

融合形状结构恢复和细节补偿的双分支点云修复网络

缪永伟^{1,2)}, 景程宇¹⁾, 刘复昌²⁾, 张旭东^{3)*}

¹⁾ (浙江理工大学计算机科学与技术学院 杭州 310018)

²⁾ (杭州师范大学信息科学与技术学院 杭州 311121)

³⁾ (浙江树人学院信息科技学院 杭州 310015)

(xdzhang@zjsru.edu.cn)

摘 要: 针对传统点云修复中难以有效地保持原始形状细节结构信息的问题, 提出一种融合形状全局结构恢复和局部细节补偿的双分支点云形状修复网络. 网络中的形状全局结构恢复分支为编解码-解码器结构, 编码器对缺失点云数据进行特征变换以克服点云形状的旋转不变性, 利用最大池化操作解决点云的无序性问题, 并通过多层感知器生成原始点云的特征码字, 解码器对编码得到的特征码字使用 4 个二维网格进行 2 次折叠操作, 拟合点云形状得到粗修复结果; 为了补偿点云粗修复结果的形状细节信息, 网络中的局部细节补偿分支对编码器提取得到的不同维度特征, 通过层次特征学习和多层次特征融合学习点云形状的几何结构特征, 有效地恢复缺失点云数据并保留原始形状细节信息; 最终将经全局结构恢复分支和局部细节补偿分支分别得到的点云数据拼接融合, 再进行迭代最远点重采样, 得到点云形状精修复结果. 实验结果表明, 在 ShapeNet 数据集上, 所提网络比已有网络修复结果的平均 CD 误差和平均 EMD 误差分别低 16%~29% 和 19%~65%; 在 ModelNet 数据集上, 比已有网络修复结果的平均 CD 误差和平均 EMD 误差分别低 6%~41% 和 31%~59%; 该网络可以修复原始形状的整体结构信息并能有效地恢复其形状细节, 生成采样点分布均匀的完整点云模型, 且对模型噪声和不同程度的模型缺失均具有鲁棒性.

关键词: 点云形状; 修复补全; 几何细节补偿; 双分支网络; 编码器-解码器

中图法分类号: TP391.41 **DOI:** 10.3724/SP.J.1089.2024.19984

A Double-Branch Point Cloud Completion Network by Combining Shape Structure Recovery and Local Detail Compensation

Miao Yongwei^{1,2)}, Jing Chengyu¹⁾, Liu Fuchang²⁾, and Zhang Xudong^{3)*}

¹⁾ (School of Computer Science and Technology, Zhejiang Sci-Tech University, Hangzhou 310018)

²⁾ (School of Information Science and Technology, Hangzhou Normal University, Hangzhou 311121)

³⁾ (School of Information Science and Technology, Zhejiang Shuren University, Hangzhou 310015)

Abstract: To address the issue that it is difficult to effectively maintain the detail information of original shapes for traditional point cloud restoration methods, a two-branch point cloud completion network is proposed which combines shape structure recovery branch and local detail compensation branch. For the shape structure recovery branch, its encoder performs feature transformation on the missing point cloud data to overcome the rotational invariance of the 3D shapes, and solves the disorder problem of the point cloud by using the maximum pooling operation, which can generate the feature codeword of the input shape by adopting the multi-layer perceptron. In order to compensate shape details of the coarse completion results, the local detail compensation branch can learn

收稿日期: 2022-09-22; 修回日期: 2023-05-05. 基金项目: 浙江省自然科学基金(LZ23F020002); 国家自然科学基金(61972458); 浙江省基础公益研究计划(LGF22F020006). 缪永伟(1971—), 男, 博士, 教授, 博士生导师, CCF 杰出会员, 主要研究方向为计算机图形学、点云处理、计算机三维视觉、机器学习与深度学习; 景程宇(1996—), 男, 硕士研究生, 主要研究方向为计算机图形学、点云处理; 刘复昌(1982—), 男, 博士, 副教授, 主要研究方向为计算机图形学、计算机视觉、机器学习与深度学习; 张旭东(1982—), 男, 博士, 副教授, 论文通信作者, 主要研究方向为计算机图形学、计算机视觉.

the geometric features of the underlying shapes through hierarchical feature learning and multi-level feature fusion for different dimensional features extracted from the encoder, so as to effectively recover the missing point cloud data and retain the original shape details. Finally, the point cloud data obtained by these two branches will be stitched and fused, and then the farthest point resampling is iteratively performed to obtain the final point cloud completion results. Compared with the completion results on ShapeNet dataset, the average CD error and EMD error of our proposed network are 16%–29% and 19%–65% lower than that of the existing networks respectively, whilst the average CD error and EMD error are 6%–41% and 31%–59% lower than that of the existing network respectively if testing on the ModelNet dataset. The proposed two-branch completion network can repair the overall structure of the underlying shape and effectively recover its shape details to generate a complete point cloud model with uniform distribution of sampling points. The network is also robust to model noise and different degrees of missing data.

Key words: point cloud shape; shape completion; geometric detail compensation; double-branch network; encoder-decode

基于点云扫描数据的三维形状修复补全已成为三维视觉与计算机图形学领域的研究热点^[1]. 利用三维扫描仪、深度相机、深度传感器等获取的扫描数据通常呈现为离散点云数据(包括 RGB-D 数据), 针对点云数据的获取、增强、理解等方面的工作得到了学术界和工业界的普遍重视, 其相关技术被广泛应用于智能机器人^[2]、无人驾驶^[3]、视觉同步定位与地图构建(simultaneous localization and mapping, SLAM)^[4]等行业和领域. 然而, 无论是机器人识别与抓取、自动驾驶路径规划, 抑或移动平台 SLAM 等实际应用中, 均要求智能体与周围环境直接进行交互^[4], 需要依赖完整的三维点云数据; 但点云数据扫描获取过程中, 由于扫描设备视角单一、场景物体的自身遮挡、扫描精度不高等原因, 获取的点云数据通常表现为分布稀疏、局部扫描或不完整数据^[5], 而残缺点云数据在实际应用中会带来诸如识别不准确、检测难度增加、重建精度低等缺陷, 因此需要对缺失点云数据进行修复补全^[6].

已有的点云修复网络中, 大多采用传统的编码器-解码器结构对点云模型进行补全. Yuan 等^[7]提出的点云补全网络(point completion network, PCN)采用简单编码器-解码器框架, 能够根据缺失点云数据生成完整点云模型, 并采用 FoldingNet 结构^[8]模仿平面折叠变形将二维格点映射到三维形状表面, 最终生成完整点云模型. 然而在修复点云形状时, 传统 PCN 难以合成点云物体的精细细节特征. 借助三维形状的图集表示及其流形定义, Groueix 等^[9]提出 AtlasNet, 通过将一组正方形映

射到三维形状的表面, 以局部逼近目标形状表面, 该网络适用于合成三维对象的一般形状. Wang 等^[10]提出一种级联优化网络(cascaded refinement network, CRN), 采用从粗糙到精细的点云补全策略生成点云模型, 并通过跨层连接结构将倍增点云和形状特征向量拼接, 得到稠密的完整点云.

在点云修复网络的编码器-解码器结构中, 根据输入的缺失点云数据, 编码器首先将点云数据提取特征并压缩成低维全局特征向量; 解码器则将压缩后得到的特征码字进行解码转换为完整点云数据. 然而, 通常因为编码器-解码器结构并没有充分利用原始点云模型的形状结构和细节信息, 所以其在点云修复补全过程中弱化了点云细节特征, 导致对形状结构的恢复具有一定局限性. 为了克服传统网络的局限性, 本文提出一种融合形状全局结构恢复和局部细节补偿的双分支点云修复网络, 以实现点云形状的修复补全. 其中, 第 1 个分支中输入的缺失点云数据通过编码器-解码器结构得到粗修复结果; 第 2 个分支则结合利用全局结构恢复分支得到点云编码特征信息, 并通过层次特征学习和多层次特征融合学习点云的几何结构特征, 恢复点云的形状; 最终经过拼接融合和重采样, 得到细节保持、点云分布均匀的完整形状.

1 相关工作

与点云数据修复补全相关的工作包括: 点云生成与上采样、点云修复补全.

1.1 点云生成与上采样网络

随着扫描点云数据成为三维视觉和基于点的图形学的主流表示形式, 高分辨率点云生成与上采样问题变得至关重要. 借助生成式模型, 如生成式对抗网络(generative adversarial network, GAN)或变分自编码器(variational auto-encoder, VAE)^[11], 研究人员提出了相应的点云上采样网络. Achliopitas 等^[12]提出用于三维点云生成的 r-GAN, 通过对点云形状语义部分进行编辑造型、形状类比或形状插值等操作, 实现了形状编辑和形状补全. Valsesia 等^[13]利用图神经网络合成三维形状, 通过对各图卷积层中每个顶点的特征向量计算相邻矩阵, 学习生成局部特征并合成为形状. 虽然上述网络能够从噪声数据中有效地合成三维物体的点云形状, 但由于其点云数据分布不规则, 以及针对大规模点云数据的神经网络训练难, 借助基本的 GAN 或 VAE 网络通常仅能生成小尺度(如 1 024 个采样点)的点云形状. Yang 等^[14]提出由两级连续归一化流组成的 PointFlow 网络, 通过变分推理训练生成点云模型, 虽然该网络在点云重建中表现出优越性能, 但仅限于合成物体的一般形状, 并不适合点云形状的修复补全.

点云形状上采样旨在根据给定的稀疏、不均匀的点云数据, 生成密集、均匀的点云数据^[15]. Yu 等提出的点云形状上采样网络以 PointNet++^[15]为骨干网络^[16], 提取输入点云模型的特征信息, 通过一系列的卷积在特征空间上进行扩展, 学习每个采样点的多层次特征, 借助数据驱动的点云上采样技术生成稠密点集; Yu 等^[17]的点云采样网络通过随机降采样得到更适合网络的点云训练数据集, 并利用特征得到相对于原来点云位置的扰动, 最终通过惩罚点和边缘标签之间的距离生成平滑的边缘及物体表面. 虽然这 2 种网络均取得了较好的效果, 但其仅局限于对点云数据进行小比例(如 4 倍率)的上采样, 不能进行大比例(如 16 倍率)的点云上采样操作. 为了克服该局限性, Wang 等^[18]提出一个分层的点云特征提取和多级点云生成网络, 实现大比例(如 16 倍率)的点云上采样, 但由于在网络训练过程消耗过多计算内存, 导致其仅局限于稀疏点云数据的上采样操作, 并不适用于稠密分布的点云修复任务.

1.2 点云修复补全网络

为了有效地修复缺失点云数据, 受到 Qi 等^[19]提出的 PointNet 启发, 大部分点云形状修复补全网络采用编码器-解码器结构, 其中, 初始输入的点云数据被编码为全局特征向量, 并经过解码器

解码生成完整点云数据. 典型的 PCN^[7]通过端到端方式直接处理原始点云, 实现点云形状的修复. FoldingNet^[8]在解码器端通过折叠操作将一个规范的二维网格重建生成点云的表面形状. AtlasNet^[9]能够同时实现表面参数化与表面嵌入, 从而生成目标形状. 为了在点云上使用树结构处理方式, Tchapmi 等^[20]提出一种分层的树状结构网络生成完整点云形状, 在点云修复过程中不需要对输入的缺失点云数据施加拓扑结构约束, 并且能够隐式地建模点云结构生成结构化点云. 通过将不完整点云网格化和网格反转技术生成点云, Xie 等^[21]提出 GRNet(griding residual network), 能够在不丢失原始模型信息的前提下将点云数据转为三维规则结构化体网格, 并使用三维卷积处理体网格上的形状信息进行点云数据的修复补全. 借助跳跃注意机制, Wen 等^[22]提出一种用于点云修复的网络. 跳跃注意网络(skip-attention network, SA-Net), 该网络能够利用输入点云模型中的局部区域特征实现点云形状补全. 借鉴分形思想, Huang 等^[23]提出的 PF-Net(point fractal network), 通过多分辨率编码器进行高低层次点云语义信息的提取, 金字塔解码器用于生成点云, 生成过程中采用多阶段补全损失进行监督. 借助自监督学习策略, Alliegro 等^[24]利用去噪和对比学习从训练数据中编码点云形状局部和全局信息, 并对学习到的信息进行解码, 以估计缺失点云数据. Pan 等^[25]提出变分关联点云补全网络(variational relational point completion network, VRCNet), 通过挖掘三维形状结构关系达到预测完整形状的目的. 为了实现从完整形状到缺失形状的反向学习, Wen 等^[26]提出一种点云补全网络 Cycle4Completion, 通过学习从互补形状生成完整或不完整形状以提升神经网络理解三维形状的能力; Xiang 等^[27]提出的点云修复网络 SnowflakeNet, 把完整点云的生成理解为三维空间中雪花形状的生长过程, 其中, 点云在每次雪花点反卷积(snowflake point deconvolution, SPD)操作后通过分割父点逐步生成子点, 由 SPD 生成的结构化点云能精确地捕捉局部结构特征, 生成平滑区域和尖锐边缘. 针对三维物体或场景的修复问题, Wang 等^[28]将修复过程中的位移向量作为学习参数, 在点云修复的编解码结构中迭代地进行特征提取并进行池化, 实现点云数据修复补全.

需要指出的是, 传统点云修补网络的侧重点是形状全局结构信息的修复补全, 而对点云形状细节信息的恢复则关注并不多. 本文网络不仅能

利用全局结构修复分支恢复点云整体形状, 而且能借助局部细节补偿分支恢复形状细节信息, 并对这 2 个分支得到的点云数据进行融合与重采样, 最终得到恢复细节的点云模型。

2 本文网络

为了实现在点云形状修复过程中有效地保持原始形状细节信息的目的, 借助神经网络的几何学习机制, 本文提出一种结合形状全局结构恢复和局部细节补偿的双分支点云修复网络结构。该网络以缺失点云数据作为输入, 其全局结构恢复分支由编码器-解码器组成, 首先对缺失点云利用编码器编码, 得到带有全局信息的特征码字, 该特征码字经解码器进行 2 次折叠操作得到点云粗修复结果, 然而粗修复结果中通常缺乏形状局部细节信息; 进一步, 采用形状局部细节补偿分支恢复点云补全过程中丢失的模型局部细节。为了充分利用输

入缺失点云中包含的局部细节信息, 修复过程中, 在编码器中提取得到的多层次特征信息的基础上, 网络的形状局部细节补偿分支对各个层次的特征信息进行学习和层次融合, 目的是学习各个采样点从局部到全局的多粒度特征, 并在特征空间中扩大点集, 并经细节重塑恢复原始点云的细节信息。

图 1 所示为本文网络框架。形状全局结构恢复分支由编码器-解码器结构组成: 首先对输入的缺失点云数据 S_I 进行粗修复, 得到补全结构信息的粗修复点云 S_C , 但其缺乏形状局部几何细节; 形状局部细节补偿分支中, 在学习输入缺失点云 S_I 几何细节的基础上得到重塑点云 S_{Up} ; 最后对 2 个分支的输出进行拼接融合, 并经迭代最远点采样 (iterative farthest point sampling, IFPS)^[29] 生成保细节信息的、采样点分布均匀的形状精修复结果 S_F 。网络训练过程中, 本文采用倒角距离 (chamfer distance, CD) 误差^[30] 和 EMD (earth mover distance) 误差^[31] 评估点云修复的有效性。




图 1 本文网络框架

2.1 点云形状全局结构恢复分支

点云形状修复中, 为了对输入的缺失点云数据进行全局结构补全并恢复物体整体形状, 本文网络中的形状全局结构恢复分支采用编码器-解码器结构。其中, 编码器解决原始输入点云的旋转性和无序性问题, 并通过多层感知器 (multi-layer perceptron, MLP) 编码得到带全局信息的特征码字; 解码器对输入的特征码字使用 4 个二维网格进行 2 次折叠操作, 拟合点云形状粗修复结果。

在形状编码阶段, 全局结构恢复分支中的编码器输入为具有 M 个离散采样点坐标信息的 $M \times 3$ 矩阵 S_I 。由于该缺失输入点云存在旋转性和无序性问题, 因此首先使用 2 个联合 T-Net 变换解决原始点云旋转性问题; 其中, 3×3 输入变换能够调整点云形状姿势, 64×64 特征变换能够对经共享 MLP 训练得

到的点云特征进行对齐。经过 2 次变换后, 64 维点云特征通过 3 层感知器 (64, 128, 1024) 得到 $M \times 1024$ 的点云形状全局特征信息。至此, 解决了原始点云 S_I 的旋转性问题, 并对各采样点提取得到 1024 维特征。为了进一步克服点云无序性问题, 全局结构恢复分支利用最大池化操作聚合全局特征得到 1×1024 特征向量。最后, 通过 2 层感知器对点云全局特征进行编码, 得到输入点云 S_I 带有全局信息的 1×512 维特征码字。

在特征解码阶段, 全局结构恢复分支中的解码器以 FoldingNet^[8] 为主干网络, 从编码器编码得到带有全局信息的 1×512 维特征码字作为解码器输入。图 2 所示为解码器结构, 使用 4 个二维网格对特征码字进行 2 次折叠操作, 得到粗修复点云 S_C 。首先将编码器生成的特征码字复




图 2 解码器结构

制 N 次, 得到 $N \times 512$ 矩阵; 然后网络初始化 4 个维度 $N \times 2$ 的正方形二维网格, 通过折叠操作拟合点云的三维形状, 将特征码字 $N \times 512$ 矩阵与 4 个二维网格拼接, 得到 4 个大小为 $N \times 514$ 的矩阵, 经过 3 层感知器处理后得到第 1 次折叠结果并输出 4 个 $N \times 3$ 矩阵; 再将复制 N 次的形状全局信息特征码字与第 1 次折叠结果的 $N \times 3$ 矩阵进行拼接, 得到 4 个 $N \times 515$ 矩阵, 并将其经 3 层感知器处理后进行第 2 次折叠操作, 得到 4 个 $N \times 3$ 的矩阵; 最后对这 4 个矩阵进行拼接, 得到 $4N \times 3$ 矩阵, 至此, 在三维空间内完成了第 2 次折叠并得到粗修复点云 S_C 。

需要指出的是, 本文网络中, 全局结构恢复分支对缺失点云恢复得到的粗修复点云通常具有完整形状, 但该分支侧重点对点云整体形状的结构恢复, 难以修复模型局部细节. 因此, 需要进一步考虑局部细节补偿分支, 以对粗修复点云进行细节恢复。

2.2 点云形状局部细节补偿分支

局部细节补偿分支充分利用输入点云的局部几何信息, 通过多层次特征融合有效地学习点云形状细节, 进一步修复得到模型细节保持的上采样点云。

受到 PU-Net^[16]中层次特征学习以及多层次特征融合启发, 在本文的局部细节补偿分支中, 充分利用编码器中得到的点云模型在各个尺度上的特征, 对各采样点进行从局部到全局的多粒度特

征学习, 能在特征空间中扩大采样点集, 并经过细节重塑恢复原始点云的细节信息. 图 3 所示为局部细节补偿分支的结构, 输入为全局结构恢复分支编码器中的特征信息 $M \times C_i$ ($i=1,2,\dots,r$), 最终输出得到含 rM 个采样点的上采样点云 S_{UP} . 局部细节补偿分支的输入为来自全局结构恢复分支编码器 f 的 $M \times C_i$ 维中间特征, 这是由于中间特征能够体现编码器中各层次的分层特征信息, 并包含输入点云的局部几何信息. 局部细节补偿分支首先将分层中间特征 f_i ($i=1,2,\dots,r$) 分别输入对应的层次特征学习模块, 特征学习过程中可以对点云几何特征进行有效提取并经多层次特征融合, 将不同尺度上的特征进行组合, 从而能有效地保留原始点云的局部细节结构信息. 图 3 中, MLP(256,128,3)为感知器各层的输出维度, 首先输入的 $M \times C_i$ 维中间特征, 经各个层次特征学习模块处理后分别得到 $M \times 3$ 特征; 然后对得到的 r 个特征进行拼接, 得到 $M \times 3r$ 形状张量; 最后经过三维形状重塑, 将该形状张量转换为 $rM \times 3$ 点云坐标信息, 并输出上采样点云 S_{UP} 。

需要指出的是, 利用层次特征学习和多层次特征融合策略, 借助局部细节补偿分支可以生成原始输入点云形状中的模型缺失部分, 通过多层次特征融合方式, 从小邻域内的几何结构中提取出局部特征, 再逐级将局部特征扩大直至得到全




图 3 局部细节补偿分支的结构

局特征, 实现了在对点云形状粗修复结果的基础上保留点云形状的局部细节信息恢复. 最终, 将局部细节补偿分支重塑得到的 rM 个采样点与粗修复结果的 $4N$ 个采样点进行拼接融合, 得到 $rM + 4N$ 个采样点云形状, 对融合结果经 IFPS 重采样^[29], 生成保细节信息的、采样点分布均匀的点云形状精修复结果 S_F .

3 损失函数

为了评价结合全局结构恢复和局部细节补偿的双分支点云修复网络的补全性能, 本文损失函数定义中, 采用 CD 误差和 EMD 误差衡量模型修复结果与真实点云之间的差异. 本文网络采用双分支结构, 修复过程中不仅考虑形状全局结构信息的补全, 同时考虑局部细节特征的学习和形状细节的恢复. 损失函数包括 3 部分: 一是点云形状

粗修复结果 S_C 与真实点云形状之间的差异; 二是经细节特征学习得到的重塑点云 S_{UP} 与真实点云形状之间的误差; 三是最终精修复点云 S_F 与真实点云形状之间的误差.

本文损失函数 L 的公式为

$$L = \alpha \cdot [CD(S_C, S_{GT}) + EMD(S_C, S_{GT})] + \beta \cdot [CD(S_{UP}, S_{GT}) + EMD(S_{UP}, S_{GT})] + \gamma \cdot [CD(S_F, S_{GT}) + EMD(S_F, S_{GT})].$$

其中, 权值 α 值越大, 表明网络在训练过程中侧重恢复粗修复点云的完整形状; β 值越大, 表明网络在训练过程中更关注模型的细节特征恢复; 最终精修复点云 S_F 则既取决于 2 个网络分支的修复结果, 也在于选取合适的 γ 值. 本文在不同权值组合下, 对最终的点云修复补全效果进行实验, 如图 4 所示. 表 1 所示为不同损失权重下修复结果误差对比. 本文实验中均采用权值 3, 选取 $(\alpha, \beta, \gamma) = (0.4, 0.5, 0.1)$.




图 4 不同权值选取下的修复效果

表 1 不同损失权重修复结果的误差对比

误差	点云模型	权值 1	权值 2	权值 3
CD	椅子	0.025 34	0.025 61	0.023 37
	床	0.063 46	0.057 14	0.050 11
EMD	椅子	0.070 28	0.068 98	0.060 62
	床	0.108 92	0.081 52	0.078 67

注: 粗体表示最优值.

4 实验结果与分析

4.1 数据集和数据处理

本文采用 ShapeNet 数据集^[20]和 ModelNet 数据集^[32]提供的模型构建缺失点云与真实点云的数据集. 首先从 2 个数据集中选取 4 500 个点云模型, 包含各类别的缺失点云和相应的完整点云, 如飞机、橱柜、汽车、椅子、灯、船只、花瓶和马桶等;


然后从 4 500 个点云模型中选取 3 000 个包含缺失点云和真实点云的三维模型作为训练集, 将缺失点云数据作为网络的输入, 将对应的真实模型作为验证进行训练. 本文网络的训练周期设置为 100, 批大小设置为 16, 学习率设置为 0.000 1. 对本文网络在 ShapeNet 数据集的 8 个类别, 以及 ModelNet 数据集的 40 个类别上的点云数据修复性能进行实验, 并通过 CD 误差和 EMD 误差验证该网络的有效性.

4.2 点云形状的保细节修复

针对数据缺失的点云模型数据集, 本文网络实现了有效的点云修复. 图 5 所示为局部细节补偿分支的修复补全效果. 可以看出, 对缺失另一半的飞机、汽车、轮船等模型, 本文网络取得了更好的修复补全性能, 能有效地生成三维形状另一半结构的点云数据, 修复生成的点云形状可以有效地

恢复缺失模型原有的飞机引擎、汽车轮胎、轮船船舷等结构,同时能修复点云形状结构信息.表 2 所示为局部细节补偿分支修复效果误差统计.

图 6 所示为利用局部细节补偿分支得到的点云修复效果及放大图.可以看出,图 6b 中对模型




a. 输入点云 b. 上采样点云 c. 真实点云

图 5 局部细节补偿分支的修复效果

表 2 局部细节补偿分支修复效果的误差对比

模型	CD 误差	EMD 误差
飞机	0.020 47	0.065 64
汽车	0.027 40	0.087 67
轮船	0.021 72	0.083 26


缺失细节进行了恢复,图 6a 飞机模型中缺失的机身左侧和左侧翅膀根部均得到了有效的修复,翅膀根部和飞机翅膀的点云分布均匀程度一致;图 6a 汽车模型中缺失的左侧部分得到了有效的修复,模型中间和右侧较为完整,修复得到的汽车左侧与中间部分的点云分布均匀程度相当.实验表明,局部细节补偿分支能很好地恢复模型细节,生成较为均匀分布的点云.



a. 输入点云 b. 上采样点云 c. 真实点云

图 6 细节补偿分支修复效果及放大图

本文网络在 Ubuntu 系统上实现,运行环境为 NVIDIA GTX 1080TI GPU, Python 3.5.3, Tensorflow 1.12.0.图 7 所示为本文网络形状修复补全效果示例,其中,图 7b 所示为经过全局结构恢复分支修复得到的粗修复点云,图 7c 所示为经过 2 个



a. 缺失点云 b. 粗修复结果 c. 精修复结果 d. 真实点云

图 7 本文网络的点云修复效果

分支拼接之后进行重采样的精修复结果. 可以看出, 形状全局结构恢复分支虽然修复了输入点云模型的完整结构, 但是缺乏形状细节的有效恢复, 如飞机尾部引擎、汽车轮胎等, 同时出现诸如台灯灯罩边缘欠平滑、仅能恢复轮船整体轮廓而缺少边缘细节、轮船尾部船尾楼未能完整保留等缺陷; 经过2个分支修复拼接之后, 进行重采样的完整点云(如图7c所示)则能较好地恢复其形状细节信息, 说明局部细节补偿分支可以很好地修复原始点云的结构细节. 表3所示为本文网络补全效果的误差对比. 可以看出, CD误差通常比粗修复结果低, 其修复结果的EMD误差亦低于粗修复结果, 表明本文网络在修复形状整体结构的同时能有效地恢复形状细节, 生成采样点分布均匀的完整模型.

4.3 模型噪声和不同程度数据缺失的鲁棒性

本文网络不仅能修复普通的缺失点云数据, 而且可以对含噪声的缺失点云数据进行修复补全. 图8所示为本文网络对具有不同标准差参数(分别为0.006, 0.010, 0.014)的高斯噪声扰动后的残缺点云

表3 本文网络修复效果的误差对比

误差	修复方式	点云模型			
		飞机	汽车	台灯	轮船
CD	粗修复	0.020 82	0.023 37	0.023 74	0.018 75
	精修复	0.019 69	0.022 82	0.021 94	0.016 16
EMD	粗修复	0.039 50	0.037 35	0.102 53	0.031 12
	精修复	0.030 99	0.036 13	0.038 12	0.018 13

模型的修复补全效果. 可以看出, 本文网络可以有效地对带噪声且缺失床头的床、带噪声且缺失瓶身的水瓶、带噪声且缺失桌面和桌腿的桌子进行修复补全, 表明该网络对不同程度高斯噪声扰动的缺失点云数据修复具有鲁棒性.

标准差为0.01时, 本文网络与PCN^[7], FoldingNet^[8], AtlasNet^[9], CRN^[10]对噪声点云模型的修复效果对比如图9所示. 可以看出, 本文网络能对含高斯噪声的点云数据进行有效修复; 与其他网络相比, 本文网络能够有效地修复椅腿、瓶口等形状结构.




图8 不同标准差时高斯噪声扰动的修复效果




图9 噪声点云模型的修复效果对比

为了进一步验证本文网络的有效性,图 10 所示为在有监督情况下,数据缺失率分别为 40%、60%和 80%的点云模型的修复补全效果。可以看出,本文网络能够较好地修复具有不同程度缺失的点云数据,并能有效地恢复其完整形状。

4.4 不同点云修复网络比较

将本文网络与已有的点云修复网络进行比较,验证该网络对缺失点云形状修复的有效性,其中,采用 ShapeNet 数据集^[20]和 ModelNet 数据集^[32]作为网络训练数据集。为统一起见,ShapeNet 数据集上原始输入缺失点云数目均为 2 048,粗修复分支输出点云数目均为 1 936,重塑分支输出点云数目均

为 6 144;因此经双分支拼接融合得到的点云数目均为 8 080,经 IFPS 重采样后的最终完整点云数目均为 2 048,而真实点云的采样点数目均为 2 048。在 ModelNet 数据集上,原始输入缺失点云数目均为 614,粗修复分支输出点云数目均为 1 024,重塑分支输出点云数目均为 1 842;故经双分支拼接融合后的点云数目均为 2 866,经 IFPS 重采样后的最终完整点云数目均为 1 024,而真实点云采样点数目均为 1 024。本文使用相同训练集和测试集进行训练并测试不同点云修复网络,训练过程中均采用相同的训练周期、学习率和批大小。

图 11 所示为 5 种网络在 ShapeNet 数据集^[20]上




图 10 不同程度缺失模型的修复补全效果对比




图 11 5 种网络在 ShapeNet 数据集^[20]上的修复补全效果对比

的修复补全效果对比. 可以看出, PCN^[7], FoldingNet^[8]和 AtlasNet^[9]对缺失点云模型的修复补全效果并不理想, 存在噪点过多、细节缺失等问题, 如椅子腿的修复结果呈弯曲或尖状, 桌子腿之间存在较多噪点等; CRN^[10]虽然能够在形状补全过程中利用对称进行修复, 但修复结果中通常存在点云分布不均匀、分布稀疏等现象, 如台灯灯杆、桌子腿等. 表4所示为在 ShapeNet数据集^[20]上, 不同点云修复网络的 CD 和 EMD 误差定量评估结果对比. 可以看出, 与 PCN^[7], FoldingNet^[8], AtlasNet^[9]和 CRN^[10]相比, 本文网络的 CD 误差更低, 其 EMD 误差亦低于其他网络; 与已有网络相比, 本文网络的平均 CD 误差、平均 EMD 误差分别低 16%~29%和 19%~65%; 经本文网络补全的点云形状更接近真实形状, 取得了更好的修复性能.

图12所示为本文网络与其他点云修复网络在 ModelNet数据集^[32]上的补全效果对比. 可以看出, 与其他网络相比, 本文网络可以对诸如飞机发动机、显示器底座、办公桌桌腿等形状细节进行更好的修复补全, 在点云修复过程中有效地恢复原始点云形状整体结构, 得到的点云模型中采样点分布均匀且能有效地保留形状细节. 表5所示为不同补全网络在 ModelNet数据集^[32]上的误差对比. 可以看出, 与已有网络相比, 本文网络的平均 CD 误差、平均 EMD 误差分别低 6%~41%和 31%~59%; 经本文网络补全的点云形状更接近真实形状, 取得了更好的修复性能.

4.5 本文网络的泛化性

为了验证本文网络对点云模型补全的有效性和泛化性能, 对 Stanford 大学图形学实验室提供的

表4 5种网络在 ShapeNet数据集^[20]上的误差对比

误差	点云模型	PCN ^[7]	FoldingNet ^[8]	AtlasNet ^[9]	CRN ^[10]	本文
CD	椅子	0.040 95	0.040 30	<u>0.034 81</u>	0.074 08	0.031 40
	汽车	0.034 74	0.033 42	0.032 62	<u>0.032 52</u>	0.031 00
	台灯	0.033 62	0.027 53	0.024 06	<u>0.015 65</u>	0.014 52
	桌子	0.039 88	0.034 41	0.034 47	0.027 16	<u>0.028 36</u>
EMD	椅子	<u>0.058 76</u>	0.061 84	0.163 78	0.069 49	0.053 11
	汽车	0.040 96	<u>0.037 63</u>	0.107 50	0.074 08	0.036 61
	台灯	<u>0.048 66</u>	0.051 52	0.108 43	0.057 57	0.031 88
	桌子	0.075 88	<u>0.063 51</u>	0.125 23	0.123 17	0.050 60

注: 加粗表示最优值, 下划线表示次优值.





图12 5种网络在 ModelNet数据集^[32]上的修复补全效果对比

表 5 5 种网络在 ModelNet 数据集^[32]上的误差对比

误差	点云模型	PCN ^[7]	FoldingNet ^[8]	AtlasNet ^[9]	CRN ^[10]	本文
CD	飞机	0.045 35	0.040 30	0.037 48	<u>0.032 32</u>	0.031 78
	长凳	0.066 48	0.070 51	0.059 27	<u>0.038 92</u>	0.028 46
	显示器	0.069 17	0.067 43	0.060 63	<u>0.047 60</u>	0.046 23
	办公桌	0.097 71	0.102 34	0.080 44	0.057 79	<u>0.058 51</u>
EMD	飞机	0.071 97	0.062 71	0.118 94	<u>0.069 50</u>	0.057 83
	长凳	0.104 64	<u>0.089 44</u>	0.137 29	0.091 86	0.036 42
	显示器	0.075 88	0.076 22	0.116 88	<u>0.066 81</u>	0.056 76
	办公桌	0.105 30	0.099 28	0.158 89	<u>0.087 85</u>	0.065 96

注. 粗体表示最优值, 下划线表示次优值.

复杂点云模型进行了修复补全实验. 图 13 所示为本文网络对 Armadillo 模型和茶杯模型的补全效果. 可以看出, 对于缺失身体和胳膊的 Armadillo 模型, 本文网络能有效地修补其缺失部分, 并恢复出较接近真实点云的模型细节; 对于缺失了一小半杯壁的茶杯模型, 本文网络能恢复较为平滑的茶杯边缘, 并且修复结果中点云分布较均匀. 表 6 所示为图 13 相应模型的修复误差对比. 可以看出, 本文网络能够对训练集以外的缺失点云模型进行有效的修复, 在恢复完整形状的基础上能保持其形状细节, 并生成均匀分布的点云模型, 表现出较好的泛化性能.



a. 输入点云 b. 本文网络 c. 真实模型

图 13 泛化性实验

表 6 复杂点云模型的修复误差对比

点云模型	CD	EMD
犰狳	1.234 47	2.458 39
茶杯	0.028 57	0.043 60

5 结 语

本文提出一种针对点云形状的双分支修复网

络. 首先利用全局结构恢复分支修复缺失点云整体结构; 然后利用局部细节补偿分支借助层次特征学习修复形状细节结构; 最后将 2 个分支的修复结果融合后, 经重采样得到完整点云形状. 实验结果表明, 本文网络能有效地恢复原始形状的结构细节信息, 生成采样点分布均匀、完整的精细模型; 该网络对模型噪声和不同程度的模型缺失均具有鲁棒性. 然而, 由于点云扫描数据中通常呈现大量对称特性或重复结构信息, 而模型对称性对点云修复的具有指导作用, 未来可考虑点云模型显著特征或重复结构对点云形状修复的辅助或指导作用.

参考文献(References):

- [1] Gross M, Pfister H. Point-based graphics[M]. San Francisco: Morgan Kaufmann Publisher, 2007
- [2] Varley J, DeChant C, Richardson A, *et al.* Shape completion enabled robotic grasping[C] //Proceedings of the IEEE/RSJ International Conference on Intelligent Robots and Systems. Los Alamitos: IEEE Computer Society Press, 2017: 2442-2447
- [3] Chen S H, Liu B A, Feng C, *et al.* 3D point cloud processing and learning for autonomous driving: impacting map creation, localization, and perception[J]. IEEE Signal Processing Magazine, 2021, 38(1): 68-86
- [4] Cadena C, Carlone L, Carrillo H, *et al.* Past, present, and future of simultaneous localization and mapping: toward the robust-perception age[J]. IEEE Transactions on Robotics, 2016, 32(6): 1309-1332
- [5] Miao Yongwei, Xiao Chunxia. Geometric processing and shape modeling of 3D point-sampled models[M]. Beijing: Science Press, 2014(in Chinese)
(缪永伟, 肖春霞. 三维点采样模型的几何处理和形状造型[M]. 北京: 科学出版社, 2014)
- [6] Liu Caixia, Wei Mingqiang, Guo Yanwen. 3D point cloud restoration via deep learning: a comprehensive survey[J]. Journal

- of Computer-Aided Design & Computer Graphics, 2021, 33(12): 1936-1952(in Chinese)
(刘彩霞, 魏明强, 郭延文. 基于深度学习的三维点云修复技术综述[J]. 计算机辅助设计与图形学学报, 2021, 33(12): 1936-1952)
- [7] Yuan W T, Khot T, Held D, *et al.* PCN: point completion network[C] //Proceedings of the International Conference on 3D Vision. Los Alamitos: IEEE Computer Society Press, 2018: 728-737
- [8] Yang Y Q, Feng C, Shen Y R, *et al.* FoldingNet: point cloud auto-encoder via deep grid deformation[C] //Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. Los Alamitos: IEEE Computer Society Press, 2018: 206-215
- [9] Groueix T, Fisher M, Kim V G, *et al.* A papier-mâché approach to learning 3D surface generation[C] //Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. Los Alamitos: IEEE Computer Society Press, 2018: 216-224
- [10] Wang X G, Ang Jr M H, Lee G H. Cascaded refinement network for point cloud completion[C] //Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. Los Alamitos: IEEE Computer Society Press, 2020: 790-799
- [11] Bond-Taylor S, Leach A, Long Y, *et al.* Deep generative modeling: a comparative review of VAEs, GANs, normalizing flows, energy-based and autoregressive models[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2022, 44(11): 7327-7347
- [12] Achlioptas P, Diamanti O, Mitliagkas I, *et al.* Learning representations and generative models for 3D point clouds[OL]. [2022-09-22]. <http://arxiv.org/abs/1707.02392v3>
- [13] Valsesia D, Fracastoro G, Magli E. Learning localized representations of point clouds with graph-convolutional generative adversarial networks[J]. IEEE Transactions on Multimedia, 2021, 23: 402-414
- [14] Yang G D, Huang X, Hao Z K, *et al.* PointFlow: 3D point cloud generation with continuous normalizing flows[C] //Proceedings of the IEEE/CVF International Conference on Computer Vision. Los Alamitos: IEEE Computer Society Press, 2019: 4541-4550
- [15] Qi C R, Yi L, Su H, *et al.* PointNet++: deep hierarchical feature learning on point sets in a metric space[C] //Proceedings of the 31st International Conference on Neural Information Processing Systems. Red Hook: Curran Associates Inc., 2017: 5105-5114
- [16] Yu L Q, Li X Z, Fu C W, *et al.* PU-Net: point cloud upsampling network[C] //Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. Los Alamitos: IEEE Computer Society Press, 2018: 2790-2799
- [17] Yu L Q, Li X Z, Fu C W, *et al.* EC-Net: an edge-aware point set consolidation network[C] //Proceedings of the 15th European Conference on Computer Vision. Heidelberg: Springer, 2018: 386-402
- [18] Wang Y F, Wu S H, Huang H, *et al.* Patch-based progressive 3D point set upsampling[C] //Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. Los Alamitos: IEEE Computer Society Press, 2019: 5958-5967
- [19] Qi C R, Su H, Mo K C, *et al.* PointNet: deep learning on point sets for 3D classification and segmentation[C] //Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Los Alamitos: IEEE Computer Society Press, 2017: 652-660
- [20] Tchapmi L P, Kosaraju V, Rezaatofghi H, *et al.* TopNet: structural point cloud decoder[C] //Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. Los Alamitos: IEEE Computer Society Press, 2019: 383-392
- [21] Xie H Z, Yao H X, Zhou S C, *et al.* GRNet: gridding residual network for dense point cloud completion[C] //Proceedings of the 16th European Conference on Computer Vision. Heidelberg: Springer, 2020: 365-381
- [22] Wen X, Li T Y, Han Z Z, *et al.* Point cloud completion by skip-attention network with hierarchical folding[C] //Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. Los Alamitos: IEEE Computer Society Press, 2020: 1939-1948
- [23] Huang Z T, Yu Y K, Xu J W, *et al.* PF-Net: point fractal network for 3D point cloud completion[C] //Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. Los Alamitos: IEEE Computer Society Press, 2020: 7662-7670
- [24] Alliegro A, Valsesia D, Fracastoro G, *et al.* Denoise and contrast for category agnostic shape completion[C] //Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. Los Alamitos: IEEE Computer Society Press, 2021: 4629-4638
- [25] Pan L, Chen X Y, Cai Z G, *et al.* Variational relational point completion network[C] //Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. Los Alamitos: IEEE Computer Society Press, 2021: 8524-8533
- [26] Wen X, Han Z Z, Cao Y P, *et al.* Cycle4Completion: unpaired point cloud completion using cycle transformation with missing region coding[C] //Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. Los Alamitos: IEEE Computer Society Press, 2021: 13080-13089
- [27] Xiang P, Wen X, Liu Y S, *et al.* SnowflakeNet: point cloud completion by snowflake point deconvolution with skip-transformer[C] //Proceedings of the IEEE/CVF International Conference on Computer Vision. Los Alamitos: IEEE Computer Society Press, 2021: 5499-5509
- [28] Wang Y D, Tan D J, Navab N, *et al.* Learning local displacements for point cloud completion[C] //Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. Los Alamitos: IEEE Computer Society Press, 2022: 1568-1577
- [29] Zhao Y H, Birdal T, Deng H W, *et al.* 3D point capsule networks[C] //Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. Los Alamitos: IEEE

- Computer Society Press, 2019: 1009-1018
- [30] Son H, Kim Y M. SAUM: symmetry-aware upsampling module for consistent point cloud completion[C] //Proceedings of the 15th Asian Conference on Computer Vision. Heidelberg: Springer, 2020: 158-174
- [31] Xie C L, Wang C X, Zhang B, *et al.* Style-based point generator with adversarial rendering for point cloud completion[C] //Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. Los Alamitos: IEEE Computer Society Press, 2021: 4619-4628
- [32] Wu Z R, Song S R, Khosla A, *et al.* 3D ShapeNets: a deep representation for volumetric shapes[C] //Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Los Alamitos: IEEE Computer Society Press, 2015: 1912-1920