

基于图池化优化的点云语义分割方法研究

徐雪丽^{1,2}, 王红珍¹, 王敬禹²

(1. 延安大学 数学与计算机科学学院, 陕西 延安 716000;

2. 西北大学 信息科学与技术学院, 西安 710127)

摘要: 针对基于编码器-解码器架构的点云分割方法在几何细节与上下文信息利用方面存在的不足, 对点云语义分割中的特征流失问题进行了研究; 通过分析原始点云中几何细节与深层语义特征的互补关系, 构建了多层次特征表示体系; 采用边缘保持图池化 (EGP) 模块和边缘保持图反池化 (EGU) 模块相结合的技术方案, 其中 EGP 模块通过几何约束机制实现边缘结构特征的显式保留, EGU 模块利用保留的边缘特征指导特征重建, 形成闭环优化系统; 实验测试在 S3DIS 基准数据集上进行, 结果表明该方法在 Area-5 测试集上实现了 73.8% 的平均类别准确率 (mAcc), 较现有方法有显著提升; 消融实验验证了 EGP 和 EGU 模块的有效性, 该方法能够满足三维场景理解中对精细几何特征保持的需求, 展现了其在点云语义分割上的应用潜力。

关键词: 点云; 图卷积; 图池化; 边缘保持; 语义分割; S3DIS

Research on Point Cloud Semantic Segmentation Method Based on Graph Pooling Optimization

XU Xueli^{1,2}, WANG Hongzhen¹, WANG Jingyu²

(1. College of Mathematics and Computer Science, Yan'an University, Yan'an 716000, China;

2. School of Information Science and Technology, Northwest University, Xi'an 710127, China)

Abstract: To address the limitations of point cloud segmentation methods based on the encoder-decoder architecture in utilizing geometric details and contextual information, research on the feature loss in point cloud semantic segmentation is carried out. By analyzing the complementary relationship between geometric details and deep semantic features in the raw point cloud, a multi-level feature representation system is constructed. A technical solution combining an edge-guided graph pooling (EGP) module and an edge-guided graph unpooling (EGU) module is presented, and the EGP module explicitly retains edge structural features through a geometric constraint mechanism, while the EGU module guides feature reconstruction using the retained edge features, forming a closed-loop optimization system. Experimental tests are conducted on the S3DIS benchmark dataset, and the results show that the proposed method achieves a mean accuracy (mAcc) of 73.8% on the Area-5 test set, which is notably superior to that of existing methods. Ablation experiments validate the effectiveness of the EGP and EGU modules. The method meets the requirement to maintain fine geometric features in 3D scene understanding and demonstrates its potential applications in point cloud semantic segmentation.

Keywords: point cloud; graph convolution; graph pooling; edge preserving; semantic segmentation; S3DIS

0 引言

点云语义分割作为计算机视觉与三维场景理解的核心任务, 在场景重建^[1-3]、自动驾驶^[4]等前沿领域具有

重要研究价值。点云数据的三维表征特性, 使其能够完整保留场景的几何结构、拓扑关系以及形状特征。然而点云数据的非欧式空间特性导致传统卷积神经网络难以直接应用。早期的研究主要依赖于传统机器学习方法

收稿日期: 2025-04-29; 修回日期: 2025-06-02。

基金项目: 国家自然科学基金(62271393); 陕西省自然科学基金基础研究计划项目(2023-JC-QN-0744)。

作者简介: 徐雪丽(1990-), 女, 硕士, 讲师。

通讯作者: 王红珍(1973-), 女, 硕士, 高级工程师。

引用格式: 徐雪丽, 王红珍, 王敬禹. 基于图池化优化的点云语义分割方法研究[J]. 计算机测量与控制, 2025, 33(10): 298-304.

(如支持向量机^[5]、随机森林^[6]和决策树^[7]), 这些方法在处理小型数据集时能够取得一定的效果, 但在特征表达能力上存在明显的局限性, 其特征提取过程缺乏对复杂数据结构的自适应能力, 难以捕捉数据中的深层次信息。

近年来, 随着深度学习技术的迅猛发展, 研究者在三维数据处理领域取得了显著进展, 相继提出了三类主流深度学习方法: 1) 体素化方法^[8-10] 通过将三维空间划分为规则网格, 并在这些网格上应用三维卷积操作, 为三维数据的处理提供了一种直观且有效的解决方案。然而, 这种方法面临分辨率与计算量之间的固有矛盾: 提高分辨率虽然能够增强细节捕捉能力, 但会急剧增加计算量和内存需求, 从而限制了其在高分辨率场景下的应用; 2) 投影方法^[11-15] 通过将三维点云映射到二维平面上, 利用成熟的二维卷积神经网络进行处理。这种方法虽然在计算效率上具有一定优势, 但不可避免地引入了几何失真, 导致部分三维结构信息的丢失, 尤其在处理复杂几何形状时, 这种失真可能对后续任务产生较大影响; 3) 点云直接处理方法^[16-21], 如开创性的 PointNet++^[17], 直接在点云数据上进行操作, 能够最大程度地保留几何信息的完整性。这类方法在处理小场景和局部几何结构时表现出色, 但在面对大规模场景时, 由于点云数据的稀疏性和不规则性, 处理效率仍然面临巨大挑战。

特别值得关注的是, 随着图结构与点云数据之间对应关系的深入理解, 基于图的方法在点云处理领域蓬勃发展, 极大地推动了该领域的进步。这些方法通过将点云数据转换为图结构, 不仅保留了点云中节点与边之间的几何特征, 还使得图卷积网络 (GCN, graph convolutional network) 能够高效地进行特征提取。例如, DGCNN^[20] 利用 K 最近邻 (KNN, K-nearest neighbors) 动态构建点云的结构信息, 为点云处理提供了新的视角。DeepGCNs^[21] 则突破了传统 GCN 在多层迭代上的限制, 为图神经网络的进一步发展奠定了坚实基础。此外, Graph U-Nets^[22] 实现了图数据上的编码器-解码器架构, 引入 gPool 和 gUnpool 层, 分别用于图的池化和上采样操作, 这使得在图结构上实现类似 U-Net 的架构成为可能。然而, 尽管现有方法在点云语义分割领域取得了显著进展, 但在几何细节保持与上下文信息利用方面仍存在明显不足: 1) 多层特征传递过程中的几何信息流失问题; 2) 边缘结构特征的显式保持不足; 3) 特征重建过程中缺乏有效的几何指导机制。

与现有方法相比, 本文提出的边缘保持图池化优化网络具有以下创新优势: 1) 通过几何约束机制显式保留边缘结构特征 (优于 DGCNN 的动态图构建); 2) 构

建闭环优化系统实现几何指导的特征重建 (较 Graph U-Nets 的简单上采样方法更具针对性); 3) 多层次特征表示体系能够更好地平衡几何细节与语义信息 (相比 DeepGCNs 的深度特征提取)。

该方法在处理复杂场景时能够实现保持几何精度的同时, 提升算法对场景的语义理解能力。

1 图池化优化的点云语义分割方法

该研究提出了一种基于边缘保持的图池化优化点云分割方法, 其网络架构由编码器和解码器两部分构成。在特征提取阶段, 该方法创新性地采用了 Inception DenseGCN^[23] 来处理图形式的三维点云数据。Inception DenseGCN 是一种融合了 Inception 模块多尺度特征提取能力和 DenseGCN 特征密集连接特性的先进网络结构, 特别适用于处理大规模图数据。此外, 该方法针对图池化操作, 提出了边缘保持图池化 (EGP, edge-preserving graph pooling) 模块, 通过几何约束机制保留关键边缘特征; 针对图反池化操作, 设计了边缘保持图反池化 (EGU, edge-preserving graph unpooling) 模块, 利用保留的边缘信息指导特征重建。这两个模块协同工作, 在保持几何精度的同时有效提升了分割性能, 为点云分割任务提供了新的技术解决方案。

1.1 基于边缘保持的图池化 (EGP)

池化操作是卷积神经网络 (CNN, convolutional neural network) 中的重要步骤, 在特征降维、减少参数量以及增强特征语义等方面具有重要作用, 常见的池化方式有最大池化和平均池化。与 CNN 不同, 图卷积网络 (GCN) 无法直接使用 CNN 的池化操作, 因为会破坏特征图的空间结构信息。为解决这一问题, Graph U-Nets 提出了一种针对图卷积网络的经典池化方法。该方法在池化过程中引入了 top- k 评分机制, 通过得分评估节点的重要性来选择部分节点, 同时丢弃其余节点及其连接。这种方法虽然能够保证重要特征节点的信息不被丢弃, 但被丢弃节点的信息无法恢复。此外, 池化后新图的边通常由简单的邻接矩阵变换生成, 这导致原始边的属性被忽略, 进而影响空间信息及拓扑关系。为了克服这一局限性, 该研究提出了一种优化的基于边特征保持的图池化方法 (EGP)。该方法能够有效捕获和保留局部几何结构信息。不同采样方法的对比如图 1 所示。图 1 (a) 展示了基于 top- k (例如 $k=3$) 的传统图池化方法, 图 1 (b) 展示了 EGP 池化的过程。在 EGP 池化中, 通过 top- k 选择 k 个节点后, 并非直接对节点进行下采样, 而是从原始点云数据中构建选中 k 个节点的局部邻域图, 然后通过随机下采样 (例如 $\{t_5, t_6, t_7, t_8, t_9, t_{10}, t_{11}\}$) 选择其邻域节点。与传统仅保留

顶点信息的图池化相比,EGP 能够充分保持关键节点的局部几何结构特征。因此,在池化过程中,EGP 能够保留更多空间特征信息,从而提高模型在分类和分割任务中的性能表现。




图 1 采样方法示意图

在编码器模块中,图卷积网络(如图 2 所示)首先对输入点云执行 1×1 卷积操作,之后利用不同膨胀率进行基于 DenseGCN 的特征提取,并将结果进行连接。再使用 EGP 进行图池化操作。 d 为膨胀率, r 为 EGP 的随机下采样率。




图 2 图卷积过程

具体而言,通过 top- k 算法从特征图中选择得分最高的 k 个中心节点。基于这些中心节点,在原始点云数据中构造其局部邻域子图,并通过随机下采样降低局部邻域子图中边缘节点的密度。最后,聚合得分最高的 k 个节点及其边缘节点的特征信息。通过 EGP 将中心节点及其边缘节点合并为一个增强型节点,能够更有效地保留每个中心节点的局部特征信息。EGP 模块的设计公示如下:

$$\begin{cases} \text{Score} = \frac{\mathbf{X}^i P^i}{\|\mathbf{P}^i\|} \\ \text{idx} = \text{rank}(\text{Score}, k) \\ \mathbf{X}'_p = \mathbf{X}_p \oplus h(\mathbf{X}'_1, \dots, \mathbf{X}'_i) \\ \widetilde{\text{Score}} = \text{sigmoid}[y(\text{idx})] \\ \tilde{\mathbf{X}}^i = \mathbf{X}^i(\text{idx}, :) \\ \mathbf{X}^{i+1} = \tilde{\mathbf{X}}^i \odot (\widetilde{\text{Score}} \mathbf{1}_c^T) \end{cases} \quad (1)$$

其中: k 表示通过 top- k 算法选择的节点数量,该值是通过实验验证与理论分析相结合的方式最终确定,具体见后续消融实验章节内容。 idx 和 $\mathbf{X}^i(\text{idx}, :)$ 分别是选定点的索引和特征矩阵,用于构造新的图结构。 $\mathbf{X}_p$ 表示选定节点的特征, $\mathbf{X}'_i$ 表示随机下采样后保留的邻域点特征。编码器整体结构如图 3 所示。




图 3 编码器结构 (圆型图为 EGP 操作过程图例)

1.2 基于边缘保持的图反池化 (EGU)

反池化操作是解码器模块中的重要环节,其核心目标是将下采样过程中获得的稀疏三维点特征恢复到相应的密度水平,以便为后续的处理与分析提供更丰富的细节信息。为此,该研究提出的 EGU 模块首先将特征图中的节点设置为中心节点,并基于原始点云数据构建每个中心节点的局部邻域子图。与 EGP 类似,EGU 通过选择重要节点来保持关键特征信息。随后,对邻域子图的边缘节点进行随机下采样,以降低计算复杂度,同时保留关键信息。之后,EGU 对中心节点和边缘节点的特征信息进行聚合,进一步增强特征表达。在逐步上采样过程中,EGU 连接中心节点与其在原始点云数据中的邻域节点,并利用局部细节信息来增强中心节点的特征表示。这种方法不仅能够有效恢复下采样层得到的稀疏特征到相应的密度,还能显著提升模型的表达能力,同时保留重要的局部特征信息。这些特性使得 EGU 在点云分割任务中表现出色,显著提高了模型的性能。EGU 模块的设计公式如下:

$$\mathbf{X}'_q = \mathbf{X}_q^f \oplus \omega(\mathbf{X}_q^1, \dots, \mathbf{X}_q^i) \quad (2)$$

其中: $\mathbf{X}_q^f$ 是跳跃连接得到的编码器模块中相应层的特征信息, $\omega(\cdot)$ 是逆距离加权平均运算。

1.3 网络设计

基于图池化优化的点云分割方法如图 4 所示,该方法以 U 型编码器-解码器结构为基础,充分利用基于边缘保持的图池化 (EGP) 和基于边缘保持的图反池化 (EGU),最大限度地保留点云数据中的局部细节和全局结构信息,实现点云精细化分割。

编码器通过 3 个特征提取模块逐步提取点云数据特征,在 EGP 中通过引入 top- k 算法,选择得分最高的前 k 个中心节点,构建其局部邻域子图,在保证关键特征节点的同时通过降低边缘节点密度聚合中心节点与边缘节点的特征信息。解码器采用与编码器对应的结构,通过与编码器的跳跃连接实现局部特征信息的有效聚合。通过 EGU,在反池化操作中同样选择中心节点,构建局部邻域子图,并通过随机下采样减少边缘节点密度,最后




图 4 图池化优化的点云分割方法架构设计

聚合中心节点和边缘节点的特征信息，逐层恢复特征。

在图 4 中，黑色线和灰色线分别表示编码器和解码器的信息流动路径，凸显信息在网络中的传递和聚合。该架构通过有效融合局部细节与全局上下文信息，在点云语义分割任务中取得了具有竞争力的实验结果。

2 实验结果与分析

2.1 数据集与度量指标

S3DIS^[24]是由斯坦福大学创建的一个大规模三维室内空间点云数据集，广泛应用于点云分类、分割、室内导航等领域。该数据集包含 6 个大型室内区域，总计 271 个房间，覆盖了办公室、会议室、走廊等多种场景。每个点云数据中的点都赋予了语义标签，包括 13 个对象类别，如墙壁、窗户、门、桌子、椅子、地板等。评价该数据集的语义分割性能可以反映算法对复杂室内场景的泛化能力。

该方法使用 Tensorflow 和 Python3.6，设置动量为 0.9，初始学习率为 0.001，批次大小为 12，进行了 100 轮训练，用总体准确度（OA，overall accuracy）、平均交并比（mIoU，mean intersection over union）和平均类别准确率（mAcc，mean accuracy）作为分割的性能评价指标。相关定义如下：

$$OA = \frac{\sum_{i=0}^k c_{ii}}{\sum_{i=0}^k \sum_{j=0}^k c_{ij}} \tag{3}$$

$$mACC = \frac{1}{k+1} \sum_{i=0}^k \frac{c_{ii}}{\sum_{j=0}^k c_{ij}} \tag{4}$$

$$mIoU = \frac{1}{k+1} \sum_{i=0}^k \frac{p_{ii}}{\sum_{i=0}^k p_{ij} + \sum_{i=0}^k p_{ji} - p_{ii}} \tag{5}$$

其中： k 表示数据集有 k 个类别， c_{ij} 表示来自标准数值 i 的点并被预测为类别 j 。

2.2 结果与分析

该方法在 S3DIS 数据集上进行了 Area-5 和 6-fold 两种测试，并与现有方法进行了对比，包括 PointNet^[16]，DGCNN^[20]，SegCloud^[25]，PointCNN^[19]，SPGraph^[26]，HPEIN^[27]，MinkowskiNet^[28]，PAG^[29]，PointWeb^[18]，

PCT^[30]，SegGCN^[31]，KPConv^[32]，RandLA-Net^[33]，DPFA-Net^[34]，JSNet++^[35]，实验结果如表 1 和表 2 所示。

表 1 S3DIS Area-5 上的语义分割结果比较 %

方法	输入	OA	mAcc	mIoU
PointNet	点集	—	49.0	41.1
SegCloud	点集	—	57.4	48.9
PointCNN	点集	85.9	63.9	57.3
SPGraph	点集	86.4	66.5	58.0
HPEIN	点集	87.2	68.3	61.9
MinkowskiNet	体素	—	71.7	65.4
PAG	点集	86.8	—	59.3
PointWeb	点集	87.0	66.6	60.3
PCT	点集	—	70.8	60.1
SegGCN	点集	88.2	70.4	63.6
KPConv	点集	—	72.8	67.1
RandLA-Ne	点集	87.2	71.4	62.4
DPFA-Net	点集	88.0	—	55.2
JSNet++	点集	89.1	64.7	58.0
本文	点集	87.7	73.8	60.0

表 2 S3DIS 6-fold 上的语义分割结果比较 %

方法	输入	OA	mAcc	mIoU
PointNet	点集	78.5	66.2	47.6
DGCNN	点集	84.1	—	56.1
PointCNN	点集	88.1	—	65.4
SPGraph	点集	86.4	75.6	62.1
PAG	点集	88.1	—	65.9
PointWeb	点集	87.3	76.2	66.7
KPConv	点集	—	79.1	70.6
RandLA-Net	点集	88.0	82.0	70.0
DPFA-Net	点集	89.2	—	61.6
JSNet++	点集	88.7	72.8	62.4
本文	点集	88.6	75.8	63.1

在 Area-5 数据集上，本文方法的 $mIoU$ 达到 60.0%， OA 为 87.7%， $mAcc$ 为 73.8%，总体性能优于大多数其他方法。在 6-fold 数据集上，该方法的 $mIoU$ 为 63.1%， OA 为 88.6%， $mAcc$ 为 75.8%，虽然在 $mIoU$ 指标上略低于目前的最佳数据，但总体性能依然位于前列。总体来说，本文方法的性能在提高分类准确率（ $mAcc$ ）方面做出了突出贡献，说明该方法能够很好地保留局部细节和全局结构特征，从而提升分割精度，也说明了在点云语义分割领域的巨大应用潜力。

与 OA 和 $mAcc$ 相比，本文方法在 $mIoU$ 指标上相对逊色，可能原因如下：

首先， $mIoU$ 对小目标类别更加敏感。 $mIoU$ 是基于每个类别的 IoU 进行计算，对于柱子、梁等小目标类别的分割准确性更加敏感。相比之下， OA 和 $mAcc$ 对小目标类别的影响相对较小。由于本文方法在分割这

些小目标时效果不够理想，导致整体 $mIoU$ 降低。其次，类间相似性较高可能导致错分。在 S3DIS 数据集中，部分类别之间的相似性较高，比如墙壁和楼板、桌子和书架等。本文方法在区分这些相似类别时出现了一定程度的错分，导致 $mIoU$ 下降。相比之下， OA 和 $mAcc$ 对错分的惩罚较小。

图 5 展示了本文方法在复杂室内场景中的可视化分割效果，从结果可以观察到，该方法能够准确识别并分割各类复杂室内要素，这主要得益于 EGP 和 EGU 模块的协同作用：EGP 模块通过几何约束机制，在下采样过程中有效保留了关键边缘特征；EGU 模块利用保留的边缘指导信息，实现了更精确的特征重建；二者的闭环优化确保了特征传递中的几何一致性，助力模型更好地聚合局部信息，从而获得更优的分割结果。




图 5 在 S3DIS 上的可视化效果

表 3 展示了不同方法在 S3DIS 数据集上的详细分割结果。从实验结果可以看出，本文提出的方法在多个类别上展现出较好的性能，尤其在桌子（77.7%）、椅子（84.8%）和地板（97.5%）等主要家具和室内结构上取得了很高的分割精度，在墙壁（80.5%）和沙发（46.4%）等类别上的 $mIoU$ 显著优于其他大多数方法，在窗户（59.6%）和门（41.6%）等具有复杂几何结构的类别分割上表现也很突出。这得益于该方法的多层次特征融合机制，在复杂室内场景下能够同时捕捉局部几何细节和全局上下文信息，表明其具备较强的形状理解和几何特征提取能力。虽然对于类内差异较大的杂物

（54.2%）和柱子（20.6%）等类别，其分割精度仍有提升空间，但相比现有方法已展现出明显优势。实验也发现该方法对小尺度目标（如灯具、装饰品等）的分割效果相对有限，这主要由于点云数据本身在这些区域的稀疏性所致。未来研究将重点优化网络对小尺度目标的特征提取能力，以进一步提升整体分割性能。

2.3 消融实验

2.3.1 不同组件的消融实验

为了系统评估各模块的贡献，在 S3DIS 数据集的 Area-5 子集上进行了消融实验。表 4 的实验结果充分验证了 EGP 和 EGU 模块在特征提取与重建中的关键作用。具体而言，当采用传统 Graph U-Nets^[31] 中的 gPooling 和 gUnpooling 模块替代 EGP 和 EGU 模块时，模型的整体精度（ OA ）和平均类别准确率（ $mAcc$ ）分别显著下降至 86.9% 和 72.4%，单独移除 EGP 或 EGU 模块中的任意一个，同样会导致 OA 和 $mAcc$ 的明显下降。这是因为 EGP 模块通过几何约束机制有效保留了点云的边缘结构特征，而 EGU 模块则基于这些保留特征实现了更精确的特征重建。二者的联合作用显著减少了特征传递过程中的信息损失，特别是对细粒度几何特征的保持。这充分证明，针对 3D 点云数据特性优化图池化和反池化操作，是提升语义分割性能的有效途径，具有重要的理论价值和实际意义。

2.3.2 不同 k 值的消融实验

$top-k$ 中的 k 值决定了池化过程中保留的中心节点数量，直接影响局部几何结构的完整性。过小的 k 值会导致关键特征丢失，而过大的 k 值会增加计算负担并引入冗余信息。为了确定 k 值，在 Area-5 数据集上进行了对比实验（其中， $k \in \{8, 16, 32, 64\}$ ），实验结果如表 5 所示。

由表 5 可知，当 $k = 16$ 时，该方法在分割上的 $mAcc$ 和 $mIoU$ 指标上达到最优平衡。这一取值能够有效覆盖点云局部邻域的主要特征，同时避免过度采样。

2.3.3 不同下采样比例 r 的敏感性分析

随机下采样比例 r 的设置需兼顾以下矛盾需求：在

表 3 S3DIS area-5 上的语义分割 $mIoU$ 对比%

方法	$mIoU$	天花板	地板	墙壁	梁	柱子	窗户	门	桌子	椅子	沙发	书架	木板	杂物
PointNet	41.1	88.8	97.3	69.8	0.1	3.9	46.3	10.8	59.0	52.6	5.9	40.3	26.4	33.2
SegCloud	48.9	90.1	96.1	69.9	0.0	18.4	38.4	23.1	70.4	75.9	40.9	58.4	13.0	41.6
PointCNN	57.3	92.3	98.2	79.4	0.0	17.6	22.8	62.1	74.4	80.6	31.7	66.7	62.1	56.7
SPGraph	58.0	89.4	96.9	78.1	0.0	42.8	48.9	61.6	84.7	75.4	69.8	52.6	2.1	52.2
PCT	60.1	92.5	98.4	80.6	0.0	19.4	61.6	48.0	76.6	85.2	46.2	67.7	67.9	52.3
PointWeb	60.3	91.6	98.5	79.4	0.0	21.1	59.7	34.8	76.3	88.3	46.9	69.3	64.9	52.5
JSNet++	58.0	93.7	98.5	80.5	0.0	16.9	57.2	41.9	76.8	84.7	30.5	60.2	58.3	54.9
本文	60.0	92.1	97.5	80.5	0.0	20.6	59.6	41.6	77.7	84.8	46.4	61.5	63.4	54.2

表 4 基于不同组件的消融实验结果

EGP	EGU	OA/%	mACC/%
×	×	86.9	72.4
×	✓	87.1	73.1
✓	×	87.2	73.0
✓	✓	87.7	73.8

表 5 不同 k 值对分割性能的影响

k 值	OA/%	mAcc/%	mIoU/%
8	86.5	71.2	58.3
16	87.7	73.8	60.0
32	87.1	72.6	59.4
64	86.8	71.9	58.9

计算效率方面，较高的下采样比例可以显著减少邻域节点数，降低内存和计算开销；在几何完整性方面，较低的比例能够保留更多局部门点，有利于边缘和细小结构的特征保持。为平衡效率与精度，我们采用分层策略进行实验：在编码器的 3 个层级中，分别设置 $r=0.3$ 、 0.5 和 0.7 的不同比例探索随机下采样比例 r 对分割性能的影响，而非预设固定值。

表 6 不同下采样比例 r 的消融实验结果

层级	下采样比例 r	mIoU/%	mACC/%
1	0.3	58.9	72.1
2	0.5	59.7	73.4
3	0.7	60.0	73.8

如表 6 可知，分层递增的渐进式下采样在深层特征提取中表现更优，因其更关注全局上下文语义信息而非局部几何细节，能适应特征抽象层次的变化，浅层保留更多几何细节 ($r=0.3$)，而深层侧重语义聚合 ($r=0.7$)，并在 Area-5 数据集上实现了 73.8% 的 $mACC$ ，较固定比例提升约 1.2%。值得注意的是，过高的 r (如 $r=0.9$) 会导致小目标 (如柱子) 的 $mIoU$ 下降约 5.7%，验证了适度保留细节的必要性。与固定比例方法 (如 Graph U-Nets) 相比，本策略在保持可比计算效率的同时，提升了边缘敏感类别的分割精度。尽管动态调整策略展现了优势，但其泛化性可能受数据集密度分布的影响。未来可通过自适应学习比例参数进一步优化。

3 结束语

基于图池化优化的点云语义分割方法在点云分割研究中发挥了重要作用，并为该领域提供了新的思路。通过利用 DeepGCN 提取点的拓扑特征，不仅能够获取单个点的信息以及点之间的关系，还能更准确、细致地表达点云的整体特征信息。在每次池化 (EGP) 和反池化 (EGU) 操作中，采用 top- k 策略获取 k 个中心点，并

聚合随机邻域信息，这不仅确保了模型的学习效率，还显著减少了几何信息的丢失。此外，通过 U 形结构融合低层和高层特征，进一步提高了分割的准确性。实验结果验证了本文模型的优越性和合理性。未来可以尝试将该模型应用于更多领域，例如自动驾驶领域，以解决复杂场景下的点云分割问题。此外，还可以探索引入 U^2 Net 模型，这可能会进一步提高模型分割结果的准确性和鲁棒性。

参考文献：

[1] 宁小娟, 赵昊罡, 巩亮, 等. 物体检测驱动下的三维室内场景重建方法 [J]. 计算机辅助设计与图形学学报, 2025; 1-10.

[2] JI H, LUO X. 3D scene reconstruction of landslide topography based on data fusion between laser point cloud and UAV image [J]. Environmental Earth Sciences, 2019, 78 (17): 534.

[3] ZHOU T, ZHU Q, DU J. Intuitive robot teleoperation for civil engineering operations with virtual reality and deep learning scene reconstruction [J]. Advanced Engineering Informatics, 2020, 46: 101170.

[4] 秦飞巍, 沈希乐, 彭勇, 等. 无人驾驶中的场景实时语义分割方法 [J]. 计算机辅助设计与图形学学报, 2021, 33 (7): 1026-1037.

[5] 朱涛, 史文兵, 刘永志, 等. 基于支持向量机的三维点云岩体结构面半自动识别方法 [J]. 防灾减灾工程学报, 2025, 45 (1): 95-103.

[6] NIEMEYER J, ROTTENSTEINER F, SOERGEL U. Contextual classification of lidar data and building object detection in urban areas [J]. ISPRS Journal of Photogrammetry and Remote Sensing, 2014, 87: 152-165.

[7] WEINMANN M, JUTZI B, MALLETT C. Semantic 3D scene interpretation: a framework combining optimal neighborhood size selection with relevant features [J]. ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences, 2014, 2: 181-188.

[8] 王宏远. 基于八叉树体素的细粒度点云分割 [D]. 哈尔滨: 哈尔滨工程大学, 2022.

[9] LE T, DUAN Y. Pointgrid: a deep network for 3d shape understanding [C] //Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2018: 9204-9214.

[10] ZHU X, ZHOU H, WANG T. Cylindrical and asymmetrical 3D convolution networks for lidar segmentation [C] //Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2021: 9939-9948.

[11] JI J, SHI R, LI S. Encoder-decoder with cascaded CRFs for semantic segmentation [J]. IEEE Transactions on

- Circuits and Systems for Video Technology, 2020, 31 (5): 1926–1938.
- [12] CHEN Q, CHENG A, HE X. Spatialflow: bridging all tasks for panoptic segmentation [J]. IEEE Transactions on Circuits and Systems for Video Technology, 2020, 31 (6): 2288–2300.
- [13] SUN X, CHEN C, WANG X. Gaussian dynamic convolution for efficient single-image segmentation [J]. IEEE Transactions on Circuits and Systems for Video Technology, 2021, 32 (5): 2937–2948.
- [14] LAWIN F J, DANELLJAN M, TOSTEBERG P. Deep projective 3D semantic segmentation [C] //Computer Analysis of Images and Patterns: 17th International Conference, Ystad, Sweden, Springer International Publishing, 2017: 95–107.
- [15] BOULCH A, LE SAUX B, AUDEBERT N. Unstructured point cloud semantic labeling using deep segmentation networks [J]. 3dor@eurographics, 2017, 3: 1–8.
- [16] QI C R, SU H, MO K. Pointnet: deep learning on point sets for 3d classification and segmentation [C] //Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2017: 652–660.
- [17] QI C R, YI L, SU H. Pointnet++: deep hierarchical feature learning on point sets in a metric space [J]. Advances in Neural Information Processing Systems, 2017: 30.
- [18] ZHAO H, JIANG L, FU C W. Pointweb: enhancing local neighborhood features for point cloud processing [C] //Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2019: 5565–5573.
- [19] LI Y, BU R, SUN M. Pointenn: convolution on x-transformed points [J]. Advances in Neural Information Processing Systems, 2018: 31.
- [20] WANG Y, SUN Y, LIU Z. Dynamic graph CNN for learning on point clouds [J]. ACM Transactions on Graphics (tog), 2019, 38 (5): 1–12.
- [21] LI G, MULLER M, THABET A. DeepGCNs: Can GCNs go as deep as CNNs? [C] //Proceedings of the IEEE/CVF International Conference on Computer Vision, 2019: 9267–9276.
- [22] GAO H, JI S. Graph u-nets [C] //International Conference on Machine Learning. PMLR, 2019: 2083–2092.
- [23] QIAN G, ABUALSHOUR A, LI G. Pu-GCN: point cloud upsampling using graph convolutional networks [C] //Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2021: 11683–11692.
- [24] ARMENI I, SENER O, ZAMIR A R. 3d semantic parsing of large-scale indoor spaces [C] //Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2016: 1534–1543.
- [25] TCHAPMI L, CHOY C, ARMENI I. Segcloud: semantic segmentation of 3d point clouds [C] //2017 International Conference on 3D Vision (3DV). IEEE, 2017: 537–547.
- [26] LANDRIEU L, SIMONOVSKY M. Large-scale point cloud semantic segmentation with superpoint graphs [C] //Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2018: 4558–4567.
- [27] JIANG L, ZHAO H, LIU S. Hierarchical point-edge interaction network for point cloud semantic segmentation [C] //Proceedings of the IEEE/CVF International Conference on Computer Vision, 2019: 10433–10441.
- [28] CHOY C, GWAK J Y, SAVARESE S. 4d spatio-temporal convnets: Minkowski convolutional neural networks [C] //Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2019: 3075–3084.
- [29] PAN L, CHEW C M, LEE G H. PointAtrousGraph: deep hierarchical encoder-decoder with point atrous convolution for unorganized 3D points [C] //2020 IEEE International Conference on Robotics and Automation (ICRA). IEEE, 2020: 1113–1120.
- [30] GUO M H, CAI J X, LIU Z N. Pct: Point cloud transformer [J]. Computational Visual Media, 2021, 7: 187–199.
- [31] LEI H, AKHTAR N, MIAN A. Seggcn: Efficient 3d point cloud segmentation with fuzzy spherical kernel [C] //Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2020: 11611–11620.
- [32] THOMAS H, QI C R, DESCHAUD J E. Kpconv: Flexible and deformable convolution for point clouds [C] //Proceedings of the IEEE/CVF International Conference on Computer Vision, 2019: 6411–6420.
- [33] HU Q, YANG B, XIE L. Randla-net: Efficient semantic segmentation of large-scale point clouds [C] //Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2020: 11108–11117.
- [34] CHEN J, KAKILLIOGLU B, VELIPASALAR S. Background-aware 3-D point cloud segmentation with dynamic point feature aggregation [J]. IEEE Transactions on Geoscience and Remote Sensing, 2022, 60: 1–12.
- [35] ZHAO L, TAO W. JSNet++: Dynamic filters and pointwise correlation for 3D point cloud instance and semantic segmentation [J]. IEEE Transactions on Circuits and Systems for Video Technology, 2022, 33 (4): 1854–1867.