

3D 点云形状补全 GAN

赵新灿 常寒星 金仁标

郑州大学信息工程学院 郑州 450001



摘要 在真实的扫描环境中,由于视线遮挡或技术人员操作不当,实际采集到的点云模型会存在形状不完整的问题。点云模型的不完整性会对后续应用产生严重的影响,因此提出 3D 点云形状补全 GAN 用于完成点云模型的形状补全。该网络的点云重建部分由 PointNet 中用于数据对齐的 T-Net 结构与 3D 点云 AutoEncoder 网络相结合,来完成预测和填充缺失数据,识别器采用 3D 点云 AutoEncoder 中的 Encoder 部分对补全 3D 点云数据与真实的 3D 点云数据进行区分。最后,在 ShapeNet 数据集中训练上述网络结构,对所训练的网络模型进行验证并与其他基准方法进行定性比较。从实验结果可以看出,3D 点云形状补全 GAN 可以将具有缺失数据的点云模型补全为完整的 3D 点云。在 ShapeNet 的 3 个子数据集 chair, table 以及 bed 上,相比基于 3D 点云 AutoEncoder 的方法,所提方法的 F1 分数分别提高了 3.0%, 3.3% 以及 3.1%, 相比基于体素 3D-EPN 的方法,所提方法的 F1 分数分别提高了 9.9%, 5.8% 以及 4.3%。

关键词 3D 点云; 形状补全; AutoEncoder; 生成对抗网络

中图分类号 TP391

3D Point Cloud Shape Completion GAN

ZHAO Xin-can, CHANG Han-xing and JIN Ren-biao

School of Information Engineering, Zhengzhou University, Zhengzhou 450001, China

Abstract In the real scanning environment, due to the occlusion of line of sight or improper operation of technicians, the actual point cloud model has incomplete shape. The incompleteness of point cloud model has a serious impact on subsequent applications. Therefore, this paper proposes a 3D point cloud shape completion generative adversarial networks to complete the shape completion of point cloud model. The point cloud reconstruction part of the network combines the T-Net structure used for data alignment in PointNet with the 3D point cloud AutoEncoder network to complete the prediction and fill in the missing data. The discriminator uses the Encoder part of the 3D point cloud AutoEncoder to distinguish the completed 3D point cloud data from the real 3D point cloud data. Finally, in the ShapeNet trained the above network structure, the trained network model is verified and compared with other benchmark methods qualitatively. From the experimental results, it can be seen that the 3D point cloud shape completion generation adversarial network can complete the point cloud model with missing data into a complete 3D point cloud. In ShapeNet's three sub-datasets chair, table, and bed, compared with the method based on 3D point cloud AutoEncoder, the F1 score is improved by 3.0%, 3.3% and 3.1%, and compared with the method based on the voxel 3D-EPN method, the F1 score is increased by 9.9%, 5.8%, and 4.3%, respectively.

Keywords 3D point cloud, Shape completion, AutoEncoder, Generative adversarial network

1 引言

真实物体的三维表示是三维视觉、机器人、虚拟现实与增强现实的核心工具。由于 3D 传感器(如 LiDAR, RealScene)在室内采集时经常受到光照和遮挡的影响,导致采集到的室内点云数据不完整。

对于不完整的 3D 室内点云数据,通常将其转化成单个 3D 模型的形状补全。3D 模型的形状补全在几何处理算法中具有悠久的历史,并且国内外研究学者已对其进行了深入的研究,针对不同的 3D 模型数据缺失的情况,使用不同的算法

进行了修复或补全,并且有的算法已在各大领域得到了广泛的应用。然而,即使这样,对于单个 3D 对象的补全仍存在许多问题。

最初,研究者在小孔填充方面给予了广泛的关注。Leong 等^[1-2]提出将空洞边界直接连接,但该方法仅适用于简易的较为平滑的空洞,并且未考虑修复的空洞边界与周围网格之间的关系;Pfeifle 等^[3]在对空洞进行边界直接连接的修复之后,增加了一个三角优化的过程,最终的效果以及修复后的空洞与周围网格之间的关系得到了很大的改善;许多国外研究者^[4]也运用加权分点曲面拟合的方法在空间上进一步优化采

收稿日期:2020-01-07 返修日期:2020-06-03 本文已加入开放科学计划(OSID),请扫描上方二维码获取补充信息。

基金项目:航空科学基金(2018ZC41002)

This work was supported by the Aeronautical Science Foundation of China (2018ZC41002).

通信作者:赵新灿(iexczhao@zzu.edu.cn)

样点的位置,从而达到孔洞修复的目的。上述几何处理算法针对小孔填充的问题取得了不错的成果,但对于3D模型的大面积形状补全则显得不切实际。

国内外研究者也常常利用数据库先验知识进行3D点云的形状补全。Yang等^[5]通过构建源模型形状数据库,然后在形状数据库中为待补全的三维模型找到与其相同的CAD模型,并将其与待补全模型对齐,来实现大面积的3D点云模型补全。Sung等^[6]将数据库先验知识与对称性检测的方法相结合,对从数据库中获得的基于部分的模型进行了操作。利用数据库先验知识的方法虽取得了不错的结果,并且已在工业界被广泛应用于零件维修等方面,但是该方法仍存在很大的局限性,需要针对真实世界的三维物体,制作出相同或相似的CAD模型。为了解决这个问题,Rock等^[7]提出了检索相似的深度图来预测缺失的体素,并采用泊松表面重建的方法将预测的体素转换为三维网格;Li等^[8]使用RGB-D图像从数据库中找到相似的模型,并将其变形完成形状合成。虽然数据库先验知识的方法能够完成较大面积的模型补全,但其主要限制仍是全局结构不容易被概括,而不能推广到任意的三维模型。

近年来,深度学习在三维模型的生成或形状补全方面都取得了突破性的进展。Wu等^[9]提出的3D GAN通过将随机潜在在矢量作为输入,来学习2D图像到3D模型的映射,该方法打开了对抗神经网络在3D方面的新篇章。Wang等^[10]提出了基于体素卷积神经网络的3D生成对抗网络(3D Encoder-Decoder Generative Adversarial Network, 3D-ED-GAN),该网络利用编码器将体素化的3D对象映射到概率潜在空间,再通过生成对抗网络(Generative Adversarial Networks, GAN)的生成器,根据潜在特征表示预测完整的体积对象。Yu等^[11]首次提出用于3D场景重建的3D-SceneGAN,该网络将上次迭代预测的场景重建结果和噪声向量预测的重建部分组合输入到生成器,进而生成3D场景,然后将生成的3D场景和真实的3D场景转换成2D图像送到识别器进行识别。Dai等^[12]提出完全卷积3D CNN来完成扫描场景的形状补全以及语义分割。虽然上述网络模型与传统方法相媲美甚至更好,但由于点云的无序性,上述方法往往将3D模型转换为体素或特定角度下的深度图等更为规整的格式进行训练处理,这造成需处理的数据量庞大,并且可能产生量化损失或投影损失。

综上,传统的非深度学习的方法通过手工方式制作相同或相似的CAD模型,从而根据缺失点云的局部特征完成与CAD模型的对齐,进而完成三维模型的形状修复。在实际扫描过程中,扫描的场景一般复杂多变,传统算法针对已知的场景虽有效,但实用性不高。深度学习的方法不需要测量三维模型尺寸并为其设计CAD模型,但由于点云的无序性和稀疏性,用于3D模型形状补全的深度学习通常将训练数据转换成体素表示,这样就易产生多余的体素数据,造成需处理的数据量庞大,从而导致计算量增大。

Qi等^[13-14]提出了PointNet和PointNet++网络,直接将3D点云数据作为网络的输入来完成点云模型的分割与识别,从而证实了深度学习在直接处理点云方面可以解决无序性和稀疏性的问题。Achlioptas等^[15]提出点云生成对抗网络和AutoEncoder网络将点云数据作为输入,学习三维点云的潜

在特征表示,并通过这些潜在特征重新映射生成三维点云。AutoEncoder网络虽具备学习3D点云数据点特征的能力,但仍存在一定的不足之处,即其只接受干净完整的点集进行训练,对于不完整的点云数据集虽具备形状补全能力,但补全效果欠佳。

针对上述问题,受生成对抗网络对于2D图像修复研究工作的影响以及PointNet处理点云方式的启发,本文提出将PointNet中的T-Net结构与点云AutoEncoder网络相结合,学习局部三维点云的潜在特征,利用该潜在特征预测完整的三维点云模型;接着,将AutoEncoder预测输出的完整点云和真实的标签3D点云一同输入到识别器中进行识别,以便进一步提高所训练的网络模型参数。上文提出的3D点云形状补全GAN的网络框架如图1所示。在ShapeNet数据集^[16]上对常见的3个室内类别(床、椅子和桌子)的实验可视化的结果显示,3D点云形状补全生成对抗网络能够完成缺失部分的形状补全。在ShapeNet数据集上,相比现有基准的方法,本文提出的网络模型形状补全能力得到了与之相媲美甚至更好的结果。

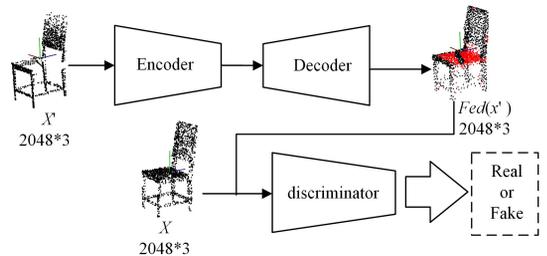


图1 3D点云形状补全GAN网络框架

Fig. 1 3D point cloud shape complements GAN network framework

2 3D点云形状补全GAN

2.1 点云数据预处理

ShapeNetCore是ShapeNet数据集^[16]中最大的子集,具有单个干净的3D模型、手动验证的类别以及对齐注释。本文使用ShapeNetCore中的桌子、椅子以及床3个室内类别的数据集,这3个数据集分别有8443个、6778个和254个三维CAD模型。将数据集的三维模型按照4:1的比例随机分为训练集和测试集。

ShapeNetCore数据集只提供网格格式的三维模型,因此,在数据输入网络之前需要对其进行预处理,将其转换成与三维传感器采集的数据非常接近的点云格式。3D点云形状补全对抗神经网络依赖于成对训练形式的监督,因此将训练集预处理分为完整点云数据集和缺失点云数据集两部分。

完整点云数据集的构造,使用PCL网格采样的方法^[17]对数据集中的三维模型进行均匀采样,生成以点云模型自身为坐标系的点云模型。

缺失点云数据集的构造,利用一个足够大的球体包围三维CAD模型建立一个球形包围盒,将虚拟深度相机均匀地架设在球面上,采集模型的多视角点云。为了保证数据采集分布的均匀性,首先在球形包围盒的内部生成一个正二十面体,然后在二十面体的中心点架设虚拟深度相机以采集CAD模型的单视角点云。虚拟深度相机采集CAD模型多视角点云的位置如图2所示。



图2 虚拟深度相机采集模型多视角点云图

Fig. 2 Virtual depth camera acquisition model multi view point cloud image

虚拟相机采集到的点云是位于相机坐标系下的坐标,而本文提出的网络输入要求是与完整点云模型处于同一个坐标系。因此,需要对缺失的点云数据集进行坐标变换,其坐标变换矩阵如式(1)所示:

$$\begin{bmatrix} x_o \\ y_o \\ z_o \\ 1 \end{bmatrix} = \begin{bmatrix} R_1 & R_2 & R_3 & 0 \\ R_4 & R_5 & R_6 & 0 \\ R_7 & R_8 & R_9 & 0 \\ T_x & T_y & T_z & 1 \end{bmatrix} \begin{bmatrix} x_c \\ y_c \\ z_c \\ 1 \end{bmatrix} \quad (1)$$

其中, T_x, T_y, T_z 表示物体的包围盒中心到虚拟深度相机坐标系平移的 x, y, z 轴的距离。 $R_1 - R_9$ 的表达式如下:

$$R_1 = \cos(\alpha)\cos(\chi)$$

$$R_2 = \cos(\alpha)\sin(\chi)$$

$$R_3 = -\sin(\beta)$$

$$R_4 = \sin(\alpha)\sin(\beta)\cos(\chi) - \cos(\alpha)\sin(\chi)$$

$$R_5 = \sin(\alpha)\sin(\beta)\sin(\chi) + \cos(\alpha)\cos(\chi)$$

$$R_6 = \sin(\alpha)\cos(\beta)$$

$$R_7 = \cos(\alpha)\sin(\beta)\cos(\chi) + \sin(\alpha)\sin(\chi)$$

$$R_8 = \cos(\alpha)\sin(\beta)\sin(\chi) - \sin(\alpha)\cos(\chi)$$

$$R_9 = \cos(\alpha)\cos(\beta) \quad (2)$$

其中, α, β, γ 表示分别绕相机坐标系下 x, y, z 轴的旋转角。

2.2 3D点云形状补全GAN网络

2.2.1 网络结构

3D点云形状补全对抗神经网络包括点云形状补全部分和识别器部分,其网络结构如图3所示。

点云形状补全网络部分基于 AutoEncoder 网络,包括编码器和解码器两部分。编码器由4层内核大小为1、步长为1的一维卷积层组成,用于学习将点云数据的点特征压缩成潜在空间向量。为加速收敛和避免过拟合,在每个卷积层后添加 ReLU 层和批量归一化层^[18],并在最后一层采用最大池化来解决点云的无序性问题。编码器的输入是 2048×3 的点云矩阵。但由于缺失点云数据集的形状与完整点云数据集不同,其成对训练的点云模型的坐标系存在略微的偏差,直接输入缺失点云数据集时,网络模型的收敛速度较慢。受 Point-Net 网络对齐点云方式的启发,本文在网络中加入了与其相似的 T-Net 结构,用于预测仿射变换矩阵并作用于输入点云的齐次坐标。相比 AutoEncoder 网络,加入 T-Net 结构的网络具有更好的性能。解码器结构有3个完全连接层,每层分别由256个、256个、6144 (2048×3) 个神经元组成,其目标是将潜在空间向量映射生成 2048×3 的完整点云。

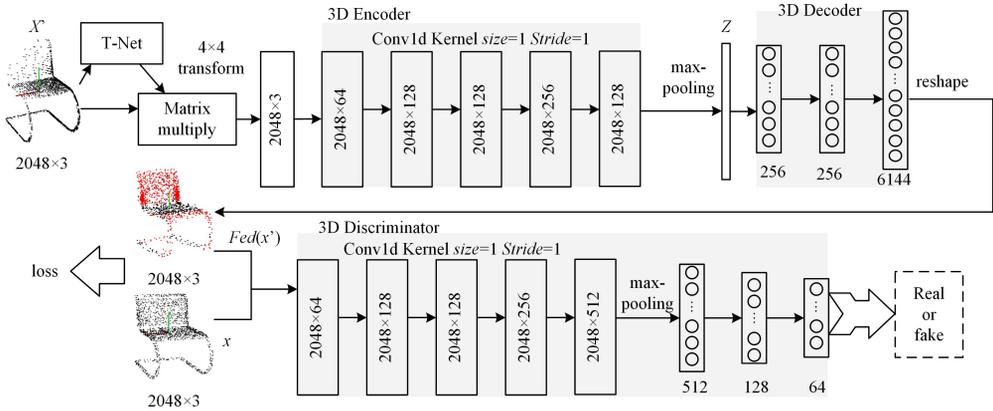


图3 3D点云形状补全GAN网络结构

Fig. 3 3D point cloud shape complements GAN network structure

识别器部分与 AutoEncoder 结构相同,不同的是识别器是用来判断输入的点云阵列是真实完整的点云还是形状补全过后的点云,而 AutoEncoder 则用来重组点云模型。在网络模型训练的过程中,由于识别器比生成器学得快,在每一层的后面采用 leaky ReLUs 代替 ReLU 和批量归一化层,避免过拟合并将最后全连接层的输出送入 sigmoid 神经元。

2.2.2 损失函数

类似于 3D-ED-GAN,网络的损失函数由两部分组成,分别为对抗网络损失函数 L_{GAN} 和重建损失函数 L_{recon} 。

生成对抗神经网络主要包括将潜在空间向量 Z 映射到数据空间 X 的生成器 G ,以及用于分类真实样本和生成样本的识别器 D 这两大部分。生成器 G 和识别器 D 是采用对抗博弈共同学习的深层网络, G 试图生成“真实”样本来迷惑 D ,

D 对真实样本与生成的样本进行区分。具体而言,GAN 网络的优化和求解的目标函数如式(3)所示:

$$\min_G \max_D (E_{x \sim p_{data}(x)} [\log D(x)] + E_{z \sim p_z(z)} [\log(1 - D(G(z)))] \quad (3)$$

其中, p_{data} 是数据分布, p_z 是噪声分布。

3D点云形状补全对抗生成网络利用编码器和解码器网络对对抗神经网络中的生成器 G 进行建模。这可以被视为一个条件 GAN,其中潜在分布采用从编码器-解码器中学习的潜在特征向量来代替传统 GAN 中的随机噪声向量 z 。因此,损失函数 L_{GAN} 通过重构式(3)导出,具体如下:

$$L_{GAN} = E_{x \sim p_{data}(x)} \log D(x) + E_{x' \sim p_{data}(x')} \log(1 - D(F_{ed}(x'))) \quad (4)$$

其中, $F_{ed}(x')$ 指缺失点云 x' 经过 Encoder-Decoder 生成完整

点云的过程函数, x' 是缺失的 3D 点云模型, x 为完整的 3D 点云模型。

Chamfer distance 是可微的, 与无序点集的置换不变度量相比计算更为高效。因此, 本文的重建损失 L_{recon} 由 Chamfer distance 定义。Chamfer distance 用于计算 $S_1 \subseteq R^3$ 子集中的每个点和 $S_2 \subseteq R^3$ 子集中最近邻之间的平方距离, 具体公式如下:

$$\begin{aligned} L_{recon} &= d_{CH}(S_1, S_2) \\ &= \sum_{x \in S_1} \min_{y \in S_2} \|x - y\|_2^2 + \sum_{y \in S_2} \min_{x \in S_1} \|x - y\|_2^2 \end{aligned} \quad (5)$$

因此, 本文提出的 3D 点云形状补全对抗神经网络的整体损失函数为:

$$Loss = \alpha_1 L_{GAN} + \alpha_2 L_{recon} \quad (6)$$

其中, α_1 和 α_2 是权重参数。

2.2.3 评价标准

本文的点云形状补全评价度量采用文献[19]提出的 Accuracy, Completeness 以及 F1 score。各个评价度量的定义如下。

(1) Accuracy。计算点云补全后每个点与标签点云中最近点的最小距离, 若最小距离小于阈值 0.03, 则将其统计为正确的匹配点, 其定义如下:

$$D(p, P_{comp}) = \min\{\|p - q\|, q \in P_{gt}\} \quad (7)$$

其中, P_{comp} 代表经过形状修复的点云, P_{gt} 代表标签点云, 且 $p \in P_{comp}$ 。

(2) Completeness 是统计 P_{gt} 中在阈值 0.03 的范围内, 与 P_{comp} 正确匹配的点数数量。

(3) F1 score 通过 Accuracy 和 Completeness 的平均值来定义。当 F1 score 等于 1 时, 证明补全的效果最完美; 反之, 效果最差。

2.3 训练参数的设置

3D 点云形状补全对抗神经网络采用批量为 50, $\beta = 0.5$ 的 Adam 优化算法来训练整个模型。在训练过程中, 识别器比生成器学得更快, 因此, 首先在只有重建损失的情况下单独训练编码器-解码器网络, 并将学习率设置为 5×10^{-5} , 单独训练 20 代。接着将识别器和编码器-解码器网络共同训练 100 代, 并设置编码器-解码器的学习速率为 10^{-4} , 识别器的学习率为 10^{-5} , 将 α_1 和 α_2 设定为 0.001 和 0.999。当共同训练时, 若每一代的最后一个批次中识别器的准确率不高于 80%, 则只更新识别器。

3 实验结果与分析

3.1 ShapeNet 测试集形状补全结果

本节将 ShapeNet 数据集的 80% 作为训练集, 20% 作为测试集, 并针对数据集常用的 3 个类别(桌子、椅子、床)单独训练其对应的网络模型, 然后在 ShapeNet 测试集上对所训练的网络模型进行评估比较。图 4 给出了 3D 点云形状补全生成

对抗网络缺失点云、完整点云以及补全后点云的结果图。由图 4 可以看出, 本文所训练的网络模型具备了根据不完整的点云预测完整点云的能力。实验结果也表明, 对于某些类别, 即使在缺失区域较大的情况下, 3D 点云形状补全对抗神经网络也可以产生合理的补全效果。

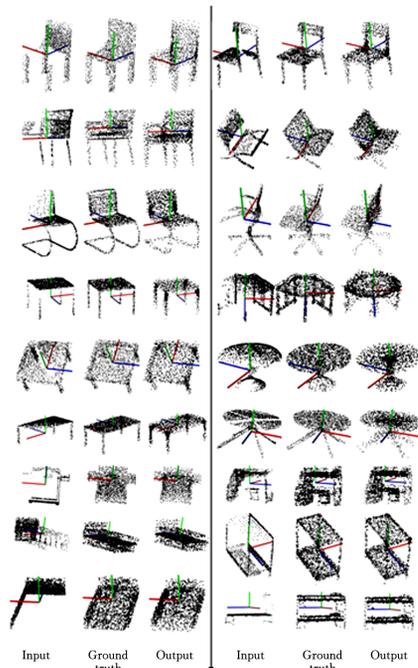


图 4 网络模型对 ShapeNet 中椅子、桌子和床补全后点云分辨率为 2048×3 的结果展示

Fig. 4 Results of point cloud resolution of 2048×3 after chair, table and bed completion in ShapeNet by network model

为了进一步评估本文提出的网络模型的形状补全能力, 本文在本文构造的数据集上用 2.2.2 节的评价度量将 3D 点云形状补全对抗神经网络与 AutoEncoder, 3D-EPN^[20] 以及 PCN^[21] 进行比较。本文将 3D-EPN 的距离场表示结果转换为曲面网格, 并从中均匀地采样 N 个点来计算基于点的度量, 其可视化对比结果如图 5 所示。3D 点云形状补全对抗神经网络的定量分析结果如表 1 所列。

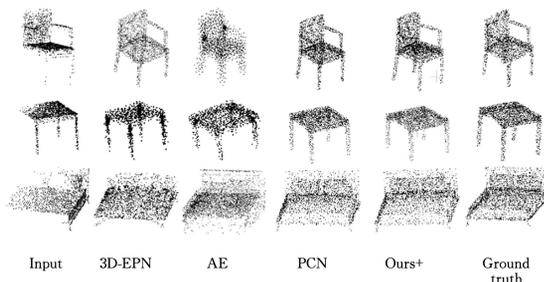


图 5 3D 形状补全 GAN 结果的对比

Fig. 5 Comparison results of 3D shape completion GAN

表 1 3D-EPN, AE 和 PCN 与本文提出的点云形状补全 GAN 的对比结果

Table 1 Comparison of 3D-EPN, AE, PCN and proposed point cloud shape completion network results

	3D-EPN			AE			PCN			Ours			Ours+(with T-Net)		
	Acc.	Comp.	F1	Acc.	Comp.	F1	Acc.	Comp.	F1	Acc.	Comp.	F1	Acc.	Comp.	F1
chair	52.3	64.6	58.5	69.1	61.7	65.4	77.6	75.2	76.4	71.5	62.4	67.0	72.3	64.5	68.4
table	58.5	72.1	65.3	71.3	64.2	67.8	80.9	77.4	79.2	72.6	65.5	69.1	74.9	67.3	71.1
bed	69.8	72.3	71.1	75.8	68.8	72.6	82.1	86.4	84.3	77.9	70.3	74.1	79.2	71.6	75.4

分析定性比较的实验结果可知,虽然本文提出的网络的 F1 分数低于 PCN 网络,但相比基于体素的 3D-EPN 方法以及点云 AE 网络,本文方法具有更高的准确率和覆盖率。

3.2 网络模型应用

本文使用 3D 点云形状补全生成对抗神经网络所训练的网络模型对仿真环境 Gazebo 所采集的缺失点云以及在真实场景中采用 RealSense 采集的 3D 点云进行了形状补全,实验结果分别如图 6 和图 7 所示。

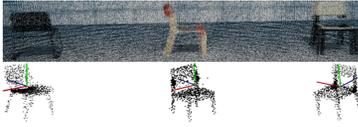


图 6 Gazebo 采集的点云补全的结果

Fig. 6 Point cloud completion results collected by Gazebo

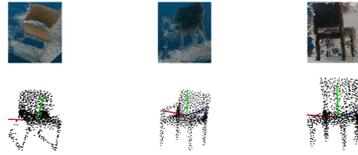


图 7 RealSense 采集的点云补全的结果

Fig. 7 Point cloud completion results collected by RealSense

结束语 针对 3D 点云模型的数据缺失问题,本文提出了一种基于 AutoEncoder 的形状补全方法。该方法可以学习缺失 3D 点云数据的点特征,然后将其压缩成潜在空间向量并且可以从该潜在空间向量映射生成一个完整的 3D 点云。为更好地训练该网络模型,利用对抗神经网络对抗博弈的原理,在 AutoEncoder 中添加了识别器,进一步提高了从潜在空间向量映射生成完整点云的能力。实验结果验证了本文提出的网络的有效性,并且相比点云 AutoEncoder 和 3D-PCN 等方法,其具有更好的重建能力以及更高的覆盖率。

参考文献

- [1] LEONG K F, CHUA C K, NG Y M. A study of stereolithography file errors and repair. Part 1. Generic solution[J]. The International Journal of Advanced Manufacturing Technology, 1996, 12(6): 407-414.
- [2] LEONG K F, CHUA C K, NG Y M. A study of stereolithography file errors and repair. Part 2. Special cases[J]. The International Journal of Advanced Manufacturing Technology, 1996, 12(6): 415-422.
- [3] PFEIFLE R, SEIDEL H P. Triangular B-splines for Blending & Filling of Polygonal Holes[C]// Graphics Interface. 1996: 186-193.
- [4] ISHIGAMI G, OTSUKI M, KUBOTA T. Path planning and navigation framework for a planetary exploration rover using a laser range finder[C]// Field and Service Robotics. Springer, Berlin, Heidelberg, 2014: 431-447.
- [5] YANG R, FENG Y Q, YUAN X J. Restoration of Fragmentary 3D Models Using Existing Models[J]. Journal of Computer-Aided Design & Computer Graphics, 2015(1): 98-105.
- [6] SUNG M, KIM V G, ANGST R, et al. Data-driven structural priors for shape completion[J]. ACM Transactions on Graphics (TOG), 2015, 34(6): 1-11.
- [7] ROCK J, GUPTA T, THORSEN J, et al. Completing 3d object shape from one depth image[C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. 2015: 2484-2493.
- [8] LI D, SHAO T, WU H, et al. Shape completion from a single rgbd image[J]. IEEE Transactions on Visualization and Computer Graphics, 2016, 23(7): 1809-1822.
- [9] WU J, ZHANG C, XUE T, et al. Learning a probabilistic latent space of object shapes via 3d generative-adversarial modeling [C]// Advances in Neural Information Processing Systems. 2016: 82-90.
- [10] WANG W, HUANG Q, YOU S, et al. Shape inpainting using 3d generative adversarial network and recurrent convolutional networks[C]// Proceedings of the IEEE International Conference on Computer Vision. 2017: 2298-2306.
- [11] YU C, WANG Y. 3D-Scene-GAN: Three-dimensional Scene Reconstruction with Generative Adversarial Networks[C]// ICLR (Workshop). 2018: 1-4.
- [12] DAI A, RITCHIE D, BOKELOH M, et al. Scancomplete: Large-scale scene completion and semantic segmentation for 3d scans [C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. 2018: 4578-4587.
- [13] 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. 2017: 652-660.
- [14] QI C R, YI L, SU H, et al. Pointnet++: Deep hierarchical feature learning on point sets in a metric space[C]// Advances in Neural Information Processing Systems. 2017: 5099-5108.
- [15] ACHLIOPTAS P, DIAMANTI O, MITLIAGKAS I, et al. Learning representations and generative models for 3d point clouds[J]. arXiv: 1707. 02392.
- [16] CHANG A X, FUNKHOUSER T, GUIBAS L, et al. Shapenet: An information-rich 3d model repository [J]. arXiv: 1512. 03012, 2015.
- [17] ALDOMA A, MARTON Z C, TOMBARI F, et al. Tutorial: Point cloud library: Three-dimensional object recognition and 6 dof pose estimation[J]. IEEE Robotics & Automation Magazine, 2012, 19(3): 80-91.
- [18] IOFFE S, SZEGEDY C. Batch normalization: Accelerating deep network training by reducing internal covariate shift[J]. arXiv: 1502. 03167.
- [19] CHEN X, CHEN B, MITRA N J. Unpaired Point Cloud Completion on Real Scans using Adversarial Training[J]. arXiv: 1904. 00069, 2019.
- [20] DAI A, RUIZHONGTAI QI C, NIEßNER M. Shape completion using 3d-encoder-predictor cnns and shape synthesis[C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. 2017: 5868-5877.
- [21] YUAN W, KHOT T, HELD D, et al. Pen: Point completion network[C]// 2018 International Conference on 3D Vision (3DV). IEEE, 2018: 728-737.



ZHAO Xin-can, born in 1972, Ph.D., associate professor. His main research interests include virtual reality (VR) and augmented reality (AR).