

文章编号:1001-5078(2024)06-0870-08

· 激光应用技术 ·

基于点特征传递的电力设备部件激光点云补全网络

裴佳慧^{1,2}, 景超^{1,4}, 王慧民¹, 李雪薇¹, 张兴忠^{1,2}, 程永强^{1,3}

(1. 山西省能源互联网研究院, 山西 太原 030000; 2. 太原理工大学软件学院, 山西 晋中 030600;
3. 太原理工大学信息与计算机学院, 山西 晋中 030600; 4. 西安交通大学人工智能学院, 陕西 西安 710049)

摘要:针对电力场景下因激光雷达扫描范围有限、电力设备部件相互遮挡等因素导致电力设备部件点云缺失的问题,提出了基于点特征传递的电力设备部件激光点云补全网络 PPC-Net (Power Point cloud Complete Net)。该网络使用多尺度特征融合编码器提取不同尺度输入残缺点云的全局和局部特征,以避免多维度映射特征导致的电力设备部件细节特征丢失问题,并引入 EdgeConv 加强对点云邻域信息提取;在精细完整点云生成阶段提出 DT 模块整合父级点到子级点的特征传递,以保留生成点云的局部特征;设计平滑优化模块,经三级平滑采样算法输出分布均匀、表面平滑的电力设备部件完整点云。在自建电力设备部件点云数据集 ELE 及公开数据集 PCN 上实验表明,PPC-Net 对残缺的电力设备部件点云有较好的补全效果,并在一般形状点云上良好泛化性。

关键词: 图像处理; 点云补全; 电力设备部件; 多尺度特征; 点特征传递

中图分类号: TP242 **文献标识码:** A **DOI:** 10.3969/j.issn.1001-5078.2024.06.005

LiDAR point cloud completion network for power equipment components based on point feature transform

PEI Jia-hui^{1,2}, JING Chao^{1,4}, WANG Hui-min¹, LI Xue-wei¹, ZHANG Xing-zhong^{1,2}, CHENG Yong-qiang^{1,3}

(1. Shanxi Energy Internet Research Institute, Taiyuan 030000, China;
2. School of Software, Taiyuan University of Technology, Jinzhong 030600, China;
3. College of Information and Computer, Taiyuan University of Technology, Jinzhong 030600, China;
4. College of Artificial Intelligence, Xi'an Jiaotong University, Xi'an 710049, China)

Abstract: Aiming at the problem of defective point cloud of power equipment components due to limited scanning range of LiDAR and mutual occlusion of power equipment components in power scenario, a power equipment component LiDAR point cloud completion network Power Point Cloud Complete Net (PPC-Net) based on point feature transform is proposed in this paper. A multi-scale feature fusion encoder is used to extract global and local features of defective point clouds at different scales to avoid the problem of losing detailed features of power equipment components caused by multi-dimensional mapping, and EdgeConv is used to enhance the extraction of neighborhood information from point clouds. Then, the DT module is proposed to integrate feature transfer from parent to child points during the generation stage of fine and complete point clouds in order to preserve the local features of the generated point cloud.

基金项目: 山西省重点研发项目 (No. 202202130501008); 山西省重点研发计划项目 (No. 2022ZDYF100) 资助。

作者简介: 裴佳慧 (1997 -), 女, 硕士研究生, 主要从事三维计算机视觉与人工智能方面的研究。E-mail: 340066347@qq.com

通讯作者: 张兴忠 (1964 -), 男, 硕士, 教授, 硕士生导师, 主要从事计算机视觉与图像识别方面的研究。E-mail: 1659898176@qq.com

收稿日期: 2023-09-11; **修订日期:** 2023-10-27

Next, a smooth optimization module is designed to output a complete point cloud of power equipment components with uniform distribution and smooth surface through three-level smooth sampling algorithm. Experiments on the self-built power equipment component point cloud dataset ELE and the public dataset PCN show that PPC-Net has a good completion effect on defective power equipment component point clouds and good generalization on the general shape point clouds.

Keywords: image processing; point cloud completion; power equipment component; multiple scale feature; point feature transform

1 引言

电力场景环境复杂、人员安全管理难度大^[1],因此建立电力施工作业场所三维数字化模型,构建可视化实时安全监控系统,对于维护电力系统安全稳定运行有着重要的意义。电力设备三维数字化模型的获取主要使用三维重建^[2]技术。随着三维计算机视觉技术^[3]的发展,点云作为一种描述物体三维形状的数据格式,在三维重建领域受到广泛应用。采用三维激光扫描仪扫描待建模的电力设备是当前获取点云数据的主要方式。

然而在采集点云数据时,由于激光雷达扫描角度的限制、电力设备部件表面材质的差异以及电力设备部件繁多、结构复杂导致的遮挡,导致获取到的点云总有一定程度的缺失,进而影响下游重建任务。因此,研究如何从残缺的电力设备部件点云中补全生成高质量的完整点云具有重要价值。

目前对于残缺点云,补全的方式主要是从已有部分推测其缺失的形状。自2017年Charles等人^[4]提出能用于直接处理点云数据的深度学习网络PointNet以来,深度学习逐渐成为点云补全任务的主流方法。这种方法通过学习输入完整点云的特征,训练出能够补全对应残缺点云的模型。Yang等^[5]提出了一种基于折叠的点云自编码器网络FoldingNet,其补全点云的方式为在点云表面曲面上叠加二维网格,其局限性在于难以还原具有局部特殊结构的物体形状。Yuan等^[6]提出了基于深度学习的点补全网络(Point completion network, PCN),采用编码器-解码器结构,首先使用编码器提取点云的全局特征向量,然后在解码器中使用该向量实现从粗略到精细的补全,但对物体细微结构特征提取不够完全。Huang等人^[7]提出了点云分形网络(Point fractal network, PF-Net),其中设计了一种新的多分辨率编码器,能够在特征提取过程中融合多级特征以减少特征损耗,使补全后的点云更加精细。但其解码器只生成预测出的缺失部分点云,导致拼接成的完整点云存在间隙。Peng等人^[8]提出雪花

网络Snowflakenet,其核心模块为雪花点反卷积(Snowflake Point Deconvolution, SPD)。该网络在生成粗糙的完整点云基础上,使用Skip-Transformer整合局部形状上下文信息,精细还原局部细节特征,对于残缺点云有良好的补全效果,但对于形状不规则、结构复杂度高的电力设备部件点云的补全,其效果仍有一定的提升空间。

综合上述问题和思路,本文提出了一种基于点特征传递的电力设备部件激光点云补全网络PPC-Net。该网络整体采用端到端的思想,针对电力设备部件局部结构复杂的特点,首先将残缺点云输入多尺度特征融合编码器(Multi-scale Feature Fusion Encoder, MFFE),使用最远点采样法^[9](Farthest Point Sampling, FPS)获取三种不同尺度点云^[10-11]用于特征提取,以充分保留原始点云结构信息,并采用联合全局特征提取器(Concatenation Global Feature Extractor, CGFE)和EdgeConv并行提取全局与局部特征并融合;其次,将该融合特征输入精细点云生成模块。该模块分为种子点云生成和点级特征传递两部分,前者使用融合特征生成粗糙但相对完整的种子点云,在此基础上,后者引入反卷积机制^[8,12],在点云局部精细化过程中,保留父级特征的同时添加局部几何特征;最后,为了能够使补全后的点云更加精细,在精细点云生成模块后加入了平滑优化模块,采用三级平滑优化算法,充分保留点云细节特征的同时使生成的点云更加均匀平滑。经在自建电力设备部件点云数据集ELE与公共数据集PCN上的实验表明,本文提出的点云补全网络PPC-Net不仅在电力设备部件点云的补全上表现良好,在一般种类点云补全上也有较好的效果,具有良好的泛化性能。

2 本文方法

2.1 PPC-Net

本文提出的PPC-Net是一个端到端的电力设备部件点云补全网络,该网络由多尺度特征融合编码器、精细点云生成和平滑优化三个模块构成,以缺失

点云作为输入,输出补全后的高质量完整点云。网络整体结构如图1所示。




图1 网络整体结构图

Fig. 1 Overall network structure

首先,将有 N 个点的残缺点云 P 输入多尺度特征融合编码器中,得到一个大小为 $1 \times C$ 的描述残缺点云 P 的特征向量 V ,其中聚合了该点云的全局结构和详细的局部模式。然后再将 V 分别输入精细点云生成模块中。该模块有两个分支模块,其中一个分支是种子点云生成模块,用于生成粗糙但相对完整的种子点云;另一个分支是点级特征传递模块,用于在上述种子点云的基础上,通过点级特征的层层传递进一步精细化补全点云。特征向量 V 经种子点生成模块生成一个粗略的种子点云 P_s ,作为最后生成的精细完整点云的“骨架”;再将 P_s 与最初输入的残缺点云 P 连接,并使用 FPS 将合并后的点云下采样得到有 N_0 个点的点云 P_0 。同时,将 V 输入点级特征传递模块中,得到点偏移量 ΔP_0 ;再将 P_0 与 ΔP_0 按点逐位相加,得到初步生成的精细点云 P_c ;再将其送入平滑优化模块,最终得到高质量的补全点云 P_q 。

2.2 多尺度特征融合编码器

为了充分利用电力设备部件点云中丰富多样的关键特征信息,本文提出了一个多尺度特征融合编码器提取并融合多尺度输入点云全局和局部特征信息。其结构如图2所示。

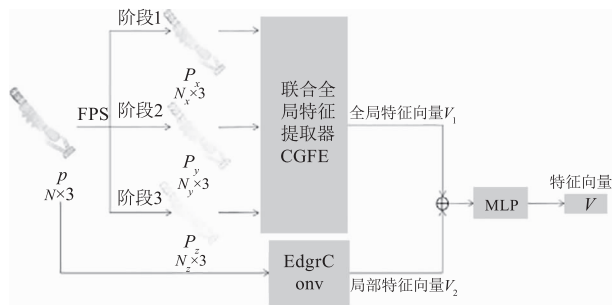


图2 多尺度特征融合编码器 MFFE 结构图

Fig. 2 Structure of multi-scale feature fusion encoder

MFFE 的输入为一个缺失点云 P ,为提取其多尺度全局特征,使用 FPS 降采样为 3 种不同尺度缺失点云,分别输入 CGFE 提取并融合得到全局特征向量 V_1 ;同时将 P 输入 EdgeConv^[13] 模块以提取局

部特征向量 V_2 ;最后,经多层感知机 (Multi Layer Perceptron, MLP) 得到融合全局与局部特征的特征向量 V 。

2.2.1 联合全局特征提取器

为了降低逐层升维全局特征提取时造成的细节损失,受 PFNet 多分辨率编码器 MRE 启发,在多尺度特征融合编码器模块中,设计了联合全局特征提取器 CGFE 提取多尺度输入点云的全局特征。其结构如图3所示。




图3 联合全局特征提取器结构图

Fig. 3 Structure of concatenation global feature extractor

首先,将经最远点采样后的不同尺度点云 P_x, P_y, P_z 使用门控多层感知机 (gating Multi Layer Perceptron, gMLP)^[14] 映射到不同的维度 (64, 128, 512, 1024),并在每一个维度上进行平均池化 (avgpool) 操作以增强对点云整体架构信息的提取;其次,拼接 (concatenation) 得到对应尺度的通道数为 1728 的特征向量 V_x, V_y, V_z ;最后,为了更加兼顾整体的结构,将上一步得到的不同尺度的特征向量逐点求和,得到最终的全局特征向量 V_1 ,其计算公式如下:

$$V_x = \text{concat}(\text{AP}(\text{GMLP}(P_x))), x = a, b, c \quad (1)$$

$$V_1 = V_a \oplus V_b \oplus V_c \quad (2)$$

其中, concat 表示拼接操作; AP 表示平均池化操作; \oplus 为逐点求和计算。

2.2.2 EdgeConv 模块

EdgeConv 模块由 Wang 等提出,是一种通过构建局部邻域图来获取点与邻近点之间的边特征,并聚合边特征以更新该点的特征值的方法。而且,在每层中,其局部邻域图由距离度量方式动态选择每个节点的邻域构成,因此它能够在保持点的排列不变性的同时捕获局部邻域信息。本文将 EdgeConv 用于点云局部特征提取使用 EdgeConv 以获取点云的局部特征向量 V_2 ,公式如下:

$$V_2 = \text{EdgeConv}(P) \quad (3)$$

再使用 MLP 聚合 V_2 与全局特征向量 V_1 ,得到最终的特征向量 V ,公式如下:

$$V = \text{MLP}(V_1 \oplus V_2) \quad (4)$$

2.3 精细点云生成模块

为了恢复点云局部特征,生成精细完整的补全点云,本文设计了精细点云生成模块,由种子点云生成模块与多阶段点级特征传递模块两部分构成。其具体结构如图4所示。




图4 精细点云生成模块结构图

Fig.4 Structure of fine point cloud generate module

其中,上半部分完成的功能是种子点云,也就是初步的粗糙完整点云的生成,下半部分实现精细化补全点云的功能。这两部分输入都是融合了全局和局部特征的特征向量V,但其并不能直接作为精细点云生成模块的输入。因此,在输入种子点生成和第一阶段点级特征传递模块之前,需要使用反卷积机制对V上一步提取的特征进行拆分。

在完整精细点云的生成过程中,种子点云 P_s 与输入点云拼接,并与经点级特征传递计算出的点偏移 ΔP_0 逐点求和,生成第一阶段完整点云。后续阶段,父级特征由上一阶段点云经PointNet提取的逐点特征替代,点偏移 ΔP_i 也与上一阶段 P_{i-1} 逐点相加。经过三个传递阶段,最终得到完整点云 P_4 。即为补全完整的点云 P_c ,公式如下:

$$P_c = P_i = P_{i-1} \oplus \Delta P_i, i = 0, 1, 2, 3, 4 \quad (5)$$

2.3.1 种子点云生成模块

该模块的目的是生成一个较为粗糙但相对完整的种子点云 P_0 ,其中包含了目标形状的几何形状与结构。特征向量V作为集合了全局和局部特征的输入点云特征描述,让其能够成为后续补全点云的依据。具体的种子点生成是通过引入反卷积机制实现的,其能够将父级特征逐点拆分为多个子级特征,从而捕获点云中现有的和缺失的结构特征。因此将V作为父级特征进行反卷积计算,得到的子级特征 v_1 再与复制多次的V拼接,就能使用共享的MLP预测出粗糙的种子点云 P_s 。将 P_s 与输入的残缺点云P拼接,再使用最远点采样将合并后的点云降采样到 P_0 ,就得到了种子点云。其公式为:

$$v_1 = \text{deconv}(V) \quad (6)$$

$$P_s = \text{SMLP}(\text{concat}(v_1, \text{repeat}(V))) \quad (7)$$

$$P_0 = \text{FPS}(\text{concat}(P, P_s)) \quad (8)$$

2.3.2 点级特征传递模块

该模块的目的是通过计算点偏移量实现点级特征的逐级传递,以完成基于种子点云的点云精细化补全。整体的点级特征传递分为三个阶段。首先,将经反卷积得到的子级特征 v_1 输入DT模块中,该模块整合子级特征与前一步的特征传递模式 k_i (第二阶段后加入),得到整合后的形状上下文信息 m_1 。其次,反卷积计算 m_1 ,就得到拆分特征图 h_1 ,将其与复制多次的 m_1 拼接并使用共享MLP融合,就得到这一阶段的偏移特征 k_1 。在此基础上,再通过第二次共享MLP,得到这一阶段的偏移量 ΔP_1 ;最后,将 ΔP_1 与输入的种子点云 P_0 相加,就获得第一阶段的精细点云 P_1 。第一阶段完成后,使用PointNet网络提取 P_1 的逐点特征作为下一阶段的子级特征 v_2 ,再与前一步得到的特征传递模式 k_1 输入到DT中重复前一阶段的生成。

为了整合前一步的特征传递模式用于下一阶段,并使生成的缺失点云彼此之间不重叠,本文借鉴Snowflakenet,提出了一种反卷积Transformer结构DT(Deconv-Transformer)模块用来作为前后点特征传递阶段的连接器。它以每一阶段的子级特征 v_i 和上一阶段的偏移特征 k_{i-1} 作为输入,得到形状上下文信息 m_i ,其结构如图5所示。




图5 DT模块结构图

Fig.5 Structure of DT module

其公式为:

$$m_i = \text{DT}(v_i, k_{i-1}) \quad (9)$$

DT模块分为两个部分整合子级特征 v_i 与偏移特征 k_i 。第一部分首先将它们拼接起来,然后将得到的特征向量输入MLP生成包含了先前点传递特征向量的 v_j 。在第二部分,为了进一步聚合形状上下文信息,DT模块使用 v_i 与 k_i 估计每一个点与其K近邻点之间注意力向量 a_i ,表示对先前点特征传递信息的关注程度。其计算公式如下:

$$a_i = \frac{\exp(\text{MLP}(v_i \ominus k_{i-1}))}{\sum_{i=1}^K \exp(\text{MLP}(v_i \ominus k_{i-1}))} \quad (10)$$

⊖代表逐元素相减计算。

整体的形状上下文信息 m_i 的计算公式如下

$$m_i = v_j \oplus \sum_{i=1}^K a_i \odot v_j \quad (11)$$

其中, \odot 代表哈达玛积计算。

通过点级特征传递模块,将种子点云中的点作为父级点,并通过 DT 模块融合历史偏移特征以及子级特征信息得到形状上下文信息,再层层传递到生成的点云子级点中,从而确保在精细完整点云的生成过程中,保留全局特征的同时不丢失局部细节信息。

2.4 平滑优化模块

上述生成的完整点云存在密度分布不均匀,表面不平滑的问题,这会导致基于该点云表面重建出的模型表面有空洞,缝隙。因此对生成的完整点云进行均匀化、平滑化处理是得到一个高质量点云的有效手段。因此本文设计了平滑优化模块处理以上问题。平滑处理模块由三级点云处理模块组成,首先将生成的完整点云 P_c 输入第一级泊松盘下采样^[15]模块中,以去除点云中距离过于相近的点;之后将处理过的点云输入第二级点云最远点采样模块中,得到能够反映原始点云形状的均匀点云;再将该均匀点云输入第三级移动最小二乘法^[16]平滑模块中,在点云表面拟合曲面操作,使点云表面更平滑。经过上述三级处理,得到最终的高质量完整点云 P_q 。图 6 为平滑优化模块结构图。



图 6 平滑优化模块结构图

Fig. 6 Structure of smooth optimization module

在平滑优化模块中,经多尺度特征融合编码器、精细点云生成模块生成的完整点云经过三级采样平滑处理,就得到表面平滑的高质量点云,可支撑以该点云为基础的三维重建工作。









3 实验结果与分析

3.1 数据集来源

实验使用的数据集是自建电力设备部件点云数据集 ELE 与从 ShapeNet 数据集^[17]派生的 8 个类别形状的子集 PCN。ELE 数据集根据 PCN 数据集的格式构建,整体分为测试集、训练集与验证集三部分,包含完整与其对应残缺点云。该数据集制作使用 3dmax 2023 软件,采集电力设备部件模型表面点作为训练集、测试集、验证集点云,种类包含瓷瓶、针式绝缘子、悬式绝缘子、套管 4 种电力设备部件。表 1 为 ELE 数据集图示。

表 1 ELE 数据集图示

Tab. 1 ELE dataset diagram

种类	瓷瓶	套管	悬式绝缘子	针式绝缘子
模型				
点云				
数量	260	665	680	434

3.2 损失函数与评价指标

使用倒角距离 CD (Chamfer Distance)^[18] 作为主要损失函数,CD 与地移距离 EMD (The Earth Mover's Distance)^[19] 共同作为衡量补全后点云质量的评价指标。倒角距离 CD 是生成点云 Y 与真实点云 X 之间平均最近平方距离,CD 的值越小,表示生成点云和输入点云之间的差别越小。CD 的计算公式如下:

$$L_{CD}(X, Y) = \frac{1}{X} \sum_{x \in X} \min_{y \in Y} \|x - y\|_2^2 + \frac{1}{Y} \sum_{y \in Y} \min_{x \in X} \|y - x\|_2^2 \quad (12)$$

相比 CD 用来衡量两个点云之间的全局结构差异,地移距离 EMD 用来度量两个点云的分布均匀度差异,EMD 越小,表示点的分布更均匀。EMD 的计算公式如下:

$$EMD(X, Y) = \min_{\varphi: X \rightarrow Y} \frac{1}{|X|} \sum_{x \in X} \|x - \varphi(x)\|_2 \quad (13)$$

为了明确地约束在种子点云生成和随后的点级特征传递过程中产生的点云质量,本文将输入的原始残缺点云 P 降采样到与 P_0, P_1, P_2, P_3 和 P_4 相同的采样密度,将完整损失定义为粗糙种子点云 P_s 与这几种点云 CD 损失之和,公式表示如下:

$$L_{\text{completion}} = L_{CD}(P_s, P'_s) + \sum_{i=1}^3 L_{CD}(P_i, P'_i) \quad (14)$$

其中, P'_s, P'_i 表示 P_s, P_i 对应的具有相同点数的真实值完整点云。

3.3 对比实验分析

为了验证本文提出的网络模型对残缺电力设备部件点云的补全能力以及对一般物体形状点云补全的泛化性,在自建数据集 ELE 与公开数据集 PCN 上与现有的深度学习点云补全方法对比实验,包括 PCN^[6]、PoinTr^[20]、Snowflakenet^[8]、PFNet^[7] 和

GRNet^[21],将其结果定量分析并部分可视化展示。

3.3.1 定量分析

表2、3是不同的点云补全网络在自建数据集ELE上瓷瓶、针式绝缘子、悬式绝缘子、套管4类电力设备部件点云上CD和EMD实验结果对比,可看出相较其他网络,PPC-Net在所有的类别上平均CD与EMD都是最低的,其均值达到了8.25与3.35,相比Snowflakenet降低了约6.8%与8.0%,更适用于电力设备部件点云补全领域。

表2 不同方法在ELE数据集上CD($\times 10^{-3} \cdot \text{cm}$)

Tab.2 Different methods on the ELE dataset

CD($\times 10^{-3} \cdot \text{cm}$)

方法	平均	瓷瓶	针式绝缘子	悬式绝缘子	套管
PCN	12.60	13.64	12.24	14.98	9.55
GRNet	11.57	14.59	10.23	12.58	8.86
PFNet	10.08	8.54	9.66	10.53	11.60
PoinTr	9.92	9.55	10.03	10.45	9.66
Snowflakenet	8.85	9.86	9.85	8.31	7.37
Ours	8.25	8.69	9.63	7.66	7.02

表3 不同方法在ELE数据集上EMD($\times 10^{-2} \cdot \text{cm}$)

Tab.3 Different methods on the ELE dataset

EMD($\times 10^{-2} \cdot \text{cm}$)

方法	平均	瓷瓶	针式绝缘子	悬式绝缘子	套管
PCN	4.87	4.38	6.21	5.25	3.65
GRNet	4.59	3.64	5.06	5.60	4.05
PFNet	4.69	3.99	4.85	5.02	4.88
PoinTr	4.65	4.02	4.65	4.93	5.03
Snowflakenet	3.64	3.54	3.45	4.57	2.98
Ours	3.35	2.86	3.39	4.38	2.76

表4、表5为不同点云补全网络与本文提出的PPC-Net网络在公开数据集PCN上的CD和EMD实验结果对比。从表4中可以看出,在Plane, Car, Chair, Table这4个类别上,PPC-Net的CD指标最低,且CD均值达到7.06,优于其他网络,相比Snowflakenet降低了约2.1%。由表5可知,在Plane, Cab, Car, Chair, Boat这5个类别上,PPC-Net的EMD指标优于其他网络,达到1.51,相比Snowflakenet降低约3.3%。表明本网络在一般形状补全上有一定的泛用性。

3.3.2 补全结果部分可视化展示

可视化实验结果如图7、8所示,图7展示了在自建电力设备部件点云数据集ELE四个类别上的可视化结果,图8展示了在公开数据集PCN上Plane, Car, Table, Chair类别上的可视化结果,GT

表示基准点云。可以看出,由于PCN在补全点云时主要关注的是全局特征,因此不可避免地丢失一些细节特征,导致整体点云轮廓过于平滑,如瓷瓶与Plane类别中,仅还原出主要几何形状,对于局部轮廓还原不够清晰。PFNet补全点云时,待补全部分是单独生成的,完整点云需要拼接生成点云与输入点云获得,因此会有拼接的缝隙存在,如套管类别出现了较为明显的缝隙。由于Snowflakenet是通过逐点分裂的方式补全点云的,所以补全的形状会出现一些局部聚合的问题,导致点云分布不均,如悬式绝缘子点云中部分边缘点云过密,Chair类别中有部分空洞出现。PPC-Net在避免以上缺点的情况下还能够适当将点云轮廓清晰化以还原细节,如针式绝缘子、Car等类别点云轮廓相比其他网络补全结果较为清晰,表现了其优秀的局部还原能力。

表4 不同方法在PCN数据集上CD($\times 10^{-3} \cdot \text{cm}$)

Tab.4 Different methods on the PCN dataset

CD($\times 10^{-3} \cdot \text{cm}$)

方法	PCN	GRNet	PFNet	Pointr	Snow	Ours
平均	9.64	8.83	9.45	8.38	7.21	7.06
Plane	5.50	6.45	5.01	4.75	4.29	4.23
Cab	22.70	10.37	10.58	10.47	9.16	9.26
Car	10.63	9.45	10.23	8.68	8.08	7.38
Chair	8.70	9.41	9.14	9.39	7.89	7.07
Lamp	11.00	7.96	10.77	7.75	6.07	6.33
Couch	11.34	10.51	12.42	10.93	9.23	9.28
Table	11.68	8.44	9.29	7.78	6.55	6.43
Boat	8.59	8.04	8.15	7.29	6.40	6.48

表5 不同方法在PCN数据集上EMD($\times 10^{-2} \cdot \text{cm}$)

Tab.5 Different methods on the PCN dataset

EMD($\times 10^{-2} \cdot \text{cm}$)

方法	PCN	GRNet	PFNet	Pointr	Snow	Ours
平均	2.14	1.99	1.89	1.76	1.53	1.48
Plane	2.43	1.38	1.58	0.94	0.97	0.97
Cab	1.89	2.13	2.05	1.99	1.75	1.53
Car	2.74	1.92	1.95	1.85	1.67	1.55
Chair	2.2	2.13	1.82	1.89	1.61	1.53
Lamp	2.38	2.15	1.65	1.74	1.42	1.5
Couch	2.06	2.47	2.04	2.24	2.01	2.04
Table	1.24	1.85	1.65	1.93	1.31	1.28
Boat	2.21	1.88	2.34	1.53	1.51	1.45

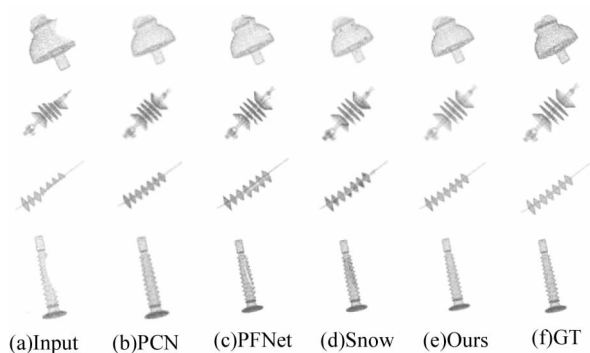


图 7 ELE 数据集补全结果可视化

Fig. 7 Visualization of ELE dataset completion results

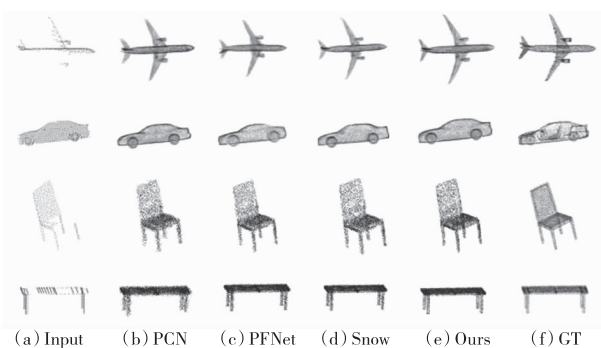


图 8 PCN 数据集补全结果可视化

Fig. 8 Visualization of PCN dataset completion results

3.4 消融实验

为进一步证明本文在多尺度特征融合编码器中加入的 EdgeConv 与 gMLP、精细点云生成模块提出的点级特征传递模块,以及提出的平滑优化模块的有效性,在自建的 ELE 数据集上进行五类消融实验。

表 6 为 ELE 数据集不同类别消融实验结果。对于多尺度特征融合编码器模块,由于 PCN、SnowflakeNet 等网络中特征提取模块使用的是 PointNet++ 中的三层特征提取,因此消融实验 [A] 中将本文提出的模型中多尺度特征融合编码器模块替换为该三层提取方法,并在 [B] 中将该模块替换为 MLP。在消融实验 [C] 中,联合全局特征提取器部分将 gMLP 替换为 MLP。对于精细点云生成模块, [D] 将本文提出模型中的点级特征传递模块替换为 SnowflakeNet 的 SPD 模块。对于平滑优化模块,由于原始模型并没有这个模块,因此 [E] 中直接删除这一部分,仅将 P_3 作为最后的补全点云输出。

由消融实验结果可知,替换删除模块之后的 CD 与 EMD 平均值均大于本文提出网络得到的 CD 值 8.29, EMD 平均值 3.36, 因此只有本文提出的模块全部存在时,网络的补全能力才会达到最佳状态。

表 6 ELE 数据集不同类别消融实验结果

Tab. 6 Results of ablation experiments for different categories in the ELE dataset

类别	描述	CD/ ($\times 10^3 \cdot \text{cm}$)	EMD/ ($\times 10^{-2} \cdot \text{cm}$)
[A]	MFFE 替换为 Pointnet ++	8.78	4.97
[B]	MFFE 替换为 MLP	9.50	6.65
[C]	CGFE 中 gMLP 替换 MLP	8.76	5.88
[D]	点级特征传递模块替换 SPD	8.33	3.49
[E]	删除平滑优化模块	10.20	7.66

4 结论

针对目前在电力场景下激光雷达扫描范围有限、材质反射率不同导致的点云数据缺失的问题,本文提出了一种基于点特征传递的电力设备部件激光点云补全网络。针对电力设备结构复杂的特征,在多尺度特征融合编码器模块中加入了 gMLP 和 EdgeConv 模块提取全局和局部特征并融合,提升了对于输入点云的局部特征信息提取效果,并在精细点云生成过程中加入点级特征传递模块,提高补全点云的局部细节还原程度。为了提升补全点云的质量,加入了平滑优化模块平滑化处理补全后的点云,从而为后续的使用该点云进行三维重建等下游工作提供支撑。由于自建数据集 ELE 中电力设备部件点云种类较少,导致本补全网络在使用范围上有一定的局限性,下一步将着手扩充点云数据集的种类和数量,以提高网络在电力设备部件点云补全领域的泛用性。

参考文献:

- [1] Wu Jian, Shan Bo, Han Yicheng, et al. Distributed physical structure model of substation high voltage equipment [J]. Laser & Infrared, 2023, 53(5): 670-676. (in Chinese)
吴健, 单波, 韩义成, 等. 变电站高压设备分布式物理化结构模型[J]. 激光与红外, 2023, 53(5): 670-676.
- [2] Liu Xiangyu, Wang Jian, Chang Qingfa, et al. Fast 3D reconstruction of point cloud based on improved greedy projection triangulation algorithm [J]. Laser & Infrared, 2022, 52(5): 763-770. (in Chinese)
刘翔宇, 王健, 常清法, 等. 改进贪婪投影三角化算法的激光点云快速三维重建[J]. 激光与红外, 2022, 52(5): 763-770.
- [3] Guo Yulan, Wang Hanyun, Hu Qingyong, et al. Deep learning for 3D point clouds: a survey [J/OL]. <http://arxiv.org/abs/1912.12033>.

- [4] Qi C R, Su H, Mo K, 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, July 21 – 26, 2017, Honolulu, HI, United States. New York: IEEE. 2017: 652 – 660.
- [5] Yang Y Q, Feng C, Shen Y, et al. Foldingnet: point cloud auto-encoder via deep grid deformation [C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. 2018: 206 – 215.
- [6] Yuan W, Khot T, Held D, et al. PCN: Point completion network [C]// 2018 International Conference on 3D Vision, September 5 – 8, 2018, Verona, Italy. New York: IEEE. 2018: 728 – 737.
- [7] Huang Z, Yu Y, Xu J, 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, June 14 – 19, 2020, Seattle, United States. New York: IEEE, 2020: 7662 – 7670.
- [8] 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. Kuala Lumpur, Malaysia: IEEE, 2021: 5499 – 5509.
- [9] Qi C R, Yi L, Su H, et al. PointNet ++ : deep hierarchical feature learning on point sets in a metric space [C]// 2008 IEEE International Conference on Neural Information Processing Systems. Long Beach, CA, USA. Curran Associates Inc, 2017: 5105 – 5114.
- [10] Gao Hui, Yang Zhijing, Ling Wingkuen, et al. Point cloud completion network based on multienoders and residual-transformer [J]. Laser & Optoelectronics Progress, 2023, 60(2): 0210012. (in Chinese)
高辉, 杨志景, 凌永权, 等. 基于多编码器 and Residual-Transformer 的点云补全网络 [J]. 激光与光电子学进展, 2023, 60(2): 0210012.
- [11] Liu Xinpu, Ma Yanxin, Xu Ke, et al. Multi-scale transformer based point cloud completion network [J]. Journal of Image and Graphics, 2022, 27(2): 538 – 549. (in Chinese)
刘心溥, 马燕新, 许可, 等. 嵌入 Transformer 结构的多尺度点云补全 [J]. 中国图象图形学报, 2022, 27(2): 538 – 549.
- [12] Lu Chunmei, Yang Zhijing. Multistage refinement of deconvolution point cloud complementation network [J]. Computer Engineering and Applications, 2023, 59(17): 242 – 249. (in Chinese)
陆春媚, 杨志景. 多级精细化反卷积点云补全网络 [J]. 计算机工程与应用, 2023, 59(17): 242 – 249.
- [13] Wang Y, Sun Y B, Liu Z W, et al. Dynamic graph CNN for learning on point clouds [J]. ACM Transactions on Graphics, 2019, 38(5): 1 – 12.
- [14] Liu H X, Dai Z H, SO D R, et al. Pay attention to MLPs [EB/OL]. <https://arxiv.org/abs/2105.08050v1>, 2021 – 05 – 17.
- [15] Li Qiqi, Hua Xianghong, Zhao Bufan, et al. A method for scattered point cloud simplification based on curvature poisson disk sampling [J]. Bulletin of Surveying and Mapping, 2020, (S1): 176 – 180. (in Chinese)
李琪琪, 花向红, 赵不钊, 等. 一种基于曲率泊松碟采样的散乱点云精简方法 [J]. 测绘通报, 2020, (S1): 176 – 180.
- [16] Tang Zeyu, Gao Baolu, Dou Mingliang. Point clouds simplification algorithm based on weighted least squares surface fitting for curvature computation [J]. Computer Engineering and Design, 2019, 40(6): 1606 – 1610, 1659. (in Chinese)
唐泽宇, 高保禄, 窦明亮. 基于加权最小二乘法曲率计算的点云精简算法 [J]. 计算机工程与设计, 2019, 40(6): 1606 – 1610, 1659.
- [17] Angel X C, Thomas F, Leonidas G, et al. ShapeNet: an information-rich 3D model repository [EB/OL]. <https://arxiv.org/abs/1512.03012>.
- [18] Borgefors G. Hierarchical chamfer matching: a parametric edge matching algorithm [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 1988, 10(6): 849 – 865.
- [19] Rubner Y, Tomasi C, Guibas L J. The earth mover's distance as a metric for image retrieval [J]. International Journal of Computer Vision, 2000, 40(2): 99 – 121.
- [20] X Yu, Y Rao, Z Wang, et al. Pointr: diverse point cloud completion with geometry-aware transformers [C]// Proceedings of the IEEE/CVF International Conference on Computer Vision (ICCV), October 2021.
- [21] H Xie, H Yao, S Zhou, et al. GRNet: gridding residual network for dense point cloud completion [C]// European Conference on Computer Vision (ECCV), 2020.