

基于改进 PoinTr 的苹果点云补全方法研究

杨林森¹ 王 宁¹ 王亚雄¹ 康 峰¹
YANG Linsen WANG Ning WANG Yaxiong KANG Feng

摘 要

针对自然环境下苹果果实点云因遮挡导致的不完整问题, 文章提出了一种改进的 PoinTr 网络。通过构建苹果点云数据集(模拟 5%~50% 遮挡), 融合动态图卷积(DGCNN)与坐标注意力(CA)模块, 增强局部特征提取; 结合几何感知 Transformer 编码器-解码器, 实现全局上下文推理。实验表明, 改进方法较原始 PoinTr 的 F_1 分数提升 1.37%, CDL1 和 CDL2 误差分别降低 2.26% 和 0.84%, EMD 降低 2.23%, 在 20% 和 45% 遮挡下补全效果优于主流算法。结果表明, 该方法有效提升补全精度, 为农业表型分析提供技术支持, 但对极端遮挡(50%)场景仍需优化。未来将探索多模态数据融合以增强泛化能力。

关键词

点云补全; 苹果果实; 改进 PoinTr; 注意力机制; 精准农业

doi: 10.3969/j.issn.1672-9528.2025.08.007

0 引言

随着计算机图形技术在精准农业中的应用, 农业生产正变得更加智能化和可持续。利用计算机视觉和图像处理技术, 实现了对作物生长的精确监测, 为精准决策提供科学依据^[1]。三维重建技术^[2]的进步, 提供了超越二维图像的详细作物评估方法, 有助于制定灌溉和施肥策略。使用多角度图像进行植物 3D 建模, 可以获得关于作物结构和生长模式的深入信息。然而, 3D 模型往往有大量的信息和复杂的格式, 这需要技术知识和建模经验来处理^[3]。在使用相关设备采集点云数据时, 由于环境干扰、物体遮挡、操作不当等原因, 采集到的原始点云往往是不完整的^[4]。因此, 实现植物点云补全, 能辅助植物三维形态的完整存储与无损分析, 对植物自动化表型的研究具有重要意义。

在处理生成的不完整点云时, 一种常见的方法是从分析该点云的整体形态特征入手, 基于现有部分的信息推断丢失部分可能的形状, 并据此对这些缺失进行补充, 最终实现点云的完整化^[5]。Kroemer 等人^[6]提出了一种创新的方法, 该方法基于物体在三维空间中的对称特性来生成一系列初始候选对象, 可以更精确地定位出那些可能的最佳匹配。Yuan 等人^[3]提出了 PCN 补全方法, 使用 PointNet 提取点云全局特征, 采用 FoldingNet 将 2D 点映射到 3D 表面, 生成缺失点云的稠密点云。Huang 等人^[7]提出了一种可直接应用于点云的多级损失函数神经网络, 实现从不完整点云到完整点云的映射。

Tchapmi 等人^[8]提出了一种叫 TopNeT 的新颖的解码器

补全算法, 能够生成无需预设特定结构或拓扑的结构化 3D 点云, 显著提升了在 ShapeNet 数据集^[9]上的 3D 点云形状完成任务的表现。在深度点云补全任务中, Transformer^[10]凭借其全局上下文建模能力和自注意力机制, 能高效捕捉点云中的长距离空间依赖, 即使在输入部分缺失或稀疏时也能推理出完整的几何结构。Yu 等人^[11]提出的 PoinTr 网络引入了几何敏感的 Transformer 模块, 通过编码器-解码器结构将点云表示为无序点代理并生成缺失点云, 其实验结果在数值和可视化效果上均显著改善。针对植物枝条具有的骨架特征, 王龙其等人^[12]设计了一种基于骨架引导的植物点云补全网络, 能够融合全局骨架特征和局部的几何细节特征完成植物的点云补全工作。杨志强^[13]针对基于 SFM^[14]得到真实枸杞植株点云, 提出了一种基于几何敏感的 Transformer 补全网络进行点云补全方法, 能够较好地完枸杞植株点云补全。彭杰威^[15]提出了一种基于多尺度几何感知 Transformer 的植物点云补全网络, 该网络对叶类植物补全效果好, 为植物幼苗点云补全提供了新思路。

上述研究虽然在开源数据集和室内盆栽植物点云补全方面取得了一定的成果, 但在农业领域内, 特别是针对自然环境下果树果实(如苹果)的点云补全, 尤其是解决果实遮挡问题方面的探索尤为缺乏。目前大多数点云补全算法主要依赖于整体形态特征进行补全, 而较少关注先验特征的提取, 这导致了补全效果往往未能达到预期。鉴于此, 本文提出了一种基于 PoinTr 架构改进的点云补全方法, 通过集成 DGCNN(dynamic graph CNN)^[16]特征提取模块, 并引入 CA(coordinate attention)^[17]注意力机制, 强化了全局与局部特征的表现, 从而更精确地重建了因遮挡或其他原因缺失的苹果果实点云。通过这种方式, 我们可以期待未来能够在更

1. 北京林业大学工学院 北京 100083

[基金项目] 北京林业大学学院联合基金重点项目(2024XY-G001)

多样化的农业场景中实现更加高效、准确的作物监测与管理。

1 材料和方法

1.1 室内数据集采集

为获取相应点云补全数据集,需实现目标高质量三维点云重建,首先对目标果实进行多角度数据采集。采用环绕式拍摄方案,拍摄示意图如图1所示。




图1 数据集采集示意图

先将目标果实固定在支架上,利用相机围绕果实环绕拍摄,确保覆盖果实的各个细节。然后通过视频抽帧获取图像序列,频率需与拍摄角速度匹配,获取清晰高质量原始图像。总共采集了30个富士苹果的照片集,每个苹果的数据集包含100~300张图像。接下来,利用运动结构恢复算法的稀疏重建和神经辐射场(neural radiance fields, NeRF)^[18]稠密重建技术结合,生成高精度三维点云模型。随后,对模型进行去噪和优化处理,确保点云数据的准确性和完整性。

1.2 数据集构建

经NeRF输出的点云包含果实表面几何特征及颜色信息的PLY格式点云,点云密度可达 $10^5 \sim 10^6$ 点/果实。接下来进行补全数据集制作,参考PCN数据制作方法,将完整点云随机遮挡部分区域,生成不完整点云作为训练输入。

点云数据集构建流程:(1)数据扩增:基于几何与刚体变换不变性,通过旋转变换生成3000个苹果点云样本;

(2)归一化处理:统一 x, y, z 坐标至 $[-1, 1]$ 区间消除尺度差异;(3)遮挡模拟:采用非重叠区域随机遮挡策略,5%~50%比例覆盖果实各表面区域;(4)差异化采样:完整点云采样16384点,缺失点云独立随机采样2048点;(5)数据集架构:按8:1:1比例划分训练/验证/测试集,各集包含全遮挡梯度子集与完整点云子集。

1.3 点云补全网络

本试验提出了基于PoinTr的特征增强的点云苹果点云补全网络,其流程如图2所示。




图2 本文点云补全网络流程

本文提出的点云补全方法,将点云补全问题视为集合到

集合的转换任务。首先,输入的不完整点云通过一个轻量级DGCNN-CA提取中心点周围的局部特征,并结合位置嵌入以形成点代理。接下来,这些点代理作为Transformer编码器-解码器架构的输入,用于预测缺失部分的点代理。解码器使用由查询生成模块动态生成的查询来推断缺失点的初步轮廓,而非固定查询。最后,采用多尺度点云生成模块逐步细化从粗到细的点云补全过程。具体来说,通过给定点代理集合 $F=\{F_1, F_2, \dots, F_N\}$ 表示部分点云,将点云补全的过程建模为集合到集合的平移问题,用公式表示为:

$$V = M_E(F), H = M_D(Q, V) \quad (1)$$

式中: M_E 和 M_D 为编码器和解码器模型; $V=\{V_1, V_2, \dots, V_N\}$ 为编码器的输出特征; $Q=\{Q_1, Q_2, \dots, Q_M\}$ 为对解码器的动态查询; $H=\{H_1, H_2, \dots, H_M\}$ 为缺失点云的预测点代理; M 为预测点代理的个数。

1.3.1 数据预处理——基于DGCNN的特征提取

在三维点云数据处理中,单个点的空间坐标 (x, y, z) 能反映其在全局场景中的绝对位置,而无法有效表征该点周边区域的几何结构特征。若仅将原始三维坐标作为深度学习模型的输入,难以捕捉点云数据中具有判别性的局部邻域上下文关系,进而影响网络对点云细粒度特征的建模能力。为了减少网络的计算负担而导致的训练时间长,就要采用输入的点云数量不能多。在PoinTr中,采用于边卷积的动态图卷积网络通过构建局部邻域特征,自适应地捕捉点云中各点间的局部几何关系,生成了高纬度、低分辨率的三维点云特征。

针对DGCNN在局部几何表征弱、空间感知受限及计算效率低的问题,提出基于坐标注意力CA^[17]的特征增强方法:在图卷积与全局池化层间嵌入CA模块,通过分解坐标轴通道特征并构建长程空间依赖,动态加权三维坐标信息,强化关键区域几何建模精度。

如图3所示,在三维点云中,CA通过融合空间位置信息与通道注意力,动态增强关键区域的特征响应。

首先,通过输入特征 $[B, C, N, K]$ 分别经双向池化捕获空间统计量。其中在水平池化上,沿点云数量维度(N)进行全局平均池化,生成形状为 $[B, C, N, 1]$ 的垂直方向特征;在垂直池化上,沿邻居维度($K=16$)进行全局平均池化,生成形状为 $[B, C, 1, K]$ 的水平方向特征,并转置为 $[B, C, K, 1]$ 。接下来,将水平和垂直方向的特征拼接为 $[B, C, N+K, 1]$,通过二维卷积压缩通道,并通过非线性激活生成中间特征 $[B, \text{mip}, N+K, 1]$ 。然后,将中间特征拆分为水平与垂直分量,即 $[B, \text{mip}, N, 1]$ 和 $[B, \text{mip}, K, 1]$,再分别经二维卷积和Sigmoid激活生成点级与邻居级注意力权重。其中点级注意力权重 a_w ,形状为 $[B, C, N, 1]$,表征每个点的重要性;邻居级注意力权重 a_{nw} ,形状为 $[B, C, 1, K]$,表征每个邻居位置的贡献度。最后,将原始输入特征与两类权重逐元素相乘,突出关键点的局部几何结构。该机制通过显式编码空间分布统计量,在




图3 CA网络结构图

注： B 为批次大小； c 为通道数； N 为点数； K 为邻居数；mip 为压缩后通道数； a_h 为点级注意力权重； a_w 为邻居级注意力权重

通道注意力中嵌入方向感知能力，使模型能够自适应增强对点云边缘、曲面等判别性区域的响应，同时保持轻量化计算特性。

本文提出的基于 DGCNN 的点云特征增强的网络流程如图4所示。

本文提出的改进 DGCNN 算法通过动态图卷积与坐标注意力机制实现点云高效特征提取。算法流程如下：输入点云数据（形状为 $[B, 3, N]$ ）首先经过 1D 卷积将坐标空间映射至 8 维特征空间。随后进入多阶段特征学习框架，每个阶段包含 3 个核心操作：

（1）动态图构建：通过 K 近邻算法（ $K=16$ ）建立局部图结构，计算中心点与邻域点的特征差值并拼接原始特征。

（2）分层特征提取：采用二维卷积配合组归一化和非线性激活函数进行特征变换，通过坐标注意力模块 CA 在空间和通道维度自适应加权重要特征。

（3）特征聚合：沿邻域维度执行最大池化操作，保留最具判别性的特征。算法在两个关键节点插入最远点采样策略，分别将点数从 N 下采样至 512 和 128，在降低计算复杂度的同时保持几何结构完整性。坐标注意力模块通过双向池化捕获空间相关性，利用 Sigmoid 激活生成注意力权重，有效增强了模型对关键区域的感知能力。经过四阶段处理，最终输出 128 个代表性点的三维坐标及其对应的 128 维深层特征 $[B, 3, 128]$ 和 $[B, 128, 128]$ ，该特征表示融合了多层次局部细节和全局上下文信息，通过动态更新图结构和注意力权重机制，实现了对点云非规则数据的高效表征学习。

1.3.2 局部几何 Transformer

为了促进 Transformer 更好地理解和应用三维点云中的几何结构，PoinTr 基于局部几何的 Transformer 其本身的编码器-解码器结构，常常可以根据输入的全局上下文生成注意力权

重，提升了点云数据的处理能力。如图5所示，为局部几何 Transformer 结构。

局部几何 Transformer 结构包含多头自注意力层和线性层，引入最大池化层和 K 近邻查询层作为辅助分支。在这一架构下，输入 X_{t-1} 首先进入多头自注意力层，完成与前述相

似的操作流程。同时，另一分支通过最大池化层提取关键特征，并利用 K 近邻查询层来捕捉每个点的局部几何特性。这两部分的结果分别经过各自的线性层处理后，进行拼接操作，融合全局与局部信息，再次通过一个线性层整合信息，并与原始输入 X_{t-1} 执行残差连接，从而产生最终的输出 X_t 。

1.3.3 点云生成

在本研究中，将输入解码器的 Queries 视为待预测点代理的初始状态，并在编码器与解码器之间引入了 Query 生成器，从而显著提升缺失点云的重建效果。

Transformer 模块预测了点云缺失部分的点集，但 Query 的点代理类似，点集中的每个点代表周围的局部区域。与原始不完整云的缺失部分相比，点的数量是稀疏的，因此只能称为粗点云。为了重新定义预测的缺失部分以匹配原始的不完整云，使用 FoldingNet 网络以点集为中心在局部区域内预测多个点：

$$R_i = \text{FoldingNet}(\text{MLP}(\text{concat}(f_g, p_i))) + p_i, \quad i = 1, 2, \dots, M \quad (2)$$

式中： p_i 是 Transformer 预测的 M 个点中的第 i 个点。将缺失部分点的集合 p_i 与全局特征 f_g 连接起来后，MLP 生成一个新的特征。使用 FoldingNet 网络设置 p_i 的位置，生成 p_i 周围相邻点的集合 R_i 。最后，将原始的不完整点云与经过优化的预测缺失部分拼接在一起，以获得最终的完整点云。

1.4 损失函数

Fan 等人^[19]提出的倒角距离（chamfer distance, CD）避免了计算两个点集时的无序干扰，在许多点云补全任务中得到了广泛的应用。本文改进的 PoinTr 算法的以输出结果与真值计算的倒角距离为损失项，由预测点代理计算的粗粒度点云损失和输出点云计算的细粒度




图4 基于 DGCNN 的点云特征增强的网络流程

点云损失两部分组成。

在 PoinTr 网络中, 对于给定的点云 G , 粗点云 S 和细点云 D 的损失用公式分别表示为:

$$CD_0 = \frac{1}{S} \sum_{s \in S} \min \|s - g\|_2^2 + \frac{1}{G} \sum_{g \in G} \min \|g - s\|_2^2 \quad (3)$$

$$CD_1 = \frac{1}{D} \sum_{d \in D} \min \|d - g\|_2^2 + \frac{1}{G} \sum_{g \in G} \min \|g - d\|_2^2 \quad (4)$$

$$LOSS = CD_0 + \lambda CD_1 \quad (5)$$

其中, 式 (3) (4) 作用是监督 S 生成 D , 通过真实的点云 G 来减小 CD 。式 (5) 中, λ 为权重参数, CD 的最终损失函数是 CD_0 和 CD_1 的和。

2 结果与分析

2.1 试验环境参数

本文运行的算法在以下环境中完成: GPU 为 RTX 4090 (24 GB), CPU 是 Intel (R)Xeon(R) Platinum 8352 V, 主频是 2.10 GHz, 内存 120 GB, 操作系统是 Ubuntu 22.04, 搭载的 cuda 版本是 11.3。在本文的果实数据集上, 设置网络迭代次数 300 次, 批处理大小为 58, 初始学习率设置为 0.000 5, 权重衰减同样设置为 0.000 5。利用 LambdaLR 函数对学习率进行更新, 每次衰减的比例为 0.9。

2.2 评估指标

参照已有 Huang 等人^[20]文献, 采用平均倒角距离作为评价指标, 可以在集合水平上测量预测点云和地面真值之间的距离。对于每次预测, 预测点集 P 与地面真值点集 G 之间的倒角距离计算公式为:

$$dCD_{L1}(P, G) = \frac{1}{|P|} \sum_{p \in P} \min \|p - g\|_1 + \frac{1}{|G|} \sum_{g \in G} \min \|g - p\|_1 \quad (6)$$

式中: CD_{L1} 使用的是 L1-范数, 也称为曼哈顿距离或绝对差之和。对于任意两点 p 和 g , 其距离是坐标差的绝对值之和。 $\|\cdot\|_1$ 表示 L1-范数, 即坐标差的绝对值之和。

$$dCD_{L2}(P, G) = \frac{1}{|P|} \sum_{p \in P} \min \|p - g\|_2^2 + \frac{1}{|G|} \sum_{g \in G} \min \|g - p\|_2^2 \quad (7)$$

CD_{L2} 使用的是 L2-范数, 即欧几里得距离。对于任意两点 p 和 g , 其距离是坐标差的平方和的平方根。式中 $\|\cdot\|_2$ 表示 L2-范数, 即坐标差的平方和的平方根。

搬土距离 (earth mover's distance, EMD) 在三维点云上通过计算一个点云转化为另一个点云的代价表示:

$$EMD(S_1, S_2) = \min_{\phi: S_1 \rightarrow S_2} \sum x - \phi(x) \quad (8)$$

式中: S_1 和 S_2 分别表示两个不同的点云; x 表示点云 S_1 、 S_2 中的点; ϕ 表示点集 S_1 和 S_2 之间的一个双射, 利用 ϕ 将 S_1 和 S_2 进行转化, 计算最小欧式距离。

2.3 改进 PoinTr 训练过程分析

在本文中的损失函数为最终损失函数, 包括点代理和输出点云的损失。由图 6 可知, 随着训练轮数的增加, 损失函数的值都在逐渐减小, 这表明模型在不断学习和优化。具体来说, 最终损失函数从 130 左右开始, 逐渐下降到 67 左右, 在 300 轮的时候趋于稳定, 这表明模型在训练过程中对数据的拟合程度不断提高, 损失值的降低意味着模型预测结果与实际结果之间的差距在缩小。




图 6 本文改进的 PoinTr 最终损失函数图像

2.4 不同方法果实补全结果分析

为了分析本文提出的基于 PoinTr 的点云补全算法对于模拟遮挡缺失果实的性能, 将本网络与具有代表性的 FoldingNet、PCN、TopNet 以及原始 PoinTr 网络进行对比实验。以生成的 3 000 个样本作为训练的数据集, 各个网络模型超参数的 epoch 都设为 300, 其他保持原有的最佳设定。对这几种方法在果实数据集上的补全结果进行定量对比分析, 结果如表 2 所示。

从表 2 对比结果中可知, 本文提出的改进 PoinTr 获得了最高的 F_1 -分数较原始的 PoinTr 网络提升了 1.37%。在倒角距离上, 改进的 PoinTr 相较于原始的 PoinTr 有一定提升。其中, 在 CD_{L1} 上, 改进 PoinTr 达到最佳效果, 与 PoinTr 相比下降了 2.26%。 CD_{L2} 与原始的 PoinTr 相比下降了 0.84%。PCN 在本次苹果果实的点云补全中获得了最佳的 EMD 指标, 改进 PoinTr 达到了 52.353 比原始的 PoinTr 下降了 2.23%。从综合性来看, 改进的 PoinTr 相比原始的 PoinTr 和其他补全算法可以达到一个更好精度和更低的误差。

表 2 不同补全模型的苹果果实点云补全效果

模型	F_1 -分数	CD_{L1}	CD_{L2}	EMD
改进 PoinTr	0.148	26.537	2.232	51.178
PoinTr	0.146	27.151	2.251	52.353
PCN	0.048	29.172	2.418	47.139
TopNet	0.057	28.011	2.183	53.805
FoldingNet	0.057	29.236	2.544	89.963

为了能直观体现出补全效果，选取 20% 和 45% 缺失的苹果点云作为补全可视化推理，用于观察果实点云补全效果，可视化效果如表 3 所示。

表 3 可视化结果分析

缺失比例	输入	改进 PoinTr	PoinTr	PCN	TopNeT	FoldingNeT	真实点云
20%							
45%							

在表 3 中可以看出，第一列是输入的不同缺失比例残缺点云，后面的依次是改进 PoinTr、PoinTr、PCN、TopNeT、FoldingNeT 输出的补全点云，最后一列是真实点云。相比之下，改进 PoinTr 能够获得较好果实外观效果，点云分布较均匀，没有点云过度集中的现象。试验结果表明，本文提出的方法能针对苹果果实的形态特性，对其完成点云补全任务，且补全效果较准确。

3 结论

本文针对自然环境下苹果果实点云因遮挡导致的不完整问题，搭建室内数据采集平台，模拟自然环境下的遮挡，提出了一种基于 PoinTr 架构改进的点云补全方法。通过集成动态图卷积网络与坐标注意力机制，有效强化了局部几何特征与全局上下文信息的融合能力，显著提升了复杂遮挡场景下的补全精度。实验表明，相较于原始 PoinTr 网络， F_1 -分数提升了 1.37%， CD_{L1} 与 CD_{L2} 误差分别降低了 2.26% 和 0.84%，且可视化结果验证了补全点云的形态完整性与细节保真度。

然而，当前方法对极端遮挡（如缺失比例超过 50%）的补全效果仍有待优化，且模型泛化性在多样化果实形态（如形状不规则或密集簇生场景）中需进一步验证。未来工作将探索引入先验语义信息与多模态数据融合策略，以增强复杂农业场景的适应性，同时拓展至其他作物表型分析任务，推动精准农业的智能化发展。

参考文献:

[1] 刘勇, 唐霞. 计算机视觉技术在智慧农业中的应用 [J]. 中国农业资源与区划, 2024, 45(12): 84.
[2] 于瑞清. 农业场景三维重建中景深估计方法研究 [D]. 北京: 北京林业大学, 2022.
[3] YUAN W T, KHOT T, HELD D, et al. PCN: point completion network[EB/OL].(2019-09-26)[2024-05-25].<https://doi.org/10.48550/arXiv.1808.00671>.
[4] YANG Y Q, FENG C, SHEN Y R, et al. FoldingNet: point

cloud auto-encoder via deep grid deformation[EB/OL]. (2018-04-03)[2024-02-23].<https://doi.org/10.48550/arXiv.1712.07262>.

[5] 曾安, 彭杰威, 刘畅, 等. 基于多尺度几何感知 Transformer 的植物点云补全网络 [J]. 农业工程学报, 2022, 38(4): 198-205.
[6] KROEMER O, AMOR H B, EWERTON M, et al. Point cloud completion using extrusions[C/OL]//2012 12th IEEE-RAS International Conference on Humanoid Robots (Humanoids 2012). Piscataway:IEEE,2013[2024-06-23]. <https://ieeexplore.ieee.org/document/6651593>.DOI:10.1109/HUMANOIDS.2012.6651593.
[7] HUANG H H, CHEN H L, LI J X. Deep neural network for 3D point cloud completion with multistage loss function[C/OL]// 2019 Chinese Control And Decision Conference(CCDC).Piscataway:IEEE,2019[2025-01-02]. <https://ieeexplore.ieee.org/document/8832956>.DOI:10.1109/CCDC.2019.8832956.
[8] TCHAPMI L P, KOSARAJU V, REZATOFIGHI H, et al. TopNet: structural point cloud decoder[C/OL]// 2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition(CVPR).Piscataway:IEEE,2019[2024-06-12]. <https://ieeexplore.ieee.org/document/8953650>.DOI:10.1109/CVPR.2019.00047.
[9] CHANG A X, FUNKHOUSER T, GUIBAS L, et al. ShapeNet: an information-rich 3D model repository[EB/OL]. (2015-12-09)[2024-06-13].<https://doi.org/10.48550/arXiv.1512.03012>.
[10] ZHAO H S, JIANG L, JIA J Y, et al. Point transformer[EB/OL].(2021-09-26)[2025-03-12].<https://doi.org/10.48550/arXiv.2012.09164>.
[11] YU X M, RAO Y M, WANG Z Y, et al. PoinTr: diverse point cloud completion with geometry-aware transformers[EB/OL].(2021-01-11)[2024-05-25].<https://doi.org/10.48550/arXiv.2301.04545>.
[12] 王龙其, 杨志强, 张鹏, 等. 基于几何敏感的枸杞植株点云补全方法 [J]. 农业科学研究, 2023, 44(3): 24-29.
[13] 杨志强. 基于三维重建的枸杞植株表型测量系统研究与实现 [D]. 银川: 宁夏大学, 2022.
[14] SCHONBERGER J L, FRAHM J M. Structure-from-motion revisited[C/OL]// 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR).Piscataway: IEEE, 2016[2025-05-11].<https://ieeexplore.ieee.org/document/7780814>.DOI: 10.1109/CVPR.2016.445.

基于条件生成对抗网络的不确定性空间信息重建

屠红艳¹ 陈 钰^{2*}
TU Hongyan CHEN Yu

摘 要

目前用于不确定性空间信息重建的方法例如多点地质统计法,需要多次对训练图像(TI)进行扫描,再通过复杂的概率计算获得模拟结果,导致其效率较低。针对这一问题,文章提出了一种基于条件生成对抗网络(CGAN)的不确定性空间信息重建方法。条件数据作为已知的信息对不确定性空间信息重建具有非常重要的引导意义,CGAN方法将随机噪声与条件数据一起输入生成器中,条件数据用于指导空间信息的生成过程,而判别器用于判断生成器的重建数据与训练样本是否为同一数据。相较于传统方法,CGAN方法在训练完成后,学习到的特征能够以参数的形式存储在硬盘中,当需要进行同种空间信息重建时就可以重复利用,而不必每次重新扫描训练样本,因此具有明显的速度优势。对重建结果与训练样本进行孔隙度、变差函数、多点连通曲线和孔隙分布的对比分析工作,实验证明了CGAN方法在条件数据的指导下能较好地再输出结果中再现TI的结构特征,同时效率与传统方法相比具有优势。

关键词

空间信息重建;深度学习;条件生成对抗网络

doi: 10.3969/j.issn.1672-9528.2025.08.008

0 引言

不确定性空间信息重建中有多种常用方法,如地质统计法、基于图像处理的方法还有近年兴起的机器学习与深度学习,其中地质统计法应用最为广泛。由于地质统计学与空间数据和结构信息密切相关,也称之为“空间信息统计学”^[1-2]。空间建模工具如今在石油地质、地层学、岩石学、气象学、遥感地质等诸多领域有着广泛的应用^[3]。

目前,应用较多的不确定性空间信息重建方法多点信息统计法,无法将重建特征以参数形式存储在磁盘上,所以每次重建均需要重新扫描TI。而深度学习方法在训练完成后,学习到的特征能够以参数的形式存储在硬盘中,因此可以重复利用,无需每次重新扫描TI。生成对抗网络中生成器将噪声映射到数据空间,期望生成数据具有与真实样本同样的分布。

本文结合条件数据,将CGAN应用于不确定性空间信息重建研究,阐述了条件数据的提取过程,通过对比传统GAN与基于条件数据CGAN的工作原理,并与其他不确定性空间

1. 上海电力大学现代教育技术中心 / 信息办 上海 201306
2. 上海理工大学科技发展研究院 上海 200093

[15] 彭杰威. 基于深度学习的植株点云数据修补算法研究[D]. 广州: 广东工业大学, 2022.

[16] WIDYANINGRUM E, BAI Q, FAJARI M K, et al. Airborne laser scanning point cloud classification using the DGCNN deep learning method[J]. Remote sensing, 2021, 13(5): 859.

[17] HOU Q B, ZHOU D Q, FENG J S. Coordinate attention for efficient mobile network design[C]// 2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Piscataway:IEEE, 2021:13708-13717.

[18] MILDENHALL B, SRINIVASAN P P, TANCIK M, et al. NeRF: representing scenes as neural radiance fields for view synthesis[J]. Communications of the ACM, 2021, 65(1): 99-106.

[19] FAN H Q, SU H, GUIBAS L. A point set generation network for 3D object reconstruction from a single image[EB/

OL].(2016-12-07)[2025-02-12].<https://doi.org/10.48550/arXiv.1612.00603>.

[20] HUANG Z T, YU Y K, XU J W, et al. PF-Net: point fractal network for 3D point cloud completion[C/OL]//2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition(CVPR).Piscataway:IEEE,2020[2024-11-12]. <https://ieeexplore.ieee.org/document/9156663>.DOI:10.1109/CVPR42600.2020.00768.

【作者简介】

杨林森(1998—),男,四川巴中人,硕士研究生,研究方向:果园三维重建及点云处理, email: 185287562@qq.com。

(收稿日期: 2025-03-13 修回日期: 2025-07-30)