络的点云去噪方法

Table 2 Point cloud denoising methods based on CNN/GNN

方法简称	核心思想
PointProNets ^[25] (2018)	将局部点云patch投影为二维高度图, 利用CNN对高度图去噪并反投影生成稠密点云, 实现点云巩固。
FP-filter ^[31] (2020)	基于深度学习的特征保持法向量估计方法, 通过分类网络区分特征/非特征点并分样本训练, 结合迭代位置更新优化点云, 保留几何特征。
Score-Based ^[37] (2021)	将噪声点云分布视为干净样本分布与噪声模型卷积的结果, 通过神经网络估计该卷积分布的分数, 利用梯度上升迭代更新点的位置来去噪。
GPDNet ^[26] (2020)	动态图卷积更新邻域图, 结合表面距离损失优化几何重建。
GPOD ^[27] (2020)	利用高维特征相似性构建复杂特征层次, 实现点云去噪与离群点去除的联合优化。
IterativePFN ^[29] (2023)	级联图卷积模块模拟迭代过程, 自适应目标损失逐步收敛噪声点。
SSPCN ^[8] (2023)	单阶段点云清理网络, 简化传统两阶段流程。
DMRDenoise ^[36] (2020)	自编码器结构, 通过可微分下采样提取低噪声点及其邻域特征, 显式重建点云流形表面。
Manifold denoising network structure ^[38] (2023)	通过流形特征提取模块和流形去噪模块联合处理未知噪声, 克服传统方法和梯度估计在未知场景下的性能下降问题。
Random screening-based feature aggregation ^[39] (2023)	基于随机筛选的特征聚合方法, 通过融合密集点与稀疏点的局部几何信息, 增强对非均匀分布和高噪声点云的鲁棒去噪能力。
AFE-GFE-FAGA ^[40] (2023)	结合自适应特征提取与梯度场估计的迭代去噪框架, 通过动态特征引导与加速梯度上升优化点云去噪性能。
PD-LTS ^[41] (2024)	基于隐空间分解噪声与干净点云, 通过多级图卷积网络提取多尺度几何特征, 结合可逆网络与单调算子实现噪声分离。
GeoGCN ^[28] (2022)	融合全局几何先验(真实法线与虚拟法线), 联合空间域与法线域图卷积优化细节。
PN-Internet ^[30] (2024)	双交互式图卷积网络联合去噪与法线估计, 逐步优化几何一致性。
HAM-PC ^[9] (2023)	利用混合注意力机制动态捕获点云多维度特征, 通过自适应权重融合与残差优化, 实现去噪。

1.3 基于 Transformer 网络的方法

Transformer 通过自注意力机制捕捉序列中远距离依赖关系^[42], 与卷积神经网络相比, Transformer 具有并行计算和置换不变性的优势, 逐渐被引入计算机视觉任务中^[43]。此类方法首先将点云坐标与特征映射为高维嵌入向量, 关键步骤是引入位置编码以保留点云的空间几何结构信息; 随后, 利用多头自注意力机制计算全图或大尺度邻域内点对之间的相关性权重, 从而捕捉长距离的语义依赖; 最后, 通过前馈网络利用聚合的全局上下文信息预测去噪后的点云坐标。图 5 为基于 Transformer 方法的去噪范式示意。




图 5 基于 Transformer 的去噪范式

Fig. 5 Transformer-based paradigm

1.3.1 代表性方法

Xu 等^[44]提出的 TDNet(Transformer-based denoising network)将改进的 Transformer 架构引入点云去噪任务, 构建编码器-解码器框架对点云进行特征建模。该方法利用点云坐标信息构建基于坐标的输入嵌入, 并引入相对注意力(relative attention, RA)增强特征表达; 同时设计自适应局部邻域采样(adaptive local neighborhood sampling, AS)模块, 在最远点采样(farthest point sampling, FPS)初始采样基础上动态更新采样点位置, 使其更接近潜在干净表面。随后, 解码器基于高维特征学习局部潜在流形, 并通过流形重建与重采样生成去噪点云。针对深度学习模型忽略特征通道相关性的问题, Zhu 等^[45]提出了 MSaD-Net, 该网络构建了一种混合自注意力机制, 该机制不仅利用 Transformer 捕捉空间上的全局上下文以区分噪声与真实几何细节, 还引入了通道注意力模块。该模块能够动态评估并调整不同特征通道的重要性, 从而使网络在去噪时能更多地依赖那些对噪声不敏感的鲁棒特征。

Wang 等^[10]提出 TPCDN(Transformer-based point cloud denoising network), 结合 Transformer 与局部-全局特征融合机制。该算法通过特征提取模块自适应捕获局部几何信息, 随后引入点云 Transformer(point cloud transformer, PCT)模块建模点间长距离依赖与全局结构特征, 并通过特征融合模块集成通道注意力优化多尺度特征。Ren 等^[11]提出一种融合卷积网络与 Transformer 的时变双流扩散生成模型 TIGER, 该方法通过分析扩散过程中不同时间步的特征需求, 设计时变权重掩码动态融合 CNN 的局部特征与 Transformer 的全局特征。为增强 Transformer 的几何感知能力, 提出相位偏移位置编码(phase-shifted positional encoding)与基 λ 位置编码(base- λ positional encoding)

ing) 两种连续空间编码方法, 有效解决点云无序性带来的几何信息表征难题。

1.3.2 基于 Transformer 网络的方法讨论

表 3 给出了上文中讨论的基于 Transformer 的方法。引入 Transformer 的初衷是利用自注意力机制捕捉长距离依赖关系, 突破了 CNN 和 MLP 感受野受限的局限, 能够从全局语义层面更好地区分噪声与物体结构。然而, 这种全局感知能力是以巨大的计算代价为交换的, 标准 Attention 的二次方级复杂度使其难以直接处理大规模场景点云。此外, Transformer 缺乏卷积网络的归纳偏置, 对训练数据的规模和多样性要求极高, 且如何设计既能保留高频几何细节又不破坏旋转不变性的位置编码, 仍是该领域当前的技术难点。

表 3 基于 Transformer 网络的点云去噪方法
Table 3 Point cloud denoising methods based on Transformer models

方法简称	核心思想
TDNet ^[44] (2021)	改进NLP中的Transformer结构以适配点云数据, 通过自适应采样优化传统FPS的噪声敏感性, 利用潜流形重建实现表面级去噪, 整合全局语义关联与局部几何特征。
MSaD-Net ^[45] (2023)	通过局部信息嵌入、Transformer 和通道注意力的结合, 建立点云局部结构的长距离依赖, 优化特征通道权重, 平衡局部细节与全局结构的建模能力。
TPCDN ^[10] (2023)	通过局部特征提取、全局依赖建模和特征融合的3级架构, 解决传统方法局部信息丢失问题, 提升复杂几何结构的去噪精度。
TIGER ^[11] (2024)	发现卷积与Transformer在扩散过程中的时间依赖性, 通过双流架构和时间掩码实现动态特征融合, 提升 3D 点云生成的全局结构与局部细节质量。

1.4 基于非传统网络的方法

1.4.1 代表性方法

Mao 等^[46]提出了一种基于归一化流的 PD-Flow 方法, 通过分布学习和特征解缠实现噪声分离。该方法将噪声点云建模为干净点与噪声的联合分布, 利用可逆的标准化流网络将点云映射到潜在空间, 通过设计维度增强模块突破传统流的维度瓶颈, 增强潜在表征的灵活性。该方法避免了逐点位移预测或下采样操作带来的细节损失, 在统一的可逆框架下实现了端到端的噪声解缠。Chen 等^[47]提出一种基于循环神经网络(recurrent neural network, RNN)的多阶段点云去噪架构 RePCD-Net, 通过循环传播层和双向 RNN 模块实现噪声渐进消除与几何特征动态恢复。该方法通过多尺度邻域采样提取局部特征, 并利用双向 RNN 自适应融合不同尺度的信息, 解决了传统方法中固定邻域尺度导致的噪声残留或细节过平滑问题。

基于深度学习的网络往往参数量大、计算效率低等问题, Sheng 等^[48]提出轻量级点云去噪网络 LPCDNet, 该方法通过轻量级三角函数位置编

码、非参数特征聚合和解码模块, 在仅 30K 参数量下实现高效去噪。强化学习(reinforcement learning, RL)是一种通过智能体与环境的交互来学习最优决策策略的机器学习范式。智能体根据当前环境状态选择动作, 并以最大化累积奖励为目标优化策略, 实现从试错中学习的决策优化^[49]。动态路径选择机制为点云去噪提供了新思路。为此, PathNet^[50]首次将强化学习框架引入该领域, 设计路由代理(routing agent)动态为每个点选择最优去噪路径。该框架通过噪声-几何感知奖励函数, 驱动智能体优先为高噪声区域和尖锐几何特征分配深层网络路径, 而对平滑区域采用轻量级处理, 实现计算效率与去噪精度的平衡。

Vogel 等^[51]提出一种基于扩散薛定谔桥的点云去噪框架 P2P-Bridge, 将点云去噪建模为噪声点云与干净点云之间的最优传输问题, 突破了传统方法依赖高斯噪声假设的局限。PyramidPCD^[52]是一种基于特征金字塔构建的网络, 通过五层金字塔结构实现从粗到细的特征传播, 利用层次互补性, 在保持大尺度结构完整性的同时恢复细粒度几何细节。

在解决复杂场景人体三维重建中点云去噪的问题时, Du 等^[53]采用双 Kinect 传感器结合 Bursa 线性模型进行空间对齐预处理,通过卷积神经网络提取深度图像特征实现迭代配准,并结合深度数据双边滤波平滑高频噪声。针对植物三维表型分析中复杂点云的噪声问题, Wu 等^[54]提出了基于密度梯度场学习的植物点云去噪网络(plant denoising net, PDN),将密度梯度场与伞型算子结合,避免依赖几何先验。在畜禽点云分割的具体应用方面, Lin 等^[55]提出了一种结合改进的 DBSCAN 聚类算法和 PointNet++网络的方法,专门用于处理猪点云数据中的去噪和分割问题。Gan 等^[56]利用 PointNet++对标注后的航空发动机整体叶盘点云数据集进行训练,从而高效提取整体叶盘点云模型的有效信息。Zuo 等^[57]提出了基于 PCPNet 架构的 PointAPL 算法,设计注意力池化层(attention pooling layer, APL)替代传统池化操作,以解决火箭储罐面板(rocket tank panel, RTP)扫描点云的去噪问题。为了解决雪中 LiDAR 多回波点云因雪花噪声导致的遮挡问题,并实现从多回波中选择有效目标点, Seppänen 等^[58]提出了自监督多回波去噪算法 SMEDen。结合无监督学习,通过多回波邻域编码器排除自身点以构建盲点训练,并引入特征相似性正则化方法,利用噪声的强度与稀疏性特征指导去噪过程。Liu 等^[59]提出一种融合条件生成对抗网络三正交平面模型(conditional generative adversarial network on three orthogonal planes, cGAN-TOP)与链接动态图卷积神经网络(linked dynamic graph convolutional neural network, LDGCNN)的混合框架,实现端到端噪声点云人脸识别。该方法将点云投影至三正交平面进行坐标特征学习,采用双判别器结构实现针对性去噪;识别阶段结合 LDGCNN 实现多尺度特征融合,通过动态图卷积与特征链接捕获局部-全局特征关联。

1.4.2 基于非传统网络的方法讨论

流模型、循环神经网络及强化学习等非传统架构,跳出了特征回归的传统范式,转而尝试从概率密度估计、时序迭代优化或决策路径搜索的角度解决去噪问题。尽管这些方法在可解释性或特定子任务上展现了独特优势,但受限于训练难度与通用性,如流模型的可逆变换限制、RL 的稀疏奖励问题,它们目前更多是作为主流架构的补充或特定场景的专用解法,在大规模通用去噪任务上尚未成为主流骨干。

1.5 无监督学习方法

尽管上述基于监督的方法在合成数据集上展

现出优异的性能,但其对成对标注数据的强依赖性仍是实际应用的瓶颈。无监督学习策略通过挖掘点云自身的结构特性或噪声统计规律,摆脱了对标注数据的依赖^[60]。无监督策略通过重新定义两类损失函数,从含噪分布中直接解耦出潜在的几何流形:一类是基于几何先验,利用流形平滑性、局部平面拟合残差作为监督信号;另一类是基于统计独立性(如 Noise2Noise^[61]架构),利用两次独立噪声观测间的统计映射关系,在无需真值的情况下引导网络收敛至潜在的干净分布。

1.5.1 代表性方法

受无监督图像去噪技术 Noise2Noise^[61]的启发, Hermosilla 等^[62]提出了第一种用于点云的无监督去噪方法 TD(total denoising, TD),通过引入空间先验和外观相似性先验,设计了可引导网络收敛到最近潜在模式的混合先验机制,结合蒙特卡罗卷积网络架构,通过自监督学习将噪声分布卷积后的模态映射到原始表面,在仅使用含噪点云数据的情况下,突破了传统方法需要成对“噪声-真值”数据的限制。DMRDenoise^[36]的解码器结合无监督损失函数,支持仅用噪声点云自监督训练。Chen 等^[63]提出基于图拓扑推理与滤波的深度自编码器,将图信号处理与深度自编码器结合,以无监督方式同时优化点云坐标和图拓扑关系。Noise4Denoise^[64]通过生成两个噪声级别,第二个噪声级别是第一个的两倍,推导出恢复干净表面的位移信息之间的关系,从而学习每个噪声点的位移以恢复对应的干净点。Ma 等^[65]和 Zhou 等^[66]提出基于噪声到噪声映射的方法,从带噪声点云中无监督地学习精确的符号距离函数(signed distance function, SDF),引入 EMD(earth mover's distance)作为损失函数,利用几何一致性正则化约束 SDF 正确性,通过将噪声点沿 SDF 梯度方向投影至表面实现去噪。Su 等^[67]提出了自监督迭代训练框架(self-supervised iterative training framework, SITF)。通过单噪声点云和已知噪声模型迭代生成二次噪声数据集,结合迭代去噪网络实现无监督学习。

1.5.2 无监督学习方法讨论

表 4 给出了上文中讨论的基于无监督学习的方法。无监督学习策略通过挖掘数据自身的几何先验或噪声统计独立性,打破了对成对真值数据的依赖,是解决真实世界扫描数据去噪的必经之路。但目前此类方法仍面临收敛稳定性与真实域差异的双重挑战:一方面,仅靠几何先验约束极易陷入局部最优,产生过度平滑或丝状伪影;另

一方面,现有方法多假设理想的高斯噪声分布,等复杂真实噪声存在显著的域差异,限制了算法这与激光雷达或深度相机产生的各向异性、拖尾在极端环境下的泛化性能。

表 4 基于无监督学习的点云去噪方法
Table 4 Unsupervised learning-based point cloud denoising methods

方法简称	核心思想
Total Denoising ^[62] (2019)	通过无监督学习解决3D点云“总噪声”,引入空间先验和外观先验,引导网络收敛到干净模式。
Graph-based Autoencoder ^[63] (2019)	提出基于图拓扑推理与滤波的深度自编码器:折叠模块生成初步重建,图拓扑推理捕捉点间关系,图滤波模块平滑细节提升重建质量。
Noise4Denoise ^[64] (2024)	通过生成双噪声点云并学习其位移关系恢复干净点云。
基于噪声到噪声映射的方法 ^[65-66] (2023,2024)	噪声到噪声映射从单/多噪声点云中学习SDF,无需干净数据或监督,结合统计推理和几何一致性损失。

2 算法对比与分析

2.1 数据集

常用数据集分为合成数据集和真实扫描数据集。表 5 是主要数据集的详细介绍及其应用场景。

2.2 评估指标

1) 倒角距离(chamfer distance, CD)

衡量两个点云间双向最近邻平均距离,反映整体几何相似性,值越小表示去噪后点云与参考点云越接近。倒角距离计算公式为

$$D_{CD}(P, Q) = \frac{1}{|P|} \sum_{p \in P} \min_{q \in Q} \|p - q\|^2 + \frac{1}{|Q|} \sum_{q \in Q} \min_{p \in P} \|q - p\|^2$$

式中: P 和 Q 分别为预测点云和真实参考点云; p 和 q 分别为 P 和 Q 中的三维点坐标向量; $|P|$ 和 $|Q|$ 分别为两点云中的点数。

2) 豪斯多夫距离(Hausdorff distance, HD)

计算两个点云间的最大局部偏差,用于检测去噪后是否存在异常点,对离群值敏感。豪斯多夫距离计算公式为

$$D_{HD}(P, Q) = \max \left\{ \sup_{p \in P} \inf_{q \in Q} \|p - q\|, \sup_{q \in Q} \inf_{p \in P} \|q - p\| \right\}$$

3) 点到网格距离(point-to-mesh distance, P2M)

计算去噪点云到原始网格表面的平均最短距离,常用于评估网格重建任务的精度。点到网格距离计算公式为

$$D_{P2M} = \frac{1}{N} \sum_{i=1}^N d(p_i, M)$$

式中: N 为参与计算的点数, p_i 为第 i 个去噪点的三维点坐标向量, M 为原始网格, $d(p_i, M)$ 为点 p_i 到网格 M 的最短距离。

4) 点到面距离(point-to-face distance, P2F)

改进的几何误差指标,通过法线方向投影误差衡量曲面细节保留能力,对细微结构更敏感。点到面距离计算公式为

$$P_{P2F} = \frac{1}{N} \sum_{i=1}^N |(p_i - q_i) \cdot n_{q_i}|$$

式中: q_i 为参考点云中与 p_i 对应的最近点坐标向量, n_{q_i} 为 q_i 处的单位法向量。

表 5 常用数据集
Table 5 Commonly used datasets

数据集类型	数据集名称	数据特点	引用场景
合成数据集	PCNet	包含18个训练形状和10个测试形状,涵盖简单几何形状(如立方体、球体)和复杂对象(如人体、机械部件),每个干净点云包含从原始三角形网格均匀采样的10万个点。	PCN、PointFilterNet
	PU-Net	包含60个3D模型(40个训练,20个测试),包括非刚性物体(如Bunny)和刚性物体(如椅子、桌子),点云密度多样,支持稀疏(10000点)和密集(50000点)场景。	IterativePFN、Score based
	ShapeNet	大规模3D模型库,包含55个类别、约51300个模型。通过均匀采样网格生成,支持噪声添加,常用于验证算法对复杂形状的特征保留能力。	PCPNet、NPD、ECnet
	ModelNet	包含12311个3D模型,主要为刚性物体(如椅子、桌子、飞机),点云密度较低,适合验证低分辨率场景下的去噪效果,提供预处理后的点云版本。	DMR、TPCDN
真实扫描数据	Madame Paris-rue	城市级移动激光扫描数据集,基于移动激光雷达扫描的城市点云,包含复杂场景(如建筑物、植被)和非结构化噪声(如离群点、扫描误差),常用于视觉对比算法在真实复杂环境中的特征保留能力。	PointFilter、MODnet
	Kinect	包含单视图(Kinect v1/v2)和多视图融合(fusion)扫描数据,噪声源于设备原理差异(如结构光与飞行时间法的噪声分布不同),地面真实值由高精度网格提供,适用于定量评估算法对真实噪声的去除效果。	PointFilterNet、PN-Internet

2.3 代表性算法对比与分析

表 6 给出了典型点云去噪方法在 PU-Net 数据集上的性能对比结果。实验采用泊松盘采样方法从网格中获取分辨率为 10K 和 50K 的点云, 并分别施加 1%、2% 和 2.5% 噪声水平的各向同性高

斯噪声, 以 CD 和 P2M 作为评价指标。为便于比较, 表格中所有数值均已进行 10^5 倍的尺度变换处理。综合表 6 和表 7 的实验数据, 可以从噪声鲁棒性、几何特征保持能力及合成与真实域的泛化差异 3 个维度进行深入剖析。

表 6 典型方法在合成测试集 PU-Net 数据集上的性能对比 ($D_{CD} \times 10^{-5}$, $D_{P2M} \times 10^{-5}$)

Table 6 Performance comparison of representative methods on the synthetic test set of the PU-Net dataset ($D_{CD} \times 10^{-5}$, $D_{P2M} \times 10^{-5}$)

方法	类别	10K points						50K points					
		1%噪声		2%噪声		2.5%噪声		1%噪声		2%噪声		2.5%噪声	
		CD	P2M	CD	P2M	CD	P2M	CD	P2M	CD	P2M	CD	P2M
PCN ^[19]	PointNet-based	36.86	15.99	79.26	47.59	104.86	69.87	11.03	6.46	19.78	13.70	32.03	24.86
GPDNet ^[27]	GNN-based	23.10	7.14	48.24	18.55	58.37	30.66	10.49	6.35	32.88	25.03	50.85	41.34
DMR ^[36]	GNN-based	47.12	21.96	50.85	25.23	52.77	26.69	12.05	7.62	14.43	9.70	16.96	11.19
PD-FLOW ^[46]	Flow-based	21.26	6.74	32.46	13.24	36.27	17.02	6.51	4.16	12.70	9.21	18.74	14.26
Score ^[37]	GNN-based	25.22	7.54	36.83	13.78	42.32	19.04	7.16	4.00	12.89	8.33	14.45	9.58
PointFilter ^[20]	PointNet-based	24.61	7.30	35.34	11.55	40.99	15.05	7.58	4.32	9.07	5.07	10.99	6.29
IterativePFN ^[29]	GNN-based	20.56	5.01	30.43	8.45	33.52	10.45	6.05	3.02	8.03	4.36	10.15	5.88
P2P-Bridge ^[51]	Diffusion-based	18.25	4.96	25.67	8.24	28.49	10.34	4.96	3.06	7.06	4.47	9.18	5.92

表 7 典型方法在真实扫描 Kinect 数据集上的 CD 性能对比 ($D_{CD} \times 10^{-5}$)

Table 7 Performance comparison of representative methods on the real-world scanned Kinect dataset ($D_{CD} \times 10^{-5}$)

方法	fusion	v1	v2	平均值
PCN ^[19]	13.25	20.58	35.56	23.13
GPD ^[26]	17.65	23.25	32.61	24.50
TD ^[62]	38.28	50.55	70.20	53.01
PF ^[20]	14.36	18.07	32.45	21.63
Score ^[37]	14.14	19.71	32.07	21.97
RePCD ^[47]	13.50	20.42	31.28	21.73
GeoDualCNN ^[32]	12.92	20.61	33.34	22.29
PathNet ^[50]	12.84	18.82	31.59	21.08
PN-Internet ^[30]	13.89	18.34	31.97	21.40
PDFlow ^[46]	14.27	19.93	32.33	22.18

迭代式与生成式架构在强噪声干扰下表现出显著的鲁棒性优势。从表 6 可见, 随着噪声强度从 1% 增加至 2.5%, 大多数单步推断网络 (如 DMR^[36]、GPDNet^[26]) 性能衰减剧烈。特别是 GPDNet, 其 CD 误差在 2.5% 噪声下相比 1% 噪声激增了约 2.5 倍。这主要是因为基于 GNN 的方法高度依赖于局部 KNN 图的构建, 在高噪声环境下, 噪声点会导致邻域拓扑结构严重畸变, 产生“垃圾

进, 垃圾出”效应。相比之下, IterativePFN^[29] 和 P2P-Bridge^[51] 在高噪声下仍保持了较低的误差 (2.5% 噪声下 CD 值仅为 33.52 和 28.49)。这得益于 IterativePFN^[29] 的级联架构模拟了渐进式去噪过程, 通过多阶段逐步修正将点拉回潜在流形, 有效缓解了单次回归的压力; 而基于扩散模型的 P2P-Bridge^[51] 则通过学习得分函数或概率流, 能够更稳健地从混乱分布中恢复出模态, 本质上对噪声分布的容忍度更高。

几何先验与特征提取方式决定了细节保持与过平滑之间的平衡。DMR^[36] 方法在各项指标上表现相对较差, 甚至不如早期的 PointNet 类方法, 因为其自编码器结构倾向于学习整体流形的平滑表示, 导致在高频区域发生严重的过平滑现象, 丢失了几何细节。反观 Score-Based^[37] 方法, 尽管在 CD 指标上不是最优, 但在 P2M 指标上表现出色, 这表明基于梯度的位置更新策略能使点云更紧密地贴合潜在曲面。然而, PCN^[19] 等基于 PointNet 的早期方法, 由于缺乏对局部几何上下文的卷积归纳偏置, 仅依靠全局特征映射, 在处理 50K 高分辨率点云的局部微小起伏时显得力不从心, 精度明显低于结合了图卷积的后续方法。

合成域到真实域的迁移揭示了不同范式的泛化瓶颈。表 7 给出了算法在真实 Kinect 扫描数据上的表现。Total Denoising^[62] 作为无监督方法的

代表,虽然在理论上摆脱了真值依赖,但在真实数据上的误差(CD 为 53.01)远高于其他监督方法。这反映了当前无监督策略中理想高斯噪声假设与真实传感器噪声之间的巨大域差异。相比之下,PointFilter^[20]和 Score-Based^[37]方法展现出较好的泛化性(CD 约为 21),这是因为 PointFilter 利用了法线等几何辅助信息作为约束,而几何特征在不同数据源间具有较强的一致性;Score 类方法学习的是相对梯度场而非绝对位置映射,这种相对关系的学习范式在面对未见过的真实噪声分布时具有更强的适应能力。

综上所述,虽然单阶段 GNN 网络在低噪声下效率与精度兼备,但在复杂高噪声及真实场景中,引入迭代优化机制、结合生成式概率模型以及利用显式几何约束,能有效提升模型去噪上限与泛化能力。

3 挑战与机遇

3.1 技术挑战

在点云数据去噪领域,当前技术面临多维度挑战。

泛化能力与数据稀缺。监督学习依赖成对的噪声-干净数据标注,而真实场景标注成本高昂,限制了算法的优化空间。无监督方法虽通过密度假设构建损失函数,但易产生丝状伪影,影响去噪质量。跨场景适应性不足问题显著,如自动驾驶领域的模型应用于植物表型分析时,需重新设计密度梯度场,凸显算法在不同场景下泛化能力的局限性。

点云不规则性。点云数据的无序性、稀疏性及非均匀分布特性,使基于体素或网格的预处理易造成细节丢失。尽管 Transformer 架构通过自注意力机制捕捉长程依赖关系,但其局部几何特征建模能力不足。对于尖锐几何特征(如边缘、角落),引入法线约束或边缘感知损失函数虽可避免过度平滑,然而高噪声环境下法线估计的不稳定性严重影响特征保留的准确性。

计算效率与硬件依赖。大规模点云处理对显存与算力要求极高,轻量化设计通过三角函数编码与非参数聚合提升速度,但其在高强度噪声下的性能衰减问题突出。此外,硬件采集设备差异如 Kinect 与 LiDAR 导致模型迁移困难,如何动态适应不同传感器特性,成为提升算法普适性的关键挑战。

3.2 未来发展方向

ALL-in-one 模型研发。点云去噪、补全与稠密化等任务本质上均属于从退化观测恢复潜在几

何结构的逆问题,存在内在的协同关系。未来研究将打破分立式处理流程,构建任务通用型的统一修复框架。一方面可借鉴生成式范式,利用扩散模型(如 TIGER^[11]及近期的 SuperPC^[68]等工作)将不同修复任务统一为随机微分方程的逆向求解,通过条件引导实现多任务切换;另一方面可采用“预训练-微调”策略,基于掩码点云建模学习鲁棒的通用几何表征,或引入提示学习机制,通过可学习的任务提示动态调整模型功能。这种统一建模不仅能通过多任务联合训练实现全局结构补全与局部噪声去除的特征互补,更能显著降低边缘侧部署的资源消耗。

自适应噪声建模。针对现实场景中噪声的复杂性与多样性,开发噪声不可知(noise-agnostic)模型成为关键。融合物理传感器模型(揭示噪声产生的物理机制)与数据驱动方法(从实际数据中学习噪声特征),使模型摆脱对先验噪声假设的依赖,能够自适应地处理非高斯、多模态等复杂噪声,增强在不同传感器与环境下的鲁棒性。

低秩与轻量化设计。为兼顾点云处理的精度与实时性,可探索动态稀疏卷积技术,根据点云密度动态调整计算量,减少冗余操作;同时借助神经架构搜索(neural architecture search, NAS)自动化探寻最优网络架构,在保证模型性能的前提下降低计算复杂度。此类研究将推动大规模点云处理在资源受限硬件上的高效部署。

利用 RGB-D 信息(融合颜色与深度特征)或语义分割标签(提供物体类别语义)辅助点云清洗,是提升复杂场景适应性的有效途径。例如,通过 RGB 信息识别与点云几何不匹配的噪声点,借助语义标签指导保留特定物体的点云结构,弥补单一模态点云在复杂场景中信息不足的缺陷,增强算法对多样化场景的适应能力。

4 结束语

本文聚焦近 8 年基于深度学习的三维点云去噪技术,重点解析了以 PointNet 主干网络、卷积神经网络、Transformer 网络、非传统网络框架以及无监督学习策略为核心的 5 大分类体系,并涵盖了针对特定场景的应用研究。在剖析各类方法核心思路与演进脉络的基础上,本文整合了主流数据集与量化评估指标,对比分析了主流算法在不同数据域下的性能差异,并深入探讨了当前面临的泛化性瓶颈与未来全能模型研发等机遇。希望本文能为三维点云去噪技术的理论创新与工程化应用提供系统性参考。

参考文献:

- [1] 王昶畅, 江坤, 姜凯, 等. 基于反馈的迭代采样高噪声点云去噪框架[J]. *图学学报*, 2025, 46(3): 614–623.
WANG Changchang, JIANG Kun, JIANG Kai, et al. Feedback-based iterative sampling denoising framework for point clouds with high-level noise[J]. *Journal of graphics*, 2025, 46(3): 614–623.
- [2] 宋小英, 徐征, 于长龙. 三维激光点云数据去噪方法研究[J]. *测绘与空间地理信息*, 2025, 48(5): 202–204, 211.
SONG Xiaoying, XU Zheng, YU Changlong. Research on the denoising method of 3D laser point cloud data[J]. *Geomatics & spatial information technology*, 2025, 48(5): 202–204, 211.
- [3] 曲金博, 王岩, 赵琪. DBSCAN 聚类和改进的双边滤波算法在点云去噪中的应用[J]. *测绘通报*, 2019(11): 89–92.
QU Jinbo, WANG Yan, ZHAO Qi. Application of DBSCAN clustering and improved bilateral filtering algorithm in point cloud denoising[J]. *Bulletin of surveying and mapping*, 2019(11): 89–92.
- [4] 王兴涛. 基于深度学习的点云去噪研究[D]. 哈尔滨: 哈尔滨工业大学, 2022.
WANG Xingtao. Research on deep-learning point cloud denoising[D]. Harbin: Harbin Institute of Technology, 2022.
- [5] ZHOU Lang, SUN Guoxing, LI Yong, et al. Point cloud denoising review: from classical to deep learning-based approaches[J]. *Graphical models*, 2022, 121: 101140.
- [6] 肖俊, 石光田. 三维点云去噪技术[J]. *中国科学院大学学报*, 2023, 40(5): 577–595.
XIAO Jun, SHI Guangtian. Three-dimensional point cloud denoising[J]. *Journal of University of Chinese Academy of Sciences*, 2023, 40(5): 577–595.
- [7] 吴一全, 陈慧娴, 张耀. 基于深度学习的三维点云处理方法研究进展[J]. *中国激光*, 2024, 51(5): 143–165.
WU Yiquan, CHEN Huixian, ZHANG Yao. Review of 3D point cloud processing methods based on deep learning[J]. *Chinese journal of lasers*, 2024, 51(5): 143–165.
- [8] LI Ying, SHENG Huankun. A single-stage point cloud cleaning network for outlier removal and denoising[J]. *Pattern recognition*, 2023, 138: 109366.
- [9] WANG Ziwei, SUN Wei, TIAN Linyang. 3D point cloud denoising based on hybrid attention mechanism and score matching[C]//Proceedings of the 2022 5th International Conference on Artificial Intelligence and Pattern Recognition. Xiamen: ACM, 2022.
- [10] WANG Junbo, LI Ying. Transformer-based point cloud denoising network[C]//2023 4th International Conference on Big Data & Artificial Intelligence & Software Engineering. Nanjing: IEEE, 2023.
- [11] REN Zhiyuan, KIM M, LIU Feng, et al. TIGER: time-varying denoising model for 3D point cloud generation with diffusion process[C]//2024 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Seattle: IEEE, 2024.
- [12] 孔大力, 江平. 基于 Transformer 和多尺度的点云去噪[J]. *大学数学*, 2023, 39(4): 7–15.
KONG Dali, JIANG Ping. Point cloud denoising based on Transformer and multi scale[J]. *College mathematics*, 2023, 39(4): 7–15.
- [13] CHARLES R Q, HAO Su, MO Kaichun, et al. PointNet: deep learning on point sets for 3D classification and segmentation[C]//2017 IEEE Conference on Computer Vision and Pattern Recognition. Honolulu: IEEE, 2017.
- [14] 李美佳, 于泽宽, 刘晓, 等. 点云算法在医学领域的研究进展[J]. *中国图象图形学报*, 2020, 25(10): 2013–2023.
LI Meijia, YU Zekuan, LIU Xiao, et al. Progress of point cloud algorithm in medical field[J]. *Journal of image and graphics*, 2020, 25(10): 2013–2023.
- [15] QI C R, YI Li, SU Hao, et al. PointNet++: deep hierarchical feature learning on point sets in a metric space[C]//Proceedings of the 30th International Conference on Neural Information Processing Systems. Long Beach: Curran Associates, 2017.
- [16] GUERRERO P, KLEIMAN Y, OVSJANIKOV M, et al. PCPNet learning local shape properties from raw point clouds[J]. *Computer graphics forum*, 2018, 37(2): 75–85.
- [17] YU Lequan, LI Xianzhi, FU C W, et al. EC-Net: an edge-aware point set consolidation network[C]//Computer Vision. Cham: Springer, 2018.
- [18] DUAN Chaojing, CHEN Siheng, KOVACEVIC J. 3D point cloud denoising via deep neural network based local surface estimation[C]//2019 IEEE International Conference on Acoustics, Speech and Signal Processing. Brighton: IEEE, 2019.
- [19] RAKOTOSAONA M J, LA BARBERA V, GUERRERO P, et al. PointCleanNet: learning to denoise and remove outliers from dense point clouds[J]. *Computer graphics forum*, 2020, 39(1): 185–203.
- [20] ZHANG Dongbo, LU Xuequan, QIN Hong, et al. Point-filter: point cloud filtering via encoder-decoder modeling[J]. *IEEE transactions on visualization and computer graphics*, 2021, 27(3): 2015–2027.
- [21] HUANG Anyi, XIE Qian, WANG Zhoutao, et al. MOD-Net: multi-offset point cloud denoising network customized for multi-scale patches[J]. *Computer graphics forum*, 2022, 41(7): 109–119.
- [22] WANG Xingtao, FAN Xiaopeng, ZHAO Debin. PointFilterNet: a filtering network for point cloud denoising[J]. *IEEE transactions on circuits and systems for video technology*, 2023, 33(3): 1276–1290.
- [23] WANG Xingtao, CUI Wenxue, XIONG Ruiqin, et al. FCNet: learning noise-free features for point cloud denoising[J]. *IEEE transactions on circuits and systems for video technology*, 2023, 33(11): 6288–6301.
- [24] WEI Mingqiang, WEI Zeyong, ZHOU Haoran, et al. AG-Conv: adaptive graph convolution on 3D point clouds[J]. *IEEE transactions on pattern analysis and machine intelligence*, 2023, 45(8): 9374–9392.

- [25] ROVERI R, ÖZTIRELI A C, PANDELE I, et al. Point-ProNets: consolidation of point clouds with convolutional neural networks[J]. *Computer graphics forum*, 2018, 37(2): 87–99.
- [26] PISTILLI F, FRACASTORO G, VALSESIA D, et al. Learning graph-convolutional representations for point cloud denoising[C]//Computer Vision. Cham: Springer, 2020.
- [27] PISTILLI F, FRACASTORO G, VALSESIA D, et al. Learning robust graph-convolutional representations for point cloud denoising[J]. *IEEE journal of selected topics in signal processing*, 2021, 15(2): 402–414.
- [28] CHEN Zhaowei, LI Peng, WEI Zeyong, et al. GeoGCN: geometric dual-domain graph convolution network for point cloud denoising[C]//2023 IEEE International Conference on Acoustics, Speech and Signal Processing. Rhodes Island: IEEE, 2023.
- [29] DE SILVA EDIRIMUNI D, LU Xuequan, SHAO Zhiwen, et al. IterativePFN: true iterative point cloud filtering[C]//2023 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Vancouver: IEEE, 2023.
- [30] YI Cheng, WEI Zeyong, QIU Jingbo, et al. PN-Internet: point-and-normal interactive network for noisy point clouds[J]. *IEEE transactions on geoscience and remote sensing*, 2024, 62: 1–11.
- [31] LU Dening, LU Xuequan, SUN Yangxing, et al. Deep feature-preserving normal estimation for point cloud filtering[J]. *Computer-aided design*, 2020, 125: 102860.
- [32] WEI Mingqiang, CHEN Honghua, ZHANG Yingkui, et al. GeoDualCNN: geometry-supporting dual convolutional neural network for noisy point clouds[J]. *IEEE transactions on visualization and computer graphics*, 2023, 29(2): 1357–1370.
- [33] 黄东福, 刘立群. 基于图神经网络的异源图像配准方法综述[J]. *软件工程*, 2025, 28(1): 1–7.
HUANG Dongfu, LIU Liqun. Overview of heterogeneous image registration methods based on graph neural networks[J]. *Software engineering*, 2025, 28(1): 1–7.
- [34] 杨珊珊. 基于特征融合的点云配准技术研究[D]. 郑州: 郑州大学, 2022.
YANG Shanshan. Research of point cloud registration technology based on feature fusion[D]. Zhengzhou: Zhengzhou University, 2022.
- [35] WANG Yue, SUN Yongbin, LIU Ziwei, et al. Dynamic graph CNN for learning on point clouds[J]. *ACM transactions on graphics*, 2019, 38(5): 1–12.
- [36] LUO Shitong, HU Wei. Differentiable manifold reconstruction for point cloud denoising[C]//Proceedings of the 28th ACM International Conference on Multimedia. Seattle: ACM, 2020.
- [37] LUO Shitong, HU Wei. Score-based point cloud denoising[C]//2021 IEEE/CVF International Conference on Computer Vision. Montreal: IEEE, 2021.
- [38] LI Zhenglei, PAN Weigang, WANG Shuxin, et al. A point cloud denoising network based on manifold in an unknown noisy environment[J]. *Infrared physics & technology*, 2023, 132: 104735.
- [39] WANG Weijia, PAN Wei, LIU Xiao, et al. Random screening-based feature aggregation for point cloud denoising[J]. *Computers & graphics*, 2023, 116: 64–72.
- [40] YANG Wenming, HE Zhouyan, SONG Yang, et al. 3D point cloud denoising method based on global feature guidance[J]. *The visual computer*, 2024, 40(9): 6137–6153.
- [41] MAO Aihua, YAN Biao, MA Zijing, et al. Denoising point clouds in latent space via graph convolution and invertible neural network[C]//2024 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Seattle: IEEE, 2024.
- [42] 孔大力. 基于多尺度 Transformer 网络的点云去噪研究[D]. 合肥: 合肥工业大学, 2023.
KONG Dali. The research of point cloud denoising based on multi-scale transformer network[D]. Hefei: Hefei University of Technology, 2023.
- [43] 李玉洁, 马子航, 王艺甫, 等. 视觉 Transformer (ViT) 发展综述[J]. *计算机科学*, 2025, 52(1): 194–209.
LI Yujie, MA Zihang, WANG Yifu, et al. Survey of vision transformers (ViT)[J]. 2025, 52(1): 194–209.
- [44] XU Xueli, GENG Guohua, CAO Xin, et al. TDNet: transformer-based network for point cloud denoising[J]. *Applied optics*, 2022, 61(6): C80.
- [45] ZHU Xusheng, MA Shuai, CHEN Daixin, et al. MSaD-Net: a mix self-attention networks for 3D point cloud denoising[J]. *IEEE photonics journal*, 2023, 15(3): 1–7.
- [46] MAO Aihua, DU Zihui, WEN Yuhui, et al. PD-flow: a point cloud denoising framework with Normalizing flows[C]//Computer Vision – ECCV 2022. Cham: Springer, 2022.
- [47] CHEN Honghua, WEI Zeyong, LI Xianzhi, et al. RePCD-Net: feature-aware recurrent point cloud denoising network[J]. *International journal of computer vision*, 2022, 130(3): 615–629.
- [48] SHENG Huankun, LI Ying. Denoising point clouds with fewer learnable parameters[J]. *Computer-aided design*, 2024, 172: 103708.
- [49] 许同骏, 许杰. 基于深度强化学习的推荐算法的构建研究[J]. *电脑知识与技术*, 2025, 21(9): 33–37.
XU Tongjun, XU Jie. Research on the construction of recommendation algorithms based on deep reinforcement learning[J]. *Computer knowledge and technology*, 2025, 21(9): 33–37.
- [50] WEI Zeyong, CHEN Honghua, NAN Liangliang, et al. PathNet: path-selective point cloud denoising[J]. *IEEE transactions on pattern analysis and machine intelligence*, 2024, 46(6): 4426–4442.
- [51] VOGEL M, TATENO K, POLLEFEYS M, et al. P2P-bridge: diffusion bridges for 3D point cloud denoising[C]//Computer Vision – ECCV 2024. Cham: Springer, 2025.
- [52] LIU Zheng, ZHOU Weijie, GUO Chuchen, et al. PyramidPCD: a novel pyramid network for point cloud denoising[J]. *Pattern recognition*, 2025, 161: 111228.

- [53] DU Qidong. 3D point cloud registration denoising method for human motion image using deep learning algorithm[J]. *Multimedia systems*, 2020, 26(1): 75–82.
- [54] WU Jianeng, XIANG Lirong, YOU Hui, et al. Plant-Denoising-Net (PDN): a plant point cloud denoising network based on density gradient field learning[J]. *ISPRS journal of photogrammetry and remote sensing*, 2024, 210: 282–299.
- [55] LIN Runheng, HU Hao, WEN Zhikun, et al. Research on denoising and segmentation algorithm application of pigs' point cloud based on DBSCAN and PointNet[C]//2021 IEEE International Workshop on Metrology for Agriculture and Forestry. Trento-Bolzano: IEEE, 2021.
- [56] GAN Xiaohang, TAN Libin, WANG Xiaoyi. Application study of PointNet++ and hybrid filtering based point cloud denoising and segmentation algorithms for Blisk [C]//2022 5th World Conference on Mechanical Engineering and Intelligent Manufacturing. Ma'an Shan: IEEE, 2022.
- [57] ZUO L L, ZHANG J, DING S L, et al. Attention mechanism-based deep learning denoising of scanned point cloud for rocket tank panel[C]//2023 IEEE International Conference on Industrial Engineering and Engineering Management. Singapore: IEEE, 2023.
- [58] SEPPÄNEN A, OJALA R, TAMMI K. Self-supervised multi-echo point cloud denoising in snowfall[J]. *Pattern recognition letters*, 2024, 185: 52–58.
- [59] LIU Junyu, REN Jianfeng, SUN Hongliang, et al. Face recognition on point cloud with CGAN-Top for denoising [C]//2023 IEEE International Conference on Acoustics, Speech and Signal Processing. Rhodes Island: IEEE, 2023.
- [60] 侯广哲, 秦贵和, 梁艳花. 基于下采样的自监督点云去噪方法[J]. *吉林大学学报(理学版)*, 2024, 62(1): 100–105.
- HOU Guangzhe, QIN Guihe, LIANG Yanhua. Self-supervised point cloud denoising method based on down-sampling[J]. *Journal of Jilin University (science edition)*, 2024, 62(1): 100–105.
- [61] LEHTINEN J, MUNKBERG J, HASSELGREN J, et al. Noise2Noise: learning image restoration without clean data[C]//Proceedings of the 35th International Conference on Machine Learning. Brookline: PMLR, 2018.
- [62] HERMOSILLA P, RITSCHER T, ROPINSKI T. Total denoising: unsupervised learning of 3D point cloud cleaning[C]//2019 IEEE/CVF International Conference on Computer Vision. Seoul: IEEE, 2019.
- [63] CHEN Siheng, DUAN Chaojing, YANG Yaoqing, et al. Deep unsupervised learning of 3D point clouds via graph topology inference and filtering[J]. *IEEE transactions on image processing*, 2020, 29: 3183–3198.
- [64] WANG Weijia, LIU Xiao, ZHOU Hailing, et al. Noise4Denoise: leveraging noise for unsupervised point cloud denoising[J]. *Computational visual media*, 2024, 10(4): 659–669.
- [65] MA Baorui, LIU Yushen, HAN Zhizhong. Learning signed distance functions from noisy 3D point clouds via noise to noise mapping[C]//Proceedings of the 40th International Conference on Machine Learning. Brookline: PMLR, 2023.
- [66] ZHOU Junsheng, MA Baorui, LIU Yushen, et al. Fast learning of signed distance functions from noisy point clouds via noise to noise mapping[J]. *IEEE transactions on pattern analysis and machine intelligence*, 2024, 46(12): 8936–8953.
- [67] SU Zhiyong, WANG Changchang, JIANG Kun, et al. SITF: a self-supervised iterative training framework for point cloud denoising[J]. *Computer-aided design*, 2025, 179: 103812.
- [68] DU Yi, ZHAO Zhipeng, SU Shaoshu, et al. SuperPC: a single diffusion model for point cloud completion, up-sampling, denoising, and colorization[C]//2025 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Nashville: IEEE, 2025.

作者简介:



王兴涛, 副研究员, 博士, 主要研究方向为三维空间计算、沉浸式媒体、具身智能。主持国家自然科学基金青年项目 1 项, 参与包括国家重点研发计划、国自然重点联合基金、国自然面上项目在内的多项国家级项目。发表学术论文 30 余篇。E-mail: xtwang@hit.edu.cn。



代梦丽, 硕士研究生, 主要研究方向为三维点云去噪。E-mail: 24s136078@stu.hit.edu.cn。



范晓鹏, 教授, 博士生导师, 国家级高层次人才, 国家重点研发计划项目首席科学家, 哈工大计算学部智能接口与人机交互研究中心主任, 苏州研究院数字孪生与具身智能团队负责人, 曾任香港科技大学研究助理教授、哈工大人工智能专业负责人等。主要研究方向为三维视觉、视频编码、多模态、具身智能。担任中国人工智能学会(CAAI)教育工作委员会副主任、黑龙江省计算机学会学术工作委员会主任、脑机接口技术应用应急管理重点实验室学术委员会主任等。入选教育部人才计划(2011年)。2013年获IEEE标准杰出贡献奖。2023年获电子学会创新团队奖。发表学术论文 200 余篇。E-mail: fxp@hit.edu.cn。