

基于片序列注意力的颅内动脉瘤点云分割^①

李 硕, 郭莉琳

(浙江中医药大学 医学技术与信息工程学院 信息系, 杭州 310053)

通信作者: 郭莉琳, E-mail: lilinguo@zcmu.edu.cn



摘 要: 颅内动脉瘤是脑血管的病理性扩张, 一旦破裂致死率极高. 人工检测颅内动脉瘤繁琐耗时, 因此有必要引入自动化检测技术. 为解决现存算法在处理点云数据时空间利用率低, 难以同时捕捉局部细节与整体结构的问题, 设计基于片序列注意力的颅内动脉瘤点云分割算法. 利用空间填充曲线将点云序列化, 改善了传统点云在提取局部结构信息时的效果. 提出更加精细化的片注意力, 利用片分组和片交互, 进一步加强模型对不同空间关系的泛化能力. 同时设计网格池化操作, 解决了传统算法对于信息密度和重叠不可控的问题. 该方法在 IntrA 数据集上获得了健康血管段 IoU 为 95.37%、动脉瘤段 IoU 为 84.67% 的分割精度, 远优于大多数现存算法.

关键词: 颅内动脉瘤; 医学图像处理; 3D 点云; 语义分割; 序列化; 深度学习; 片注意力

引用格式: 李硕, 郭莉琳. 基于片序列注意力的颅内动脉瘤点云分割. 计算机系统应用, 2025, 34(7): 163-173. <http://www.c-s-a.org.cn/1003-3254/9885.html>

Point Cloud Segmentation of Intracranial Aneurysms Based on Patch Serialized Attention

LI Shuo, GUO Li-Lin

(Department of Information, School of Medical Technology and information Engineering, Zhejiang Chinese Medical University, Hangzhou 310053, China)

Abstract: Intracranial aneurysms refer to the pathological expansion of blood vessels in the brain. Once an aneurysm ruptures, the fatality rate is extremely high. Manual detection of intracranial aneurysms is cumbersome and time-consuming, making the introduction of automated detection technology necessary. To address the insufficient space utilization of three-dimensional (3D) point cloud data by existing algorithms and the difficulty in fully capturing both local details and overall structural information, a segmentation algorithm based on patch serialization attention for intracranial aneurysm point clouds is designed. Space-filling curves are used to serialize point clouds, which improves the effectiveness of traditional point clouds in extracting relationships between different local structures. A more refined patch attention mechanism is introduced, with patch grouping and patch interaction, to strengthen the model's ability to generalize spatial relationships. The issues related to uncontrollable information density and overlap in traditional pooling methods are resolved through graph pooling operations. On the IntrA dataset, the segmentation accuracy achieved is 95.37% IoU for healthy blood vessels and 84.67% IoU for aneurysm segments, significantly outperforming most existing algorithms.

Key words: intracranial aneurysm; medical image processing; 3D point cloud; semantic segmentation; serialization; deep learning; patch attention

① 基金项目: 浙江中医药大学校级科研项目 (781100E036)

收稿时间: 2024-11-21; 修改时间: 2024-12-09, 2025-01-07; 采用时间: 2025-01-21; csa 在线出版时间: 2025-05-27

CNKI 网络首发时间: 2025-05-28

颅内动脉瘤是一种以局部血管扩张为特征的脑血管疾病^[1]。颅内动脉瘤一旦破裂,会导致蛛网膜下腔出血,病死率极高,对患者的生命安全危害极大^[2]。目前主要的治疗方法是对动脉瘤颈部夹闭以防止瘤体破裂。但是人工检验颅内动脉瘤需要高度专业化的医生手动审查复杂的影像数据,这不仅耗时耗力,还可能因人而异导致诊断结果不一致。深度学习模型可以在短时间内高效处理大量的数据,这对于传统的手工分析来说几乎不可能实现。现有研究主要集中于处理规则像素的2D图像数据^[3-6]而不是3D点云数据。随着Intra^[7]发布了一个包含动脉瘤段和健康血管段的颅内动脉瘤点云数据集,才使得通过点云数据来解决颅内动脉瘤的分割成为可能。

然而,现有的基于点云的深度学习算法存在分割效果不佳的问题。PointNet^[8]对点云的全局特征提取有较好的效果,但是忽略了点之间的几何关系,限制了局部特征的提取。大部分算法^[9-11]在处理颅内动脉瘤点云数据时,都选择直接采用3D点云数据作为模型输入,

但是点云数据的非结构化特性给后续模型处理带来了极大挑战。Yu等^[12]考虑了复杂的生物学结构,但由于点云丰富的几何特性,最终使得模型在区分血管与动脉瘤边缘方面表现欠佳。Liu等^[13]采用了堆叠块、图卷积等方法,致力于优化语义流和分割流进而产生更清晰的边缘特征,纠正了混淆特征,与一般算法相比取得了显著性能提升。

综上,本文受到PTV3^[14]的启发,进一步认识到结构化点云特征对于点云处理的重要性,并由此设计了基于片序列注意力的颅内动脉瘤点云分割算法。

1 算法详情

用于颅内动脉瘤3D点云数据分割的整体模型框架如图1所示,在直接处理非结构化点云数据时,模型很难同时有效地捕捉整体空间结构与局部细节。所以我们利用空间填充曲线^[15]和序列化操作实现了原始点云数据由非结构化到结构化的转换,探索了点云数据的序列化特征潜力。

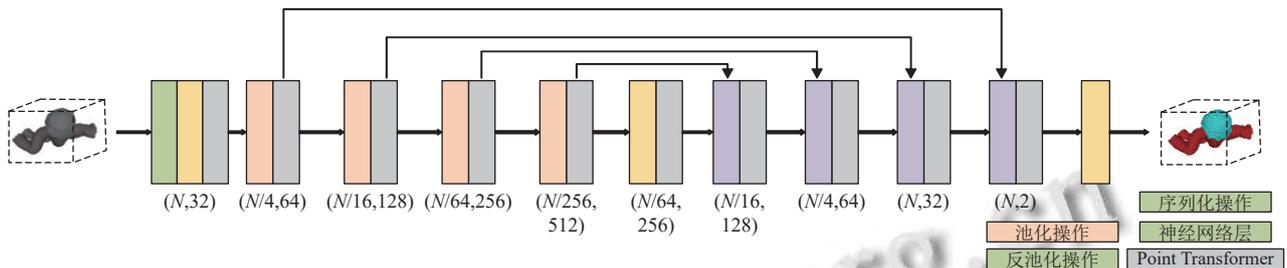


图1 基于片序列注意力的颅内动脉瘤点云分割模型

为了准确提取和理解医学点云数据中的关键特征,特别是局部细节和多尺度信息,需要专门设计能够适应不规则空间结构的技术,确保模型不仅能处理数据的随机性,还能保持对几何变换的鲁棒性。医学点云数据具有不规则的空间分布和复杂的几何特性,传统U-Net方法难以有效捕捉其内在信息。本模型架构与U-Net基本框架一致,都是由编码器和解码器组成,但此基础上又利用了基于分区的网格池化操作,对点云数据空间进行有组织的划分,确保了每个区域内部及区域间的特征一致性,提高了模型对点云数据的空间感知能力。受益于窗口^[16]和点积注意力^[17,18]机制,定义片序列注意力,实现了更高性能的瘤体分割。

不可否认的是本模型为了学习捕获的精细细节,使用了更多的参数。在一定程度上增加了操作难度,但

是实验部分证明了模型性能在分割分类以及泛化性上都得到了大幅的提升。我们的模型能够更精确地解析医学点云数据,提升诊断准确性,从而为医学诊断和分析提供可靠的支持。对于早期发现和精确诊断颅内动脉瘤提供了更加精确和可靠的工具,

1.1 点云序列化

在数据预处理阶段,根据不同类别的空间填充曲线,将3D空间中的点云转换为有序的一维序列,并据此实现将原本非结构化的点云数据转换为结构化的格式。

1.1.1 空间填充曲线

空间索引是指依据空间实体的位置和形状或不同实体之间的空间关系,按一定顺序排列起来的一种数据结构,其中一种形式即是空间填充曲线。从数学的角度上看,空间填充曲线是一种双射函数:

$$f: z \rightarrow z^n$$

其中, n 是空间的维度, 表示将一个一维的区间映射到 n 维空间中, 同时满足遍历该 n 维空间中的所有点.

本文选取了两条具有代表性的空间填充曲线: Z阶曲线^[19]和希尔伯特曲线^[20]. Z阶曲线(图2(a))能够确保相邻的空间点映射到一维空间后仍保持相对接近, 并维持了原有的空间关系, 使得模型有效地捕获3D点云数据中的细微结构. 而希尔伯特曲线(图2(b))在递归过程中提供了更好的连续性, 从而提供了更好的局部保持特性. 为了更有效地提取和利用点云数据的细节信息, 我们通过改变原始空间填充曲线遍历的顺序, 在 x 轴之前优先考虑 y 轴, 引入了标准空间填充曲线的重新排序变体. 从而产生图3显示的 super Hilbert 新呈现方式.

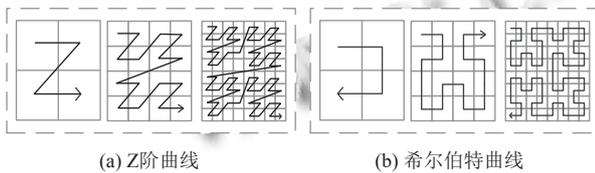


图2 两种空间填充曲线(2D)

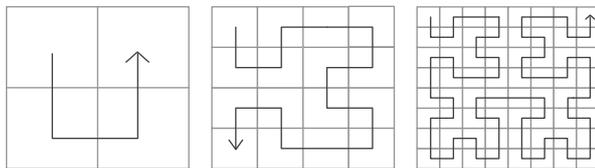


图3 1阶、2阶、3阶 super Hilbert 示意图(2D)

算法根据3D点云数据的空间特性, 使用三维模型的空间填充曲线. 尽管示例是在二维空间中给出的, 但空间填充曲线的基本原理和概念在二维和三维空间中都是适用的, 因此选用二维例子作为解释三维空间填充曲线的基础.

用三元组可视化来展示序列化的3种模式. 对于 super Hilbert 三元组, 展示了用于序列化的空间填充曲线(图4(a))、空间填充曲线内的点云序列化可变排序顺序(图4(b))以及用于注意力的序列化片(图4(c)).

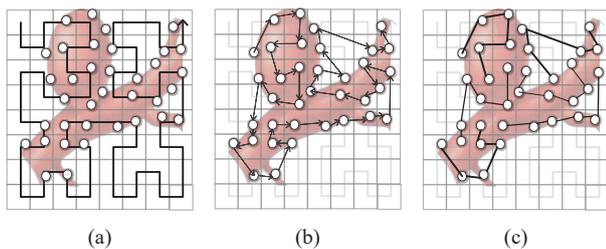


图4 颅内动脉瘤2D点云序列化示意图

1.1.2 序列化编码

空间填充曲线具有良好的局部保持特性, 为了利用精细的局部特征信息, 我们选择采用序列化编码, 将点的位置转换成一个整数, 这个整数代表了该点按照空间填充曲线遍历的顺序. 使得模型能够更好地捕捉局部细节和结构信息.

由于空间填充曲线的双射性质, 存在一个反向映射函数:

$$f^{-1}: z^n \rightarrow z$$

将点的位置 $p_i \in \mathbb{R}^3$ 投影到网格大小 $g \in \mathbb{R}$ 的离散空间后转换为序列化一维编码.

为点云数据集中每个点 p 分配一个64位整数 P 作为其序列化编码, 代表点 p 在曲线上的位置, 如下式:

$$P = f^{-1}\left(\left\lfloor \frac{P}{g} \right\rfloor\right) \quad (1)$$

具体来说, 首先将点 p 的位置离散化到一个网格中, 然后利用空间填充曲线的反向映射函数计算离散化点在曲线上的位置, 最终得到整数值 P .

序列化编码设计如图5, 前 k 位来表示空间填充曲线上的位置信息, 剩下的 $64-k$ 位表示批次索引 b . 将批次索引 b 左移位, 即将 b 的二进制表示放置在64位整数的最前面, 最后通过按位或运算将两个值合并成一个64位整数. 实现把批次索引放在高位, 空间填充曲线的位置编码放在低位. 整个过程如式(2):

$$Encode(p, b, g) = (b \ll k) | f^{-1}\left(\left\lfloor \frac{P}{g} \right\rfloor\right) \quad (2)$$

其中, \ll 表示左移位, $|$ 表示按位或.

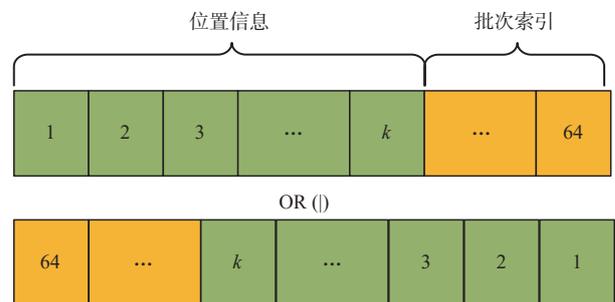


图5 序列化编码示意图

这个编码方案能够有效地将点云数据组织起来, 并且保留了点之间的局部性. 此外, 通过批次索引, 可以更方便地处理多个批次的数据, 使得数据管理和检索更高效.

1.2 片注意力

Vision Transformer 之所以能够从图像的像素级信息中学习, 得益于图像数据的规则网格结构, 可以有效地使用窗口或者点积注意力机制来捕捉局部特征. 本文基于窗口和点积注意力的启发, 定义了片注意力, 将点云数据分组到不重叠的片中, 并在每个单独的片中执行注意力. 片注意力的有效性依赖于两个主要设计: 片分组和片交互.

自注意力机制^[21]是通过计算序列中每个元素与其他所有元素之间的关系来工作的. 在此基础上, 我们设计了片注意力机制, 旨在捕捉每个点与其邻域内其他点之间的相互作用, 可以用式 (3) 表示. 具体而言, 对于每个点 x_i 及其序列化领域中的各点 x_j , 使用减法关系来计算它们之间的特征差异, 以此捕捉 x_i 与其邻域内其他点之间的相互作用. 随后, 将差值输入到映射函数 η 中, 该函数输出一个注意力向量, 表示 x_i 和 x_j 之间的相对重要性或关联度. 为了保留点的位置信息, 我们在注意力向量和转换后的特征中都添加了位置编码 P . 生成的注意力向量接着通过标准化函数 ε 进行处理, 确保所有注意力权重之和为 1, 从而保证不同点的重要性能够公平比较. 标准化后的注意力权重同样增加了位置编码的转换特征进行加权. 最后, 这些加权特征相加得到新特征 y_i , 代表了中心点 x_i 在其邻域内的综合特征. 公式表示如下:

$$y_i = \sum_{x_j \in X(i)} \varepsilon(\eta(\varphi(x_i) - \phi(x_j) + P)) \odot (\alpha(x_j) + P) \quad (3)$$

其中, \odot 表示逐元素乘法, 将权重与特征相乘, x_i 代表一组点云数据特征向量, y_i 是输出特征向量, φ 、 ϕ 、 α 是线性层, 分别进行特征变换. P 是位置编码. 映射函数 η 是一个具有两个线性层和一个 ReLU 非线性的 MLP. 对片注意力的解释和步骤如图 6 所示.

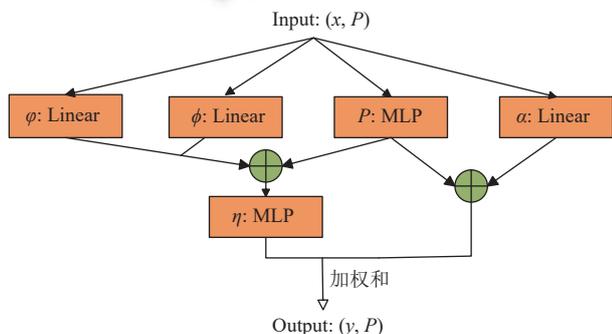


图 6 片注意力层计算流程图

这种机制允许片注意力捕捉点云数据中点与点之间的复杂关系, 同时保留了它们的位置信息, 帮助模型更好地聚焦于重要的局部特征.

相邻的点通常会共享相似的属性, 一旦点云数据被序列化, 接下来将它们分组为片, 确保每个片内的点在空间上是相对接近的, 更好的捕捉点云数据的局部特征. 与此同时, 如果不采用分片处理而是直接将序列化的点云数据输入到模型中, 不仅会导致计算资源和内存需求过大, 还会使模型难以充分关注每个区域的局部细节, 从而影响有效局部特征捕捉的效果. 通过分片处理操作, 我们可以显著降低计算成本, 并且在更小的区域内集中处理, 进而提升对局部细节的关注度和几何特征的捕获能力. 图 7 对片分组机制进行了展示.

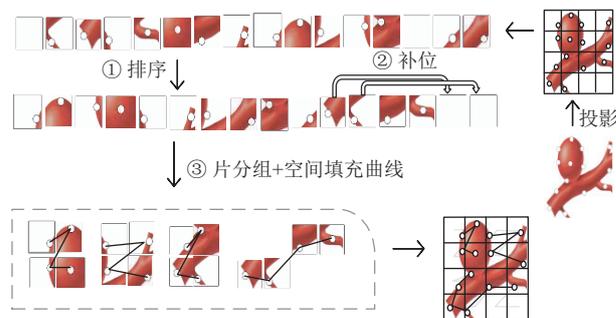


图 7 片分组机制过程图

① 重新排序

按照一种特定模式来重新排序序列化点云数据中的点, 确保后续处理步骤更加有序, 更好地捕捉点之间的空间关系. 这种有序的排列有助于模型更轻松地识别点云中的模式, 从而更高效地理解数据中的局部和全局特征.

② 片补位

将点云分割成片之前, 对空缺的点云序列进行填充: 某些片因为边界条件而缺少足够的点, 可以从最临近的片中“复制”一些点进行补位, 以此填充空缺的位置. 确保了每个片都具有相同数量的点, 从而保持片之间的空间一致性, 具体过程详见图 7.

③ 片分组

每个片包含了一定数量的连续点, 这些片将用于注意力机制, 使模型可以集中处理每个片内的信息, 更好地捕获局部特征和上下文信息. 序列化片的示意图见图 4(c). 这种分组策略与我们的序列化模式相结合,

旨在有效地扩大注意力机制在 3D 空间中的有效范围,更好地捕捉和利用序列化点云数据中的空间领域关系。

不同的空间填充曲线的序列化模式会带来不同的局部邻域关系,切换序列化模式可以让注意力机制学习到更多样化的空间特征.这对于处理复杂的 3D 颅内动脉瘤点云数据特别有用,它可以帮助模型理解不同角度和细节,捕获到更多的空间关系和上下文信息,从而提高下游分割实验性能。

④ 随机片交互

随机片交互示意图如图 8 所示.具体而言,在每一批次数据处理时,为每个点云数据随机选用一种空间填充曲线进行序列化和分片.不断转换点云数据的序列化顺序,减少模型对某一特定序列化模式的过度依赖,避免过拟合的产生.每次随机使用空间填充曲线,导致输入到各个注意力模块的信息也相应变化,有利于更好地捕捉局部细节与全局结构特征,促进模型在不同注意力模块间实现更加灵活多样的特征融合,增强泛化性。

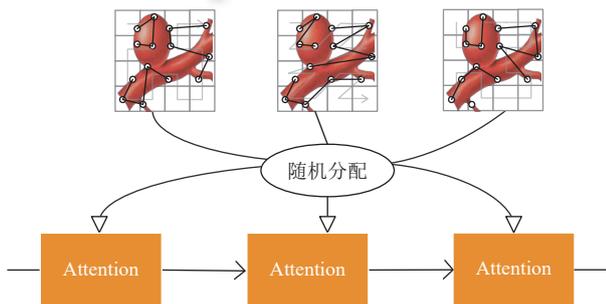


图 8 随机片交互机制示意图

这种方法确保了每个注意力层接受的局部结构特征各不相同,不仅有助于帮助模型更好地理解局部细节与全局结构之间的关联,而且增加了模型的鲁棒性和泛化能力。

1.3 基于分区的网格池化

在传统的基于点云的算法中,往往会选择最远点采样或随机采样等方法,选定一些代表性的点.对于选中的每个点,通过查询其临近点来聚合信息,实现对点云数据的有效简化和特征提取.然而这些方法的问题在于,每个查询集都是独立生成的,且每次查询时临近点间的信息密度和重叠程度都是不可控的.因此在空间上,点的查询集并没有对齐,从而导致最终得到的特征表征不够一致,这会削弱模型捕捉局部特性的能力。

为了解决这个问题,我们提出了一种更有效的基于分区的网格池化方法,如图 9 所示。

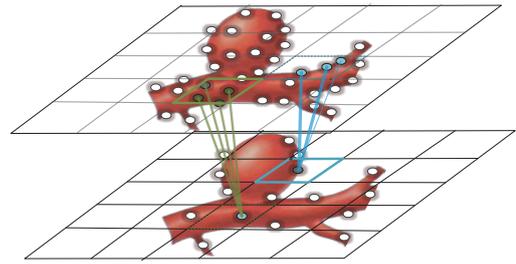


图 9 基于分区的网格池化示意图

1.3.1 池化操作

给定一个点集 $M=(P, F)$, 其中 P 是所有点云的位置坐标集合, F 是所有点对应的特征集合。

将 M 划分为多个不重复子集 $[M_1, M_2, M_3, \dots, M_n]$, 即将空间划分为不重叠的区域, 每个分区内的点构成了一个子集 M_i . 每个子集 $M_i=(P_i, F_i)$ 包含一组点的位置 P_i 和对应的特征 F_i 。

对单个分区的每个点子集 $M_i=(P_i, F_i)$ 的操作如下。

首先, 对于点子集中的每个点的特征 f_j , 通过线性投影 $U \in R^{c \times c}$ 映射到一个新的特征空间, 使用最大池化操作来聚合这些映射后的特征. 公式如下:

$$f'_i = \text{MaxPool}(\{f_j U \mid f_j \in F_j\}) \quad (4)$$

然后, 对于 M_i 中的每个点的位置 p_j , 使用均值池化操作来计算所有点位置的平均值. 公式如下:

$$p'_i = \text{MeanPool}(\{p_j \mid p_j \in P_i\}) \quad (5)$$

最后, 从 n 个子集收集池化点, 形成新的点集 $M_0 = \{p'_i, f'_i\}_{i=1}^n$ 。

1.3.2 反池化操作

在池化过程中, 原始点集 M 中每个点的位置 p_i 都会被记录下来. 对于 M 中的每个点 (p_i, f_i) , 如果 $(p_i, f_i) \in M_j$ 则将 M_0 中对应子集的特征映射给该点. 通过将 M_0 中的特征映射回 M 相应的点上, 完成了将经过池化处理的点云数据恢复到原始点集的规模, 处理和重建了原始数据。

总的来说, 基于分区的网格池化操作能够提取出更具有代表性的高层的抽象特征, 同时通过减少特征图的尺寸, 减少了模型参数的数量, 从而降低过拟合的风险. 使用非池化的方法来保留丰富的底层细节特征, 对于提高模型在测试数据上的表现非常重要。

2 实验分析

对比其他算法, 分别基于 IntrA 数据集、ShapeNet

数据集和 ModelNet 数据集做了不同层次与方面的模型性能测试. 实验环境是 NVIDIA RTX A5000, 显存总量为 24 GB. CPU 频率为 2900 MHz, 总内存为 62 GiB, 搭建有 Python 3.10.12, Ubuntu 22.04.4, PyTorch 2.4.0 和 CUDA 12.6.

在训练阶段, 我们设置批大小为 8, 配置了 4 个线程进行并行处理. 为确保公平比较, 所有方法和模式均在这个环境下接受训练和测试. 根据数据集的特性, 模型输入设计为包含 6 个通道, 每个通道代表不同的特征信息. 在训练过程中使用了 Adam 优化器^[21], 学习率设定为 0.005. 对于损失函数, 我们采用了交叉熵损失^[22]和洛瓦兹损失函数^[23]相结合的策略. 从而全面提升模型的分割性能.

交叉熵损失函数是机器学习和深度学习中经典损失函数, 用于衡量模型预测的概率分布与真实标签之间的差异. 损失越低, 表示模型的预测结果越接近真实的标签. 交叉熵损失函数相关计算公式如下:

$$l_{ce} = -[y(\log(\hat{y}) + (1 - y)\log(1 - \hat{y}))] \quad (6)$$

其中, y 为样本的真实标签 ($y \in \{0, 1\}$), \hat{y} 是模型输出的预测概率 ($0 \leq \hat{y} \leq 1$).

洛瓦兹损失函数的核心思想是直接最小化预测值与真实标签之间的平均交并比, 训练模型时可以直接改善最终的分割质量.

2.1 实验数据集

IntrA: 专门为深度学习设计的 3D 颅内动脉瘤点云数据集. IntrA 数据集通过重构患者的二维磁共振血管造影图像, 生成了三维的颅内动脉瘤模型. 数据集包括 1909 段血管模型, 116 个用于分割任务的注释实例, 区分了健康血管部分 (标记为 0) 和动脉瘤部分 (标记为 1). IntrA 数据集为面向颅内动脉瘤的深度学习模型训练提供了精准的数据资源, 已成为深度学习方法在颅内动脉瘤诊断、治疗研究和发展的基准数据集之一. 官方发布的数据集可以在这里访问: <https://github.com/intra3d2019/IntraA>.

ShapeNet^[24]: 大规模、多类别的三维模型数据库, 广泛应用于三维形状理解和分析. ShapeNet 数据集由 16 个类别和 50 类零件分割标注组成. 原始数据集包括 14006 个用于训练的实例和 2874 个用于测试的实例. 其包含丰富的类别和大量的标注数据. ShapeNet 数据集已成为深度学习方法在三维场景中研究和发展的基

准数据集之一.

ModelNet^[25]: 广泛使用的三维形状数据集, 主要用于三维物体识别和分类任务. 该数据集由 13 211 个通用对象的 3D 合成模型组成, 其中包含 9 843 个训练样本和 2 468 个测试样本, 包括 40 个日常生活中常见的物体类型, 如: 椅子、桌子等. ModelNet 数据集属于三维形状识别领域的一个重要基准, 被用于评估各种三维物体识别和分类算法的性能.

2.2 IntrA 数据集结果

2.2.1 颅内动脉瘤分割对比实验

从平均交并数 (IoU) 和骰子相似系数 (DSC) 两个传统指标来度量分割效果. IoU 是每一类预测结果和真实值的交集与并集的比值, DSC 指标用来衡量预测结果与真实值之间的相似度. 相关计算公式如下:

$$IoU = \frac{\sum_{b=0}^{a-1} t_{bb}}{\sum_{b=0}^{a-1} t_{bd} + \sum_{b=0}^{a-1} (t_{db} + t_{bb})} \quad (7)$$

$$DSC = \frac{\sum_{b=0}^{a-1} 2 \times t_{bb}}{2 \times \sum_{b=0}^{a-1} t_{bd} + \sum_{b=0}^{a-1} (t_{db} + t_{bb})} \quad (8)$$

其中, a 为类别数, b 为真实类别, d 为预测类别, t_{bb} 为类别预测正确的点的数量, t_{bd} 为假负的数量, t_{db} 为假正的数量.

本文将所提出的分割算法与传统的点云分割算法进行了详细的对比分析, 结果如表 1 所示. 从表 1 中可以看出, 对于具有 1 024 个输入点的模型分割任务, 我们的模型在动脉瘤段实现了较高的 IoU 和 DSC 值, 分别是 84.67% 和 91.68%.

值得一提的是, 相比以往的分割模型, 我们的模型在动脉瘤段的准确率高达 91.68%, 这一结果远超过了现有模型的分割性能, 显示出我们在处理颅内动脉瘤点云数据时的显著优势.

2.2.2 颅内动脉瘤分类对比实验

在基于 IntrA 数据集的颅内动脉瘤分类任务上, 我们使用了 3 个指标来评估模型性能: ① **V.acc**: 测量正确预测的健康血管样本占有所有健康血管样本的百分比. ② **A.acc**: 正确预测的动脉瘤血管样本占有所有动脉瘤血管样本的百分比. ③ **F1 评分**: 精确率和召回率的谐波平均值, 并用来评估模型的质量.

表1 具有所有输入特征的健康血管段(V.)和动脉瘤段(A.)的每类模型的分割结果

数据模型	点云数目	IoU (%)		DSC (%)	
		V.	A.	V.	A.
SpiderCNN ^[26]	512	90.16	67.25	94.53	75.82
	1024	87.95	61.60	93.24	71.08
	2048	87.02	58.32	92.17	67.74
SO-Net ^[27]	512	94.22	80.14	96.95	87.9
	1024	94.42	80.99	97.06	88.41
	2048	94.46	81.40	97.09	88.76
PointCNN ^[28]	512	95.1	82.11	95.97	78.55
	1024	94.42	80.99	96.53	81.74
	2048	94.46	81.4	96.62	81.36
PointNet++ ^[29]	512	93.35	76.38	96.48	83.92
	1024	93.35	76.38	96.47	84.62
	2048	93.24	76.21	96.40	84.64
PointNet ^[8]	512	93.42	76.22	84.05	48.96
	1024	95.54	83.97	85.00	48.38
	2048	95.43	83.22	84.17	49.59
PointConv ^[30]	512	94.16	79.09	96.89	86.01
	1024	94.59	79.42	97.15	86.29
	2048	94.65	79.53	97.18	86.52
AdaptConv ^[31]	512	90.45	70.25	96.01	80.60
	1024	90.69	75.26	94.92	84.40
	2048	90.97	75.05	95.05	84.72
PACov ^[32]	512	91.97	78.66	95.66	87.57
	1024	90.34	74.31	94.54	83.16
	2048	92.2	70.59	95.81	79.18
PMMNet ^[9]	512	93.89	78.15	96.77	86.04
	1024	93.74	77.48	96.71	85.68
	2048	94.24	78.57	96.99	86.50
3DMedPT ^[33]	512	94.82	81.8	97.29	89.25
	1024	94.76	82.39	97.25	89.71
	2048	93.52	80.13	96.59	88.69
PCT ^[34]	512	92.49	78.09	96.08	85.84
	1024	92.05	78.12	95.85	86.77
	2048	91.66	77.10	95.43	86.02
N-PointNet ^[10]	512	94.58	78.45	97.20	85.32
	1024	94.69	78.43	97.22	85.30
	2048	94.67	78.49	97.21	85.48
Ours	512	94.78	82.48	97.32	90.37
	1024	95.37	84.67	97.63	91.68
	2048	94.17	82.01	96.99	90.07

如表2所示,本文模型表现出卓越的性能,尤其在颅内动脉瘤由1024个点组成的点云数据集上,模型的V.acc高达98.64%,而F1值达0.9463,这些指标远远超过绝大多数现有模型,展现了所提方法在Intra数据集分类任务上的显著优势。值得一提的是,该模型不仅在训练数据上展现出优异的拟合能力,更重要的是,模型还具备很好的泛化能力。这意味着模型不仅能够训练过程中很好的学到Intra数据集的内在规律,还能够在面对全新的、未曾见过的颅内动脉瘤数据时给出可靠的预测。这一点在测量值A.acc上表现尤为突出。

色,本模型的A.acc高达94.85%,显著超过了目前现有的大多数模型。

表2 基于Intra数据集的颅内动脉瘤分类结果

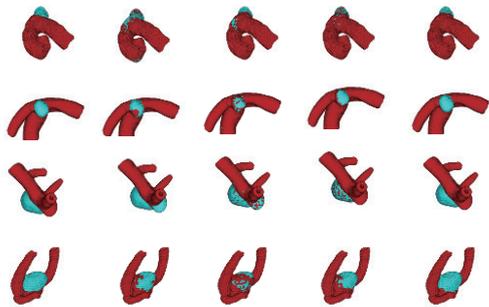
数据模型	点云数目	V.acc (%)	A.acc (%)	F1
SpiderCNN ^[26]	512	98.05	84.58	0.8692
	1024	97.28	87.90	0.8722
	2048	97.82	84.89	0.8662
SO-Net ^[27]	512	98.76	84.24	0.8840
	1024	98.88	81.21	0.8684
	2048	98.88	83.94	0.8850
PointCNN ^[28]	512	98.38	78.25	0.8494
	1024	98.79	81.28	0.8748
	2048	98.95	85.81	0.9044
DGCNN ^[35]	512	95.22	60.73	0.6578
	1024	95.34	72.21	0.7376
	2048	97.93	83.40	0.8594
PointNet++ ^[29]	512	98.52	86.69	0.8928
	1024	98.52	88.51	0.9029
	2048	98.76	87.31	0.9016
PointNet ^[8]	512	94.45	67.66	0.6909
	1024	94.98	64.96	0.6835
	2048	93.74	69.50	0.6916
AdaptConv ^[31]	512	98.53	89.00	0.9040
	1024	98.98	89.71	0.9060
	2048	98.19	85.74	0.8820
PACov ^[32]	512	97.58	79.99	0.8090
	1024	99.05	82.90	0.8580
	2048	97.87	75.94	0.7990
PMMNet ^[9]	512	99.20	91.91	0.9440
	1024	99.63	94.32	0.9630
	2048	99.56	90.75	0.9420
3DMedPT ^[33]	512	99.02	94.06	0.9200
	1024	99.24	93.26	0.9360
	2048	99.07	93.49	0.9310
PCT ^[34]	512	99.03	89.07	0.9110
	1024	98.87	89.71	0.9140
	2048	98.96	89.49	0.9170
FoldingNet ^[36]	512	91.37	77.41	0.6159
	1024	91.83	78.28	0.6240
	2048	91.64	79.54	0.6316
Dual-brunch ^[11]	512	96.74	82.35	0.8296
	1024	97.45	84.28	0.8613
	2048	95.41	89.47	0.8226
N-PointNet ^[10]	512	98.53	92.15	0.9260
	1024	98.48	92.02	0.9210
	2048	98.53	92.13	0.9250
GS-Net ^[37]	512	98.55	83.84	0.8730
	1024	98.78	83.08	0.8720
	2048	98.39	85.74	0.8820
Ours	512	98.41	91.22	0.9422
	1024	98.64	94.85	0.9463
	2048	98.58	93.34	0.9455

这一对比结果表明,本文模型不仅能在训练阶段有效捕获颅内动脉瘤点云数据的特征,还能在面对实

际临床应用场景时提供稳定且精准的分类分割性能。

2.2.3 可视化结果分析

为了直观地评估所提方法的有效性,我们将其分割结果与 IntraA 数据集上的几种领先方法进行了比较,可视化结果如图 10 显示。



(a) GT (b) PMMNet (c) PointNet (d) 3DMedPT (e) Ours

图 10 基于 IntraA 数据集的可视化结果

如图 9 所示,图 9(a) 显示了由医学专家精心分割的真实值 (GT) 标签,而 (b)–(e) 分别展示了 PMMNet、PointNet、3DMedPT 和本模型的分割结果。通过对不同方法的分割效果进行详细的对比分析,清楚地展现出本文方法在处理颅内动脉瘤点云数据时的优势。很明显,PointNet 和 PMMNet 的分割性能较差,适应不同瘤体的能力较弱。3DMedPT 表现出一些改善,但在健康血管和动脉瘤之间的交叉部分仍然存在明显的错误分类,且因在采样阶段能力不足而出现部分所属瘤体的点未能分割正确的情况。因此,我们所提出的基于片序列注意力的颅内动脉瘤点云分割算法能够学习更全面的特征信息,从而获得与基本事实非常相似的分割结果。

2.2.4 模型复杂度

如表 3 所示,使用 params (参数量) 和每秒浮点运算次数 (floating point operations per second, FLOPs) 作为衡量模型复杂度的标准。结果表明,本模型包含 4.61M 模型参数, FLOPs 为 1.73G。

表 3 模型复杂度

数据模型	Params (M)	FLOPs (G)
Ours	4.61	1.73
DGCNN ^[35]	1.82	2.43
PointNet++ ^[29]	1.75	1.70
PointNet ^[8]	3.50	0.45

不可否认的是本模型在处理颅内动脉瘤点云数据时,通过更精细地捕捉局部特征和全局特征,来保证更

高的性能。而这也意味着需要更多的参数来学习捕获到的细节。从对比结果可以看出,与一些传统的轻量级方法相比,我们的方法确实具有更多的参数。对于该挑战,后续我们也将继续探索,实现在捕捉精细特征的同时使得模型更简单轻便。

2.3 其他数据集上的结果

2.3.1 ModelNet 数据集分类结果

如表 4 所示,对于 ModelNet 数据集的分类,我们的准确率达到 93.52%。这一结果清晰的反映了本模型在不同类别物体上的分类性能,展示了其在复杂三维数据上的强大泛化能力和鲁棒性。

表 4 基于 ModelNet 数据集的准确率结果 (%)

数据模型	V.acc
PointNet++ ^[29]	93.17
G3DNet-18 SVM ^[38]	93.10
PolyNet ^[39]	94.93
MVCNN ^[40]	92.51
SO-Net ^[41]	95.50
PMMNet ^[9]	96.59
Ours	93.52

2.3.2 ShapeNet 数据集分割结果

为更加全面地反映本模型的综合性能,我们将本算法与具有代表性的深度学习方法在 ShapeNet 数据集上进行指标对比,结果如表 5 所示。本文模型在类级分割中显示出卓越性能,尤其在车、笔记本电脑、摩托车、马克杯和火箭几个类别的分割中表现尤为出色,相比其他模型,获得了显著的性能提升。

2.3.3 ShapeNet 数据集结果可视化

图 11 对模型在 ShapeNet 数据集上的零件分割结果进行了展示。可以看出对分割中的任意点云数据均具有高鲁棒性,在面对复杂集合形状和变化多端的点云分割时,仍然能够保持稳定分割性能。进一步证明,无论是在物体的各个部分还是在点云密度变化较大的区域,本模型均能精准地识别并分离出各组成部分。实验证明本模型能够有效地识别并准确地勾勒出目标物体的轮廓,具有广泛的适用性和较高的准确性。

2.4 消融实验

片的规模对于模型性能会产生显著影响,因此我们在不同片数量的情况下做了消融实验。

如表 6 所示,实验结果表明,随着片数量的增长,各项性能指标均有不同程度的提升。由此可见,合理的

分片数量不仅可以帮助模型更好地拟合数据,还能增强其在处理复杂三维结构时的鲁棒性和泛化能力. 因此在未来的模型迭代中,设计片的大小以优化模型性

能将成为一个重要的考量因素,这不仅有助于提高模型的精度,还有助于在实际应用中实现更可靠的三维数据处理性能.

表5 基于 ShapeNet 数据集的 IoU 分割结果 (%)

模型	cls.mIoU	Airplane	Bag	Car	Chair	Earphone	Guitar	Knife	Lamp	Laptop	Motorbike	Mug	Pistol	Rocket	Skateboard	Table
PointNet ^[8]	80.4	83.4	78.7	74.9	89.6	73.0	91.5	85.9	80.8	95.3	65.2	93.0	81.2	57.9	72.8	80.6
PointNet++ ^[29]	81.9	82.4	79.0	77.3	90.8	71.8	91.0	85.9	83.7	95.3	71.6	94.1	81.3	58.7	76.4	82.6
PointCNN ^[28]	84.6	84.1	86.5	80.8	90.6	79.7	92.3	88.4	85.3	96.1	77.2	95.2	84.2	64.2	80.0	83.0
DGCNN ^[35]	82.3	84.0	83.4	77.8	90.6	74.7	91.2	87.5	82.8	95.7	70.8	94.6	81.1	63.5	74.5	82.6
KPConv ^[42]	85.0	83.8	86.1	81.6	91.0	80.1	92.1	87.8	82.2	96.2	77.9	95.7	86.8	65.3	81.7	83.6
PACConv ^[32]	84.6	84.3	85.0	79.7	90.6	80.8	92.0	88.7	82.2	95.9	73.9	94.7	84.7	65.9	81.4	84.0
AdaptConv ^[31]	83.4	84.8	81.2	79.7	91.2	80.9	91.9	88.6	84.8	96.2	70.7	94.9	82.3	61.0	75.9	84.2
3DMedPT ^[33]	84.3	81.2	86.0	79.6	90.1	81.2	91.9	88.5	84.8	96.0	72.3	95.8	83.2	64.6	78.2	83.8
PCT ^[34]	83.1	85.0	82.4	81.2	91.9	71.5	91.3	88.1	86.3	95.8	64.6	95.8	83.6	62.2	77.6	83.7
Ours	84.7	82.5	83.2	82.9	90.2	76.9	91.8	88.2	83.1	96.5	78.8	96.5	86.3	68.2	77.0	82.9

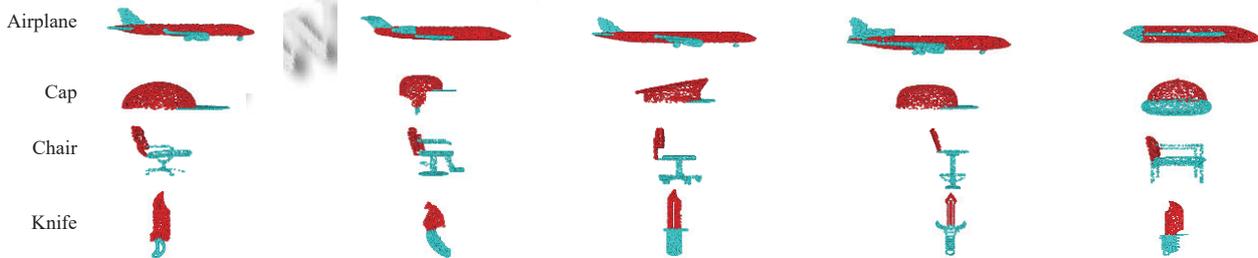


图11 ShapeNet 数据集上的零件分割部分结果可视化

表6 有关分片数量的消融实验结果 (%)

分片数量	IoU		DSC	
	V.	A.	V.	A.
8	87.39	58.31	93.27	73.67
16	89.76	66.04	94.60	79.55
32	91.30	70.93	95.45	82.99
64	92.74	72.76	96.23	84.23
128	93.97	77.93	96.89	87.60
256	95.33	82.89	97.61	90.64

3 结束语

本文设计了一种基于片序列注意力机制的模型,解决了现有方法在整合局部与全局信息方面的不足. 实验结果表明,对于健康血管段,模型能够以非常高的精度 (IoU 为 95.37%) 进行分割,在更具挑战性的颅内动脉瘤段,模型实现了 IoU 为 84.64% 的分割精度,在分割精度上超过了大部分现有方法. 实验结果充分展示了所提方法的优势,在处理复杂的颅内动脉瘤点云数据时,无论是健康血管段部分还是动脉瘤段的分割精度都得到显著提升,显示出巨大的临床应用潜力.

参考文献

- 余昕宇, 夏良涛, 魏翔. 颅内动脉瘤与主动脉疾病相关性的研究进展. 中华神经外科杂志, 2020, 36(11): 1186-1188. [doi: 10.3760/cma.j.cn112050-20191014-00440]
- 邓汉顺, 王清华. 颅内动脉瘤的形成原因及破裂因素研究进展. 医学综述, 2018, 25(15): 3018-3022.
- Joo B, Ahn SS, Yoon PH, et al. A deep learning algorithm may automate intracranial aneurysm detection on MR angiography with high diagnostic performance. European Radiology, 2020, 30(11): 5785-5793. [doi: 10.1007/s00330-020-06966-8]
- Nakao T, Hanaoka S, Nomura Y, et al. Deep neural network-based computer-assisted detection of cerebral aneurysms in MR angiography. Journal of Magnetic Resonance Imaging, 2018, 47(4): 948-953. [doi: 10.1002/jmri.25842]
- Lu XQ, Chen HH, Yeung SK, et al. Unsupervised articulated skeleton extraction from point set sequences captured by a single depth camera. Proceedings of the 32nd AAAI Conference on Artificial Intelligence. New Orleans: AAAI, 2018. 7226-7234.
- Ueda D, Yamamoto A, Nishimori M, et al. Deep learning for

- MR angiography: Automated detection of cerebral aneurysms. *Radiology*, 2019, 290(1): 187–194. [doi: [10.1148/radiol.2018180901](https://doi.org/10.1148/radiol.2018180901)]
- 7 Yang X, Xia D, Kin T, *et al.* Intra: 3D intracranial aneurysm dataset for deep learning. Proceedings of the 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Seattle: IEEE, 2020. 2656–2666.
- 8 Qi CR, Su H, Mo K, *et al.* PointNet: Deep learning on point sets for 3D classification and segmentation. Proceedings of the 2017 IEEE Conference on Computer Vision and Pattern Recognition. Honolulu: IEEE, 2017. 652–660.
- 9 Cao FR, Zhang DW, Wei PJ, *et al.* PMMNet: A dual branch fusion network of point cloud and multi-view for intracranial aneurysm classification and segmentation. *IEEE Journal of Biomedical and Health Informatics*, 2024, 29(5): 3137–3147.
- 10 Wang JQ, Liu JT, Xu YZ, *et al.* N-PointNet: A multi-layer embedded deep learning model for 3D intracranial aneurysm classification and segmentation. <https://www.researchsquare.com/article/rs-2760399/v1>, 2023. [doi: [10.21203/rs.3.rs-2760399/v1](https://doi.org/10.21203/rs.3.rs-2760399/v1)]
- 11 Rida-E-Fatima S, Javed A, Banjar A, *et al.* A multi-layer dual attention deep learning model with refined word embeddings for aspect-based sentiment analysis. *IEEE Access*, 2019, 7: 114795–114807. [doi: [10.1109/ACCESS.2019.2927281](https://doi.org/10.1109/ACCESS.2019.2927281)]
- 12 Yu JH, Zhang CY, Wang H, *et al.* 3D medical point Transformer: Introducing convolution to attention networks for medical point cloud analysis. arXiv:2112.04863, 2021.
- 13 Liu YF, Liu J, Yuan YX. Edge-oriented point-cloud Transformer for 3D intracranial aneurysm segmentation. Proceedings of the 25th International Conference on Medical Image Computing and Computer-assisted Intervention. Singapore: Springer, 2022. 97–106.
- 14 Wu XY, Jiang L, Wang PS, *et al.* Point Transformer V3: Simpler, faster, stronger. Proceedings of the 2024 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Seattle: IEEE, 2024. 4840–4851.
- 15 Peano G. Sur une courbe, qui remplit toute une aire plane. *Mathematische Annalen*, 1890, 36(1): 157–160. [doi: [10.1007/BF01199438](https://doi.org/10.1007/BF01199438)]
- 16 Liu Z, Lin YT, Cao Y, *et al.* Swin Transformer: Hierarchical vision Transformer using shifted windows. Proceedings of the 2021 IEEE/CVF International Conference on Computer Vision. Montreal: IEEE, 2021. 10012–10022.
- 17 Dosovitskiy A, Beyer L, Kolesnikov A, *et al.* An image is worth 16x16 words: Transformers for image recognition at scale. Proceedings of the 9th International Conference on Learning Representations. OpenReview.net, 2021.
- 18 Vaswani A, Shazeer N, Parmar N, *et al.* Attention is all you need. Proceedings of the 31st International Conference on Neural Information Processing Systems. Long Beach: Curran Associates Inc., 2017. 6000–6010.
- 19 Morton GM. A Computer Oriented Geodetic Data Base and A New Technique in File Sequencing. Ottawa: IBM Ltd., 1966.
- 20 Hilbert D. Über die stetige Abbildung einer Linie auf ein Flächenstück. In: Band D, ed. *Analysis-Grundlagen der Mathematik-Physik Verschiedenes*. Berlin: Springer, 1935. 1–2.
- 21 Kingma D, Ba J. Adam: A method for stochastic optimization. arXiv:1412.6980, 2014.
- 22 Wang YS, Ma XJ, Chen ZY, *et al.* Symmetric cross entropy for robust learning with noisy labels. Proceedings of the 2019 IEEE/CVF International Conference on Computer Vision. Seoul: IEEE, 2019. 322–330.
- 23 Berman M, Triki AR, Blaschko MB. The lovász-Softmax loss: A tractable surrogate for the optimization of the intersection-over-union measure in neural networks. Proceedings of the 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Salt Lake City: IEEE, 2018. 4413–4421.
- 24 Chang AX, Funkhouser T, Guibas L, *et al.* ShapeNet: An information-rich 3D model repository. arXiv:1512.03012, 2015.
- 25 Xie J, Dai GX, Zhu F, *et al.* DeepShape: Deep-learned shape descriptor for 3D shape retrieval. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2017, 39(7): 1335–1345. [doi: [10.1109/TPAMI.2016.2596722](https://doi.org/10.1109/TPAMI.2016.2596722)]
- 26 Xu YF, Fan TQ, Xu MY, *et al.* SpiderCNN: Deep learning on point sets with parameterized convolutional filters. Proceedings of the 15th European Conference on Computer Vision. Munich: Springer, 2018. 90–105.
- 27 Li JX, Chen BM, Lee GH. SO-Net: Self-organizing network for point cloud analysis. Proceedings of the 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Salt Lake City: IEEE, 2018. 9397–9406.
- 28 Li YY, Bu R, Sun MC, *et al.* PointCNN: Convolution on X-transformed points. Proceedings of the 32nd International Conference on Neural Information Processing Systems. Montréal: Curran Associates Inc., 2018. 828–838.
- 29 Qi CR, Yi L, Su H, *et al.* 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: Curran Associates Inc., 2017. 5105–5114.
- 30 Wu W, Qi Z, Fuxin L. PointConv: Deep convolutional networks on 3D point clouds. Proceedings of the 2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Long Beach: IEEE, 2019. 9621–9630.
- 31 Zhou HR, Feng YD, Fang MS, *et al.* Adaptive graph convolution for point cloud analysis. Proceedings of the 2021 IEEE/CVF International Conference on Computer Vision. Montreal: IEEE, 2021. 4965–4974.
- 32 Xu M, Ding R, Zhao H, *et al.* PAConv: Position adaptive convolution with dynamic kernel assembling on point clouds. Proceedings of the 2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition. IEEE, 2021. 3173–3182.
- 33 Shamshad F, Khan S, Zamir SW, *et al.* Transformers in medical imaging: A survey. Medical Image Analysis, 2023, 88: 102802. [doi: [10.1016/j.media.2023.102802](https://doi.org/10.1016/j.media.2023.102802)]
- 34 Guo MH, Cai JX, Liu ZN. PCT: Point cloud Transformer. Computational Visual Media, 2021, 7(2): 187–199. [doi: [10.1007/s41095-021-0229-5](https://doi.org/10.1007/s41095-021-0229-5)]
- 35 Phan AV, Le Nguyen M, Nguyen YLH, *et al.* DGCNN: A convolutional neural network over large-scale labeled graphs. Neural Networks, 2018, 108: 533–543.
- 36 Yang Y, Feng C, Shen Y, *et al.* FoldingNet: Point cloud auto-encoder via deep grid deformation. Proceedings of the 2018 IEEE Conference on Computer Vision and Pattern Recognition. Salt Lake City: IEEE, 2018. 206–215.
- 37 Zhang Y, Wang Z, Han J, *et al.* GS-Net: Generalizable plug-and-play 3D Gaussian splatting module. arXiv:2409.11307, 2024.
- 38 Dominguez M, Dhamdhere R, Petkar A, *et al.* General-purpose deep point cloud feature extractor. Proceedings of the 2018 IEEE Winter Conference on Applications of Computer Vision (WACV). Lake Tahoe: IEEE, 2018. 1972–1981.
- 39 Zhang X, Li Z, Change Loy C, *et al.* PolyNet: A pursuit of structural diversity in very deep networks. Proceedings of the 2017 IEEE Conference on Computer Vision and Pattern Recognition. Honolulu: IEEE, 2017. 718–726.
- 40 Liang G, Zhao X, Zhao J, *et al.* MVCNN: A deep learning-based ocean-land waveform classification network for single-wavelength LiDAR bathymetry. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2022, 16: 656–674.
- 41 Li J, Chen BM, Lee GH. SO-Net: Self-organizing network for point cloud analysis. Proceedings of the 2018 IEEE Conference on Computer Vision and Pattern Recognition. Salt Lake City: IEEE, 2018. 9397–9406.
- 42 Thomas H, Qi CR, Deschaud JE, *et al.* KPConv: Flexible and deformable convolution for point clouds. Proceedings of the 2019 IEEE/CVF International Conference on Computer Vision. Seoul: IEEE, 2019. 6411–6420.

(校对责编:王欣欣)