



# 基于生成对抗网络的点云形状保结构补全

缪永伟<sup>1\*</sup>, 刘家宗<sup>1</sup>, 陈佳慧<sup>1</sup>, 舒振宇<sup>2</sup>

1. 浙江理工大学信息学院, 杭州 310018

2. 浙江大学宁波理工学院计算机与数据工程学院, 宁波 315100

\* 通信作者. E-mail: ywmiao@zstu.edu.cn

收稿日期: 2019-05-11; 修回日期: 2019-07-25; 接受日期: 2019-09-17; 网络出版日期: 2020-04-17

国家自然科学基金 (批准号: 61972458, 61872321)、浙江省公益技术研究 (批准号: GG19F020006) 和浙江理工大学科研基金 (批准号: 17032001-Y) 资助项目

**摘要** 针对三维点云形状修复补全中难以保持形状精细结构信息的问题, 借助于生成对抗网络框架, 本文提出了一种自动修复补全三维点云形状的神经网络结构. 该网络由生成器和判别器构成. 神经网络的生成器采用编码器-解码器结构, 以缺失的三维点云形状作为输入, 首先通过输入变换和特征变换对齐输入点云数据的采样点位置与特征信息; 然后借助权共享多层感知器对各采样点提取局部形状特征并利用最大池化层与多层感知器编码提取出采样点的特征码字; 其次将采样点特征码字加上网格坐标数据, 解码器使用 2 个连续的三层感知器折叠操作将网格数据转变成点云形状的缺失补全数据; 最后将缺失补全数据与点云输入数据合并, 得到完整的三维点云形状. 神经网络的判别器则接收真实的完整点云形状数据和生成器生成的完整点云形状数据, 并利用与生成器相同的编码器结构判别出点云形状数据的真假并反馈以不断优化生成器, 最终使生成器生成足以“以假乱真”的点云形状数据样本. 实验表明, 针对形状缺失的稠密点云和稀疏点云数据, 本文方法在修复补全形状缺失部分的同时能有效保持输入点云形状的精结构信息.

**关键词** 生成对抗网络, 编码器-解码器结构, 点云数据, 形状补全, 折叠操作

## 1 引言

三维模型的数字化修复是计算机图形学与数字几何处理领域的重要问题, 其在数字化文物修复、数字化产品设计与制造、数字博物馆和虚拟场景漫游等行业得到普遍重视<sup>[1]</sup>. 在数字几何处理和 3D 计算机视觉中, 离散点云数据由于其数据获取容易、能够有效表示复杂三维形状、无需维护拓扑连接关系等优点得到广泛应用<sup>[2]</sup>.

点云数据主要有 2 种来源方式<sup>[1,2]</sup>: 一是利用传统激光扫描设备扫描获取离散点云数据, 但通常存在着设备价格高昂、扫描效率低、扫描数据质量不高等缺陷; 二是通过相机 (如立体相机、RGBD 深

**引用格式:** 缪永伟, 刘家宗, 陈佳慧, 等. 基于生成对抗网络的点云形状保结构补全. 中国科学: 信息科学, 2020, 50: 675–691, doi: 10.1360/SSI-2019-0096

Miao Y W, Liu J Z, Chen J H, et al. Structure-preserving shape completion of 3D point clouds with generative adversarial network (in Chinese). Sci Sin Inform, 2020, 50: 675–691, doi: 10.1360/SSI-2019-0096

度相机等) 获取场景信息, 并利用配准重建<sup>[3]</sup>等方法获得离散点云数据. 然而, 通过扫描或相机拍摄获取的数据通常会受到场景中物体之间相互遮挡、深度相机的传感器距离限制等原因, 导致获取的三维点云形状出现孔洞区域或出现部分形状结构的缺失. 传统的形状修复方法(如 Laplace 孔洞区域填充<sup>[4,5]</sup>、Poisson 曲面重建<sup>[6]</sup>等) 通常能修复三维模型中的孔洞区域缺失数据, 而对于补全如桌子腿、椅子靠背等类似的形状结构的缺失则难以直接利用传统的形状修复方法. 虽然可以借助专业 CAD 软件手工补全三维形状, 然而往往由于待修复模型的复杂性、手工修复效率低且成本高等原因, 亟需提出一种能够保持点云形状结构信息的修复方法, 自动实现三维缺失形状的保结构补全.

深度神经网络在许多领域取得很好的效果<sup>[7]</sup>, 但由于缺少大型 3D 模型数据集、三维形状难以量化输入神经网络等问题, 将神经网络技术应用于三维模型的自动生成和修复补全仍具有一定的挑战性. 近年来, 随着大型三维 CAD 模型数据集 ShapeNet<sup>[8]</sup> 的出现, 推动了神经网络和深度学习技术在三维形状生成和修复补全方面取得若干进展. 一般来说, 三维形状作为深度神经网络的输入方式中典型的有基于多视图方式<sup>[9]</sup>、基于体素方式<sup>[10]</sup>等. 其中, 基于多视图的输入方式通过拍摄 3D 模型多个视角下的照片并利用处理二维图像的方式处理三维形状<sup>[11,12]</sup>, 然而该方式难以有效地表示三维完整模型, 如复杂模型的部分结构信息往往会由于模型自身遮挡导致难以获得被遮挡部分的形状视图. 基于体素的输入方式则将三维形状嵌入 3D 体素空间中, 并将体素空间信息输入深度神经网络进行训练<sup>[13~15]</sup>, 然而该方式由于体素空间的三维特点导致其输入数据量和神经网络参数规模成倍增长, 受制于有限的 GPU 存储空间, 传统神经网络将难以处理高分辨率的体素模型. 由于基于点云数据的神经网络 PointNet<sup>[16]</sup> 的提出, 使得直接将点云数据作为神经网络的输入并实现点云形状的建模和处理成为可能. 相比于三维体素模型表示, 直接输入点云将大大减少输入数据量和神经网络的参数规模, 使得网络训练速度得到极大提高, 同时也能够完整保留输入模型的全部信息. 因此, 构建基于三维点云数据输入的保结构神经网络成为三维形状修复补全中的一个重要问题.

针对三维点云形状修复, Yuan 等<sup>[17]</sup> 提出了一种点云修复网络 (point completion network, PCN), 该网络针对输入的缺失点云数据, 借助于自编码解码器, 利用编码器编码输入的缺失点云数据, 并通过解码器解码重构出完整的点云形状, 但是该方法易出现重构生成的点云形状丢失原始形状部分结构信息的局限性. 此外, 利用 PCN 网络重构得到的点云形状对采样点稀疏的精细结构(如细线、薄面等) 的修复效果并不理想, 导致通常出现细线结构断裂、薄面处生成的采样点过于稀疏等缺陷. Yang 等<sup>[18]</sup> 则提出了用于点云重建与分类的神经网络 FoldingNet. 该网络是一个自编码器结构, 编码器将提取输入点云模型中各采样点及其邻域点的特征信息并编码成一个高维码字, 该高维码字将合并点云数据二维网格信息, 并通过折叠操作由二维网格生成三维点云. 此外, 近年来研究者使用生成对抗网络 (generative adversarial network, GAN) 及其拓展在二维图像生成领域取得了较大成功<sup>[19~21]</sup>. 针对传统生成对抗网络中存在的难以稳定训练等问题, Arjovsky 等<sup>[22]</sup> 提出的 WGAN 网络利用 Wasserstein 距离代替原始 GAN 网络中的 Jensen-Shannon 散度, 有效提高了神经网络训练的稳定性, 但却存在着收敛速度慢、生成的样例不丰富等缺点. Gulrajani 等<sup>[23]</sup> 提出的 WGAN-GP 则将 WGAN 中的权重修剪操作改为根据输入来惩罚判别器的梯度正则项, 解决了 WGAN 存在的部分问题.

受生成对抗网络在二维图像生成领域方面工作的启发, 为了在对三维点云形状修复补全中能保持形状的精细结构信息, 借助于生成对抗网络框架, 本文提出了一种能够自动修复补全三维点云形状的生成对抗网络结构, 其主要贡献在于: (1) 基于生成对抗网络框架, 提出了一个直接以三维点云数据作为输入的点云形状补全网络, 利用该网络能有效实现点云形状的修复补全; (2) 利用提出的三维点云形状补全网络, 在补全三维形状的同时有效保持了输入点云形状的精细结构信息; (3) 在网络损失函数构建中, 利用 Wasserstein 距离优化模型, 能有效保证点云形状补全网络的收敛性和训练稳定性.

本文第 2 节介绍三维形状修复补全相关工作;第 3 节详述本文的点云形状补全网络框架结构与技术细节;第 4 节阐述网络中损失函数的构建;第 5 节给出实验讨论与分析;最后一节总结了全文。

## 2 相关工作

### 2.1 基于几何的方法

基于几何的方法通过缺损形状中的几何线索辅助完成形状的修复补全。Kazhdan 等<sup>[6]</sup>提出 Poisson 表面重建方法,该方法采取隐式拟合策略,通过求解 Poisson 方程得到点云模型所描述的形状表面隐式方程,并对该隐式方程进行抽取等值面,从而得到其形状表面模型。基于对称性,Pauly 等<sup>[24]</sup>提出有效识别提取输入的缺失形状的对称轴、对称结构,以及重复结构的方法,并利用对称性实现对局部缺失部分的修复填充。这些方法通常要求输入的三维形状及形状结构基本完整,从而能够利用缺失区域邻近的形状几何线索推断空洞区域的形状信息,但是其对实际获取的离散点云数据由于几何与结构线索提取的困难而并不适用。

### 2.2 基于检索匹配的方法

基于检索匹配的方法是将部分缺失模型与大型形状数据库中模型进行匹配完成三维形状的补全。Li 等<sup>[25]</sup>通过对已有模型的对齐和缩放变形,并将变形得到的数据库中完整模型直接替代扫描缺失的模型,实现形状三维重建。Kim 等<sup>[26]</sup>将数据库中的三维形状分割成若干部件,并生成一种基于部件的概率模板,对于缺失的待修复模型则从数据库中检索出其目标部件,并通过组装目标部件至缺失形状上以实现模型的修复补全。Pauly 等<sup>[27]</sup>提出先从数据库检索近似的候选模型,并通过对输入的待修复模型和候选模型进行非刚性对齐以完成三维形状的补全。Rock 等<sup>[28]</sup>则提出根据输入模型从数据库中检索其相似深度图,并提取出完整深度信息替代原先模型的缺失深度信息以预测模型的缺失部分,最后利用 Poisson 表面重建方法重建最终完整模型。然而,该类方法的有效性通常依赖于数据库中庞大的模型数量规模和丰富的模型类型。

### 2.3 基于学习的方法

基于学习的方法通常使用神经网络进行形状的修复补全,该类方法直接将部分缺失的形状输入映射到三维完整形状。Chang 等<sup>[8]</sup>提出 Voxlets 的方法通过训练一个随机决策树预测缺失区域体素周围的未知区域,并利用包围盒技术生成加权平均值得到未知区域预测结果。Sharma 等<sup>[10]</sup>提出一种全卷积体积自动编码器结构,利用该结构能够通过噪声数据预测三维物体的完整形状。Nguyen 等<sup>[13]</sup>利用端到端的预测神经网络,基于 Markov 随机场计算距离转换直接实现了扫描数据的修复。Dai 等<sup>[14]</sup>提出一种 3D 编码-解码器,该编码-解码器能够完成从低分辨率的缺失形状输入到高分辨率的完整形状输出。基于三维模型的体数据表示,Wang 等<sup>[15]</sup>提出一种结合生成对抗网络和循环卷积网络的网络架构,并用于三维体数据表示下的形状修复。Liu 等<sup>[29]</sup>提出一种交互式的三维模型建模框架,该框架根据用户输入的缺失体素模型,采用生成对抗网络生成补全的三维体素模型;同时用户可以利用建模框架交互式补全和编辑三维模型,最终生成用户满意的结果。然而,上述这些基于神经网络学习的方法大多基于三维模型的体素表示,该表示方式往往由于 GPU 存储空间的有限,从而限制了其对高分辨率三维模型的处理。

本文提出的形状补全网络结构直接利用点云输入,相较于传统体素输入的方法,点云数据往往占用较少的 GPU 内存,从而能有效地提高点云修复神经网络的训练速度。同时,对于具有精细结构的三

维形状, 将模型直接采用离散采样点数据表示, 通常能方便准确地表达三维形状的精微结构信息并作为神经网络的完整输入. 基于生成对抗网络框架, 本文提出一种三维点云形状的自动修复补全网络. 该网络中的生成器能够采集点云数据中的结构信息, 完成对点云数据的结构信息编码, 进而能够结合二维网格坐标数据并通过二次折叠操作重构出输入点云的缺失部分. 然而, 为了最大限度地还原点云形状缺失部分的精微结构, 本文方法并不直接重构整个点云, 而是将重构的模型缺失部分与输入点云合并得到完整的点云模型. 网络中的判别器能够判别由生成器生成的点云形状与真实点云形状的相似程度, 从而为生成器生成更加逼真的样本提供指导. 本文采用 Wasserstein 距离作为损失函数以重构点云形状缺失部分, 相较于 Jensen-Shannon 散度, Wasserstein 距离具有更好的平滑特性, 从而能有效保证点云形状补全网络的收敛性和训练稳定性.

### 3 点云形状保结构补全网络

#### 3.1 点云形状补全网络结构

受生成对抗网络在二维图像生成领域方面工作的启发<sup>[19~21]</sup>, 本文使用生成对抗网络框架提出了一种三维点云形状的修复补全网络结构. 该网络由基于 PointNet<sup>[16]</sup> 的生成器和基于折叠的解码器构成. 其中生成器的目的是生成几乎与真实点云一致的完整点云模型. 判别器的目的是判别出输入的完整点云是来自生成器生成的数据还是真实点云数据. 通过生成器不断试图“欺骗”判别器, 判别器将接受生成点云和真实点云并产生判定结果, 利用判定结果计算误差并利用梯度下降法对神经网络参数进行调整优化, 最终使生成器生成足以“以假乱真”的修复补全后的点云形状数据高质量样本.

点云形状补全网络的总体结构如图 1 所示, 其中神经网络生成器以包含  $N$  个离散点的点云模型作为输入, 经过编码器编码得到其特征码字并作为解码器的输入, 解码器通过 2 次折叠操作生成  $M$  个离散点作为点云模型的缺失部分. 图中各感知器下方括号中的数字表示每层感知器的输出维度. 本文方法利用获取的缺失数据和完整模型的样本的大规模合成数据集, 训练神经网络直接从缺失点云模型预测完整点云模型, 通过监督学习策略有效解决三维点云形状的修复补全问题. 该方法以三维离散点云数据作为输入, 采用自编码器并结合生成对抗网络框架, 同时利用 Wasserstein 距离优化使得该网络训练稳定且能生成丰富的补全样例.

#### 3.2 生成器结构

在针对离散三维点云数据的修复补全中, 由于过多的点云数据特征将会使得神经网络的训练变慢, 效率低, 同时导致其难以分辨点云数据中含有的重要特征信息, 故本文的点云形状补全网络中的生成器采用编码器 - 解码器结构, 该结构可以有效提取输入点云的局部精微特征信息和全局形状特征信息, 并将其编码成具有较小规模数据量的压缩信息, 最后通过解码器重构生成点云形状的缺失部分数据. 神经网络中的编码器采用 PointNet<sup>[16]</sup> 编码结构, 该结构能够解决点云的旋转性和无序性问题并提取点云特征信息. 神经网络中的解码器则基于折叠操作<sup>[18]</sup>, 该操作能够将一个二维网格折叠成任意形状.

如图 1 所示, 点云形状补全网络的生成器输入一个  $N \times 3$  的矩阵, 矩阵的每一行由采样点坐标  $(x, y, z)$  组成, 生成器中解码器输出为  $M \times 3$  的矩阵表示缺失数据的补全部分, 最后将输入与输出合并得到  $(N + M) \times 3$  的矩阵并恢复重建后的完整点云形状.

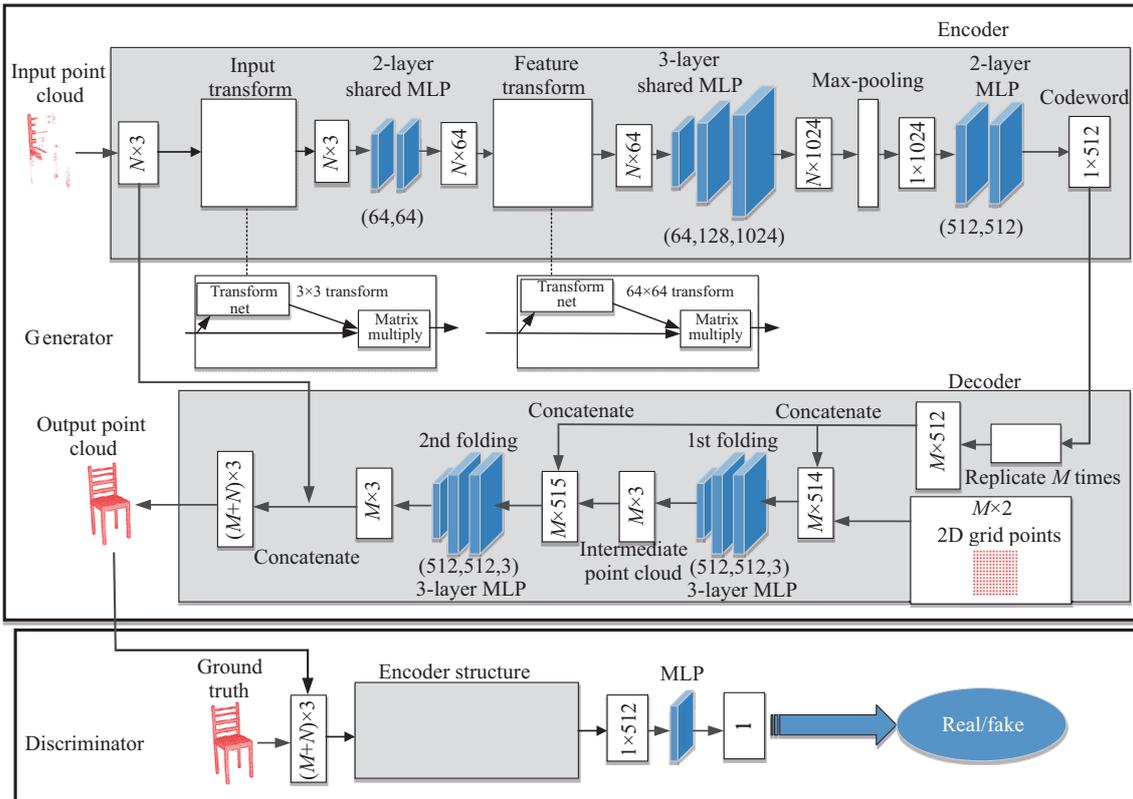


图 1 (网络版彩图) 点云形状保结构补全网络

Figure 1 (Color online) Structure of our structure-preserving shape completion network

### 3.2.1 基于 PointNet 的编码器

在编码器构建中, 本文采用文献 [16] 中的 PointNet 编码结构作为生成器的编码器, 该编码器结构能够有效解决点云数据输入的旋转性和无序性问题.

旋转性是指对输入点云形状进行旋转或平移操作时, 对于不同姿态的点云输入, 要求旋转或平移操作并不影响神经网络的修复补全效果. 本文的变换网络能够预测仿射变换  $3 \times 3$  矩阵, 并将该变换矩阵直接乘以输入矩阵, 用于配准不同输入点云数据的位置姿态. 本文将该思想进一步扩展到点云形状空间特征的对齐, 具体在点云特征基础上插入另一个变换网络以预测一个  $64 \times 64$  的特征变换矩阵, 用于配准不同输入点云数据的特征信息. 输入变换网络的网络结构如图 2 所示, 输入变换网络以  $N \times 3$  的点云数据作为输入并输出一个  $3 \times 3$  的仿射变换矩阵. 该网络由三层权共享感知器 (各层输出分别为 64, 128, 1024)、最大池化层、两层感知器 (各层输出分别为 512, 256) 构成. 同时, 为了预测仿射变换矩阵, 该网络先初始化一个大小为  $256 \times 9$  的全零权重矩阵、一个 9 维的值全为零的偏置值和一个  $1 \times 9$  的单位矩阵, 将权重矩阵与上一层感知器输出结果相乘, 再与单位矩阵和偏置值相加后的矩阵进行矩阵相加, 得到大小为  $1 \times 9$  的矩阵, 最后将其变形成  $3 \times 3$  的仿射变换矩阵输出. 特征变换网络的结构与输入变换网络相同, 不同的是特征变换网络的输出为  $64 \times 64$  矩阵.

无序性是指由于三维点云数据不同于二维图像像素矩阵, 通常是由一组无特定顺序的离散点组成, 对于输入而言其中三维离散点的顺序不影响其在空间中对整体三维形状的表达, 因此通常存在多种不同的点云数据输入但表达的同一个三维物体. PointNet<sup>[16]</sup> 网络使用最大池化层, 用于提取各采样点对

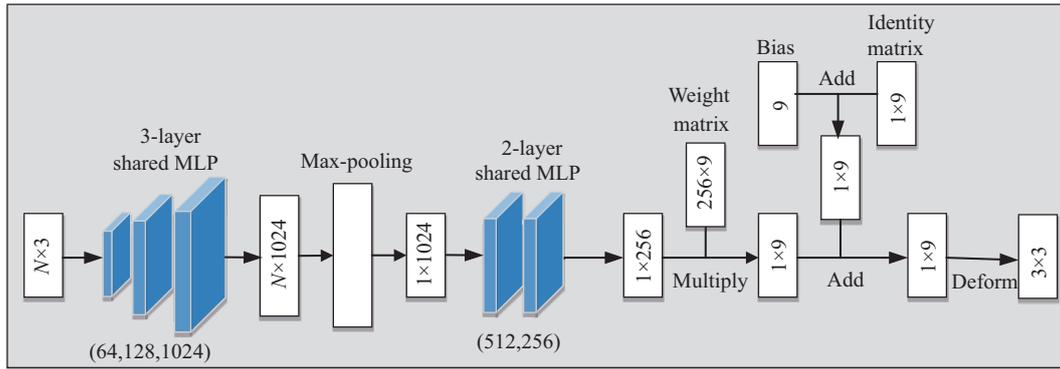


图 2 (网络版彩图) 输入变换网络结构

Figure 2 (Color online) Network structure for input transformation

应维度最大的特征, 解决了无序性问题. 由于网络结构的卷积层能有效地提取点云数据的特征, 本文先采用多层共享权感知器提取各采样点的局部特征, 再用最大池化层提取全局特征, 该全局特征各维均选取  $N$  个点对应维度的最大值, 其大小是  $1 \times 1024$ . 本文实验中, 感知器激活函数均选取如下 ReLU 函数, 而最后一层感知器不设激活函数, 其中 ReLU 函数形式如下:

$$\text{Relu}(x) = \begin{cases} x, & x \geq 0, \\ 0.2x, & x < 0. \end{cases}$$

### 3.2.2 基于折叠的解码器

在解码器构建中, 为了生成具有精细结构的复杂三维点云形状, 实现点云形状的保结构修复补全, 本文生成器中的解码器部分采用基于折叠的解码器结构. 具体来说, 该解码器采用 2 个连续的三层感知器将二维网格数据转换成输入点云数据缺失的部分. 首先, 将从编码器获得大小为  $1 \times 512$  的特征码字输入解码器, 并将其重复  $M$  次得到  $M \times 512$  的矩阵; 其次, 生成  $M$  个离散点 ( $M$  即为输入模型缺失部分的采样点数目), 这些离散点将组成一个二维网格平面, 该网格平面形状是以原点为中心的正方形, 其大小为  $M \times 2$  且每一行为离散点  $(x, y)$  坐标; 再将其与复制  $M$  次的特征码字矩阵合并得到  $M \times 514$  的矩阵, 并对该矩阵经三层感知器逐层处理并输出  $M \times 3$  的矩阵进行第 1 次折叠. 然后, 将复制  $M$  次的特征码字矩阵与第 1 次折叠输出的矩阵合并得到  $M \times 515$  的矩阵, 并将其输入到三层感知器中进行第 2 次折叠. 最后可以得到大小为  $M \times 3$  的输出矩阵并将其转换成修复补全的点云形状缺失部分数据.

需要指出的是, 解码器中的 2 次折叠操作能够实现二维结构到三维结构的一次映射. 其中的 2 次折叠操作相当于施加了一个“力”把二维网格进行变形、切割、拉伸操作并将其变成需要的点云形状. 由于多层感知器能够有效模拟诸如变形、切割、拉伸等操作, 故本文采用多层感知器实现二维网格的复杂折叠操作, 而其中特征码字则存储了折叠所需的“力”. 同时, 由于在提供适当码字的前提下, 二维网格能够通过 2 次折叠操作生成任意的点云形状<sup>[18]</sup>, 因而本文采用 2 个三层感知器串联的解码器结构.

### 3.3 判别器结构

在点云形状补全网络中, 判别器需要有效判断点云数据是真实的还是生成的数据. 本文借助于基于 PointNet 的编码器结构, 将判别点云任务转换成判别点云编码后的高维特征码字之间的区别. 本文

提出的判别器结构经过输入和特征变换、多层感知器、最大池化层等操作后,将得到  $1 \times 512$  维的码字.然而,与编码器不同的是,判别器需要输出一个标量,而编码器则输出一组向量.因而,将得到的  $1 \times 512$  维码字输入感知器(此感知器不设激活函数)最终得到一个标量,该标量能够用以判断输入的点云是来自生成器生成的数据还是真实点云数据.

#### 4 损失函数

在损失函数构建中,考虑到神经网络的训练稳定性和收敛速度,本文网络采用 Wasserstein 距离<sup>[22]</sup>代替原始 GAN 损失函数中的 Jensen-Shannon 散度<sup>[19]</sup>.生成器生成与真实点云数据相似的补全点云数据,并由判别器通过 Wasserstein 距离度量生成点云模型的真实性和真实性,其中的 Wasserstein 距离定义如下:

$$W(p_r, p_g) = \inf_{\gamma \sim \Pi(p_r, p_g)} E_{(\mathbf{x}, \mathbf{y}) \sim \gamma} \|\mathbf{x} - \mathbf{y}\|,$$

其中,  $p_r$  表示真实点云坐标数据分布,  $p_g$  表示生成点云坐标数据分布.  $\Pi(p_r, p_g)$  是以  $p_r$  与  $p_g$  为边缘分布的所有可能联合概率分布  $\gamma$  的集合.对于每一个  $\gamma$ ,可以从采样  $(\mathbf{x}, \mathbf{y}) \sim \gamma$  得到一个真实点云  $\mathbf{x}$  和生成点云  $\mathbf{y}$ ,计算该对样本之间距离并对距离期望值取下界.

由于其平滑特性, Wasserstein 距离能够更好地表示 2 个不同分布之间的距离并能计算其非零梯度,从而能够有效保证本文提出的点云形状补全网络的收敛性和训练稳定性.然而,直接计算任意 2 个分布之间的 Wasserstein 距离比较困难,可以利用其 Kantorovich-Rubinstein 对偶形式如下:

$$W(p_r, p_g) = \frac{1}{K} \sup_{\|f\|_L \leq K} E_{\mathbf{x} \sim p_r} [f(\mathbf{x})] - E_{\mathbf{x} \sim p_g} [f(\mathbf{x})],$$

其中,  $\mathbf{x}$  表示从分布中采样后的采样点云,  $f(\mathbf{x})$  表示抽象化的判别器网络,  $\|f\|_L \leq K$  表明该函数满足 Lipschitz 连续条件.

为了能够尽可能缩小生成样本的判别期望,放大真实样本的判别期望,判别器网络损失函数如下:

$$L'_D = E_{\mathbf{x} \sim p_g} [f(\mathbf{x})] - E_{\mathbf{x} \sim p_r} [f(\mathbf{x})].$$

然而,为了有效保证判别器满足 Lipschitz 连续条件,本文采用梯度惩罚的方式,在上式基础上增加一个损失项,使用如下判别器网络损失函数:

$$L_D = L'_D + \lambda E_{\mathbf{x} \sim p_U} [(\|\nabla_{\mathbf{x}} f(\mathbf{x})\|_2 - 1)^2],$$

其中  $\lambda$  为常数,本文实验中取 10;  $\nabla_{\mathbf{x}} f(\mathbf{x})$  为判别器梯度,其被约束在  $K$  附近(这里  $K$  取 1).由于在整个样本空间中采样会导致数据量过大,  $\mathbf{x} \sim p_U$  表示在生成样本空间集区域、真实样本空间集区域及其交集区域的 3 个区域并集空间  $p_U$  中采样.

此外,为了能尽可能放大生成样本的判别期望,本文采用的生成器网络优化目标函数为

$$L_G = -E_{\mathbf{x} \sim p_g} [f(\mathbf{x})].$$

#### 5 实验结果与分析

本文方法在 CentOS 系统下得到了实现,程序的硬件环境为 CPU 处理器 Intel Xeon Gold 6148,主频 2.40 GHz; GPU 为 NVIDIA Tesla V100,内存 16 G;开发平台为 Python 3.5.3 和 Tensorflow 1.12.0.

本文提出的点云形状保结构补全网络对训练数据的数量和质量均有一定的要求. 对于三维点云形状的修复补全任务, 本文采用来自 ShapeNet 数据集<sup>[8]</sup>中的模型创建包含缺失点云模型和完整点云模型的大规模数据集. 为此, 我们从 ShapeNet 数据集中挑选了常见的 2048 个三维物体网格模型, 如桌子、椅子、台灯等, 通过对选择的网格模型均匀采样得到固定数量的点云数据作为完整点云数据集; 而缺失点云数据集则通过对完整点云数据集的某些部位进行去除缺失得到. 其中每个完整点云模型对应 9 个不同部位缺失的点云数据, 本文选用 8 个缺失点云作为输入点云并用于训练, 其余 1 个作为测试数据. 具体地说, 点云形状保结构补全网络首先选取一个批次的包含若干缺失点云及其对应真实点云的数据作为输入, 其中缺失点云数据输入生成器中的编码器并获得用于折叠的码字信息, 该码字信息将结合二维网格坐标信息用于生成缺失点云的缺失部分数据, 最终得到输入点云数据与补全的缺失点云数据的合并, 即生成完整三维点云形状. 该过程中由于融合了输入的点云数据, 最终修复补全的三维点云形状能够有效保持输入点云模型的精细结构信息, 同时在修复过程中由于无需重构整个模型的点云数据, 神经网络参数相对较少. 判别器则接受生成点云数据和对应真实点云数据, 并产生一个标量指导生成器生成高质量、保持精细结构的三维完整点云形状.

### 5.1 数据集及预处理

一般来说, 稠密的点云数据能够有效表达具有复杂细节的三维物体形状, 然而在形状修复过程中如何在修复补全的同时保持这些精细结构通常是一个难点; 稀疏的点云数据由于采样点数目较少, 难以有效提取具有稀疏采样点的三维物体局部区域特征, 从而给形状修复补全带来困难. 为了有效实现稠密点云形状和稀疏点云形状的修复补全, 同时验证本文提出的保结构补全神经网络在点云形状修复中的有效性和鲁棒性, 我们分别构建了 2 个数据集, 一个是稠密点云模型数据集, 另一个是稀疏点云模型数据集, 并分别验证本文网络结构在这些数据集上的修复补全效果和性能表现.

为了构建实验需要的 2 个数据集, 本文分别对三维模型进行均匀采样, 将模型表面采样为  $S$  个点作为真实点云, 对稠密点云数据集中的模型采样点数目  $S$  取 16384, 对稀疏点云数据集中的模型采样点数目  $S$  则取 1024; 然后, 对完整点云形状进行下采样得到实验用的缺损点云模型, 每个完整点云模型对应 9 个不同部位缺失的点云数据, 并将缺损点云模型的采样点数目归一化, 其中缺损的稠密点云采样点数目为 12288, 缺损的稀疏点云采样点数目为 540. 同时, 为了使网络训练中能够快速收敛并提高训练的稳定性, 需要对缺损点云模型和完整点云模型的采样点坐标进行零均值归一化, 即将采样点坐标值分量均归一化至  $[-1, 1]$  区间内. 利用本文提出的保结构补全神经网络, 借助 Adam 优化器训练, 训练过程中生成器网络和判别器网络交替优化, 即生成器网络每更新 1 次则判别器网络更新 10 次; 神经网络学习中的学习率设为 0.0001, 持续 200 个周期, 批次大小为 8, 利用本文的神经网络结构能够获得较好的监督学习效果.

### 5.2 本文点云形状修复方法实验效果

本文使用生成对抗网络框架提出了一种三维点云数据的修复补全网络结构. 针对稠密点云模型数据集和稀疏点云模型数据集, 分别利用本文方法验证了该神经网络结构在点云形状修复补全中的有效性和优良的性能表现. 表 1 给出了本文实验中点云模型的采样点数目统计, 对不同类型的点云模型, 输入点云模型的采样点数目设置为  $N$ , 二维网格点数目设置为  $M$  (即输入点云缺失部分的采样点数目), 输出得到的点云模型采样点数目设置为  $N + M$ .

图 3 给出了残缺台灯和圆桌的修复补全效果. 对具有罩面缺失的台灯点云模型和具有桌脚缺失的圆桌模型, 利用本文提出的点云形状保结构补全网络进行修复, 生成器能够生成具有完整结构的三维

表 1 本文实验中点云模型的采样点数目

Table 1 Number of sampling points of our point cloud models

Data types	#Sampling points of input models ( $N$ )	#Sampling points of 2D grids ( $M$ )	#Sampling points of output models ( $N + M$ )
Dense point clouds	12288	4096	16384
Sparse point clouds	540	484	1024



图 3 (网络版彩图) 本文方法的修复补全效果

**Figure 3** (Color online) Shape completion results using our shape completion approach. For each point cloud model, we show the original point cloud model, completed model using our proposed method, and ground truth, respectively.

点云形状. 从中可以看到, 修复生成的完整点云形状能够有效地保持模型原有的罩面部件、桌脚部件等结构, 同时修复生成的三维形状采样点分布较均匀.

此外, 由于离散点云数据具有无序性, 为了说明本文方法修复点云形状的有效性, 考虑利用本文提出的点云形状保结构补全网络修复补全得到的点云形状和真实点云形状之间的误差. 本文采用倒角距离误差 (error of chamfer distance, ECD) [30] 度量修复点云与真实点云之间的差异程度, 对修复补全的点云模型  $S_1$  和真实点云模型  $S_2$  计算:

$$\text{ECD}(S_1, S_2) = \frac{1}{\|S_1\|} \sum_{\mathbf{p} \in S_1} \min_{\mathbf{q} \in S_2} \|\mathbf{p} - \mathbf{q}\|_2 + \frac{1}{\|S_2\|} \sum_{\mathbf{q} \in S_2} \min_{\mathbf{p} \in S_1} \|\mathbf{q} - \mathbf{p}\|_2,$$

其中  $\|S_1\|$  和  $\|S_2\|$  分别为相应点云模型的采样点数目. ECD 值能够衡量修复补全后的点云形状与真实点云形状之间的差异, 该值越接近零表示模型之间的相似程度越高, 修复补全效果越好. 图 3 中给出的对残缺台灯和圆桌的修复中倒角距离误差分别为 0.00159 和 0.00112.

同时, 为了说明本文提出的点云形状保结构补全网络的鲁棒性, 本文在密集数据集上测试了不同缺失程度的点云形状利用该网络的修复补全效果. 图 4 给出了数据缺失程度达 25%, 50%, 75% 的点云模型修复补全结果, 其修复效果表明本文方法在不同的缺失程度下均能够较好地保持输入点云形状的结构信息, 该 3 种缺失数据补全后的点云模型与真实点云模型的 ECD 值分别为 0.00138, 0.00290 和 0.00560. 实验表明, 本文网络对不同程度的损失输入依然能较好地补全缺失部分, 具有较强的鲁棒性.

此外, 利用深度神经网络进行点云形状补全的前提是能够提取输入点云数据的内在特征, 并在特征空间进行操作以处理数据集涵盖的分布范围数据. 因此, 该方法应具有生成与数据集中模型不同的模型数据的能力. 为了更好地验证本文提出的点云形状保结构补全网络的泛化性, 需要一个不同类别物体下具有多个模型的数据集, 以便网络能够充分地学习某种类别物体的特征空间, 并对不在此数据集中的缺失模型数据进行补全. 由于 ModelNet40 数据集 [31] 具有 40 种不同种类的模型, 每种类别大约有 20 ~ 130 个不同数量的模型. 本文将其处理成稀疏数据集的格式, 对每一种类别均挑选出一个模

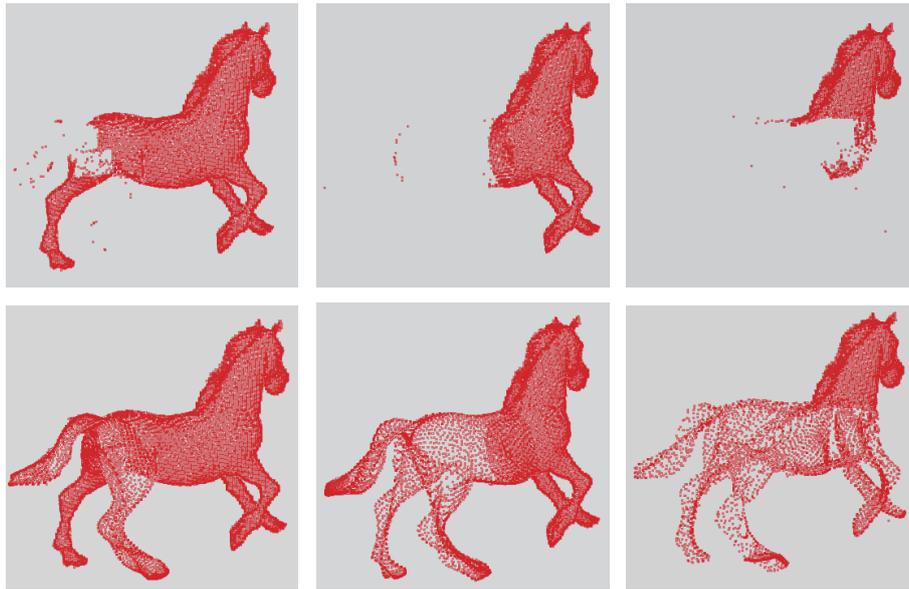


图 4 (网络版彩图) 针对不同缺失程度的点云模型修复补全效果  
 Figure 4 (Color online) Shape completion results for different levels of missing data

型不作为训练集数据. 图 5 给出了对不存在于训练数据集的具有 25%, 50%, 75% 缺失数据的点云模型 (如瓶子、显示器、吉他、椅子) 进行泛化性补全实验的结果, 其修复补全效果表明本文提出的点云形状保结构补全网络仍能对不在训练数据集中的点云形状进行有效补全, 可见本文网络具有很好的泛化性.

### 5.3 不同点云形状修复方法的比较

为了与本文提出的点云形状补全网络修复方法进行比较, 这里将采用相同数据集并分别利用基于 PCN 网络<sup>[17]</sup>与 FoldingNet 网络<sup>[18]</sup>的方法进行修复. 其中 PCN 网络<sup>[17]</sup>采用编码器-解码器结构, 其编码器通过多层权值共享感知器和 2 次最大池化层提取形状全局特征. 解码器通过多层感知器生成一个采样点数目较少的粗略点云模型, 并使用添加正方形形状的点云补丁对粗略点云模型进行采样点数目扩充, 最终得到完整点云模型; FoldingNet 网络<sup>[18]</sup>则由基于图的编码器和基于折叠的解码器组成, 对于模型各采样点, 编码器的输入不仅结合了采样点的局部协方差矩阵信息, 而且考虑了其邻域点的局部特征信息, 并通过折叠操作解码, 实现对输入点云形状的修复重构.

针对稠密点云数据集和稀疏点云数据集, 使用相同的训练集和测试集, 利用本文方法、PCN 网络方法<sup>[17]</sup>和 FoldingNet 网络方法<sup>[18]</sup>分别进行网络训练与模型修复补全, 网络训练中采用相同的训练周期、学习率和批次大小. 以稀疏数据集为例, 本文提出的点云形状补全网络框架中, 由于判别器需要不断判别生成点云数据的真假以不断优化生成器, 最终使生成器生成足以“以假乱真”的点云形状数据样本, 因而训练该网络通常需要花费较多时间, 约需 60 h; 而对 PCN 网络进行训练约需 5 h, 对 FoldingNet 网络进行训练约需 17 h. 然而, 若以一个缺损点云模型输入网络到生成对应的完整补全模型所用时间作为修复补全时间, 利用本文网络的修复补全时间约需 7 s, 而 PCN 网络与 FoldingNet 网络的修复补全时间分别约需 5 和 8 s. 图 6 给出了在稠密点云数据集上修复效果的比较. 实验可知, 利用 PCN 网络对采样点数目较少的精细形状结构的补全效果欠佳, 如对电脑椅靠背等薄面结构的修复



图 5 (网络版彩图) 模型泛化性补全实验

**Figure 5** (Color online) Generalization experiments for shape completion. (a) and (b) are the 25%-missing input data and corresponding completion results; (c) and (d) are the 50%-missing input data and corresponding completion results; (e) and (f) are the 75%-missing input data and corresponding completion results.

中往往仅产生少量的采样点, 吊灯吊线、篮子篮网等精细结构的修复中往往会发生结构断裂现象; 利用 FoldingNet 网络则会在修复的点云形状中出现网状结构, 与真实形状在精细结构上差别较大; 本文提出的形状补全网络则能够有效保持点云模型的精细结构, 如吊灯吊线、篮子篮网等. 实验表明, 本文方法修复效果在稠密数据集上的表现优于 PCN 网络与 FoldingNet 网络.

图 7 给出了在稀疏点云数据集上不同方法修复效果的比较. 实验表明, 利用 PCN 网络<sup>[17]</sup>对稀疏点云数据集的修复补全效果并不理想, 特别在模型边缘部分往往产生极其稀疏的采样点, 而在模型其他部分则产生采样点过于密集的现象, 而利用 FoldingNet 网络<sup>[18]</sup>与利用本文提出的补全网络均能较好地修复模型缺失数据. 图 7 的吉他、吧台椅模型修复中, FoldingNet 方法稍优于本文方法; 对书桌灯模型的修复则基本接近, 而对弓脚桌、落地灯模型的修复则稍逊于本文方法. 分析其原因, 我们认为 FoldingNet 网络与本文网络中补全形状的质量好坏来源于特征码字的提取, 而特征码字来源于编码器对特征的提取压缩. FoldingNet 网络的特征提取中为各采样点添加了其局部协方差矩阵信息, 同时利用图层加入了其邻域点的特征信息. 因此, 对于稀疏点云数据的信息提取, 本文网络的表现与

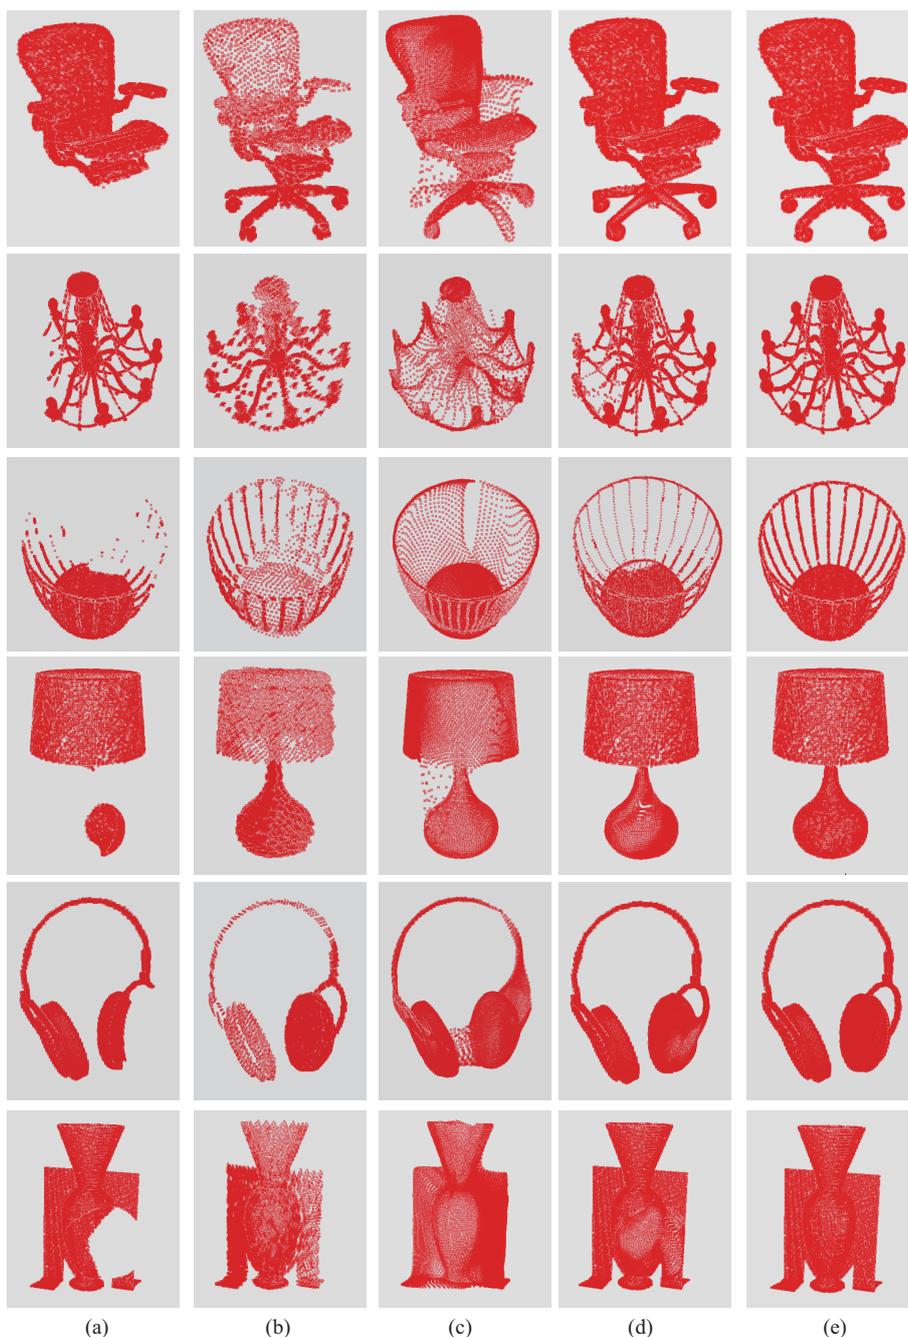


图 6 (网络版彩图) 针对稠密点云数据集的修复补全效果比较

Figure 6 (Color online) Comparisons of shape completion results for dense point cloud models. (a) Input point cloud; (b)~(d) shape completion results using PCN method<sup>[17]</sup>, FoldingNet method<sup>[18]</sup>, and our proposed method respectively; (e) ground truth.

FoldingNet 网络接近. 然而, 在针对稠密点云数据的特征提取时, 由于模型采样点数目较多, 需提取的特征数量也较多, 但由于特征码字的维度限制, 无法存储大量点云数据中庞大的特征信息, 因此可能造成某些采样点提取的特征丢失, 故 FoldingNet 网络在稠密点云数据集上的形状补全时会出现一些

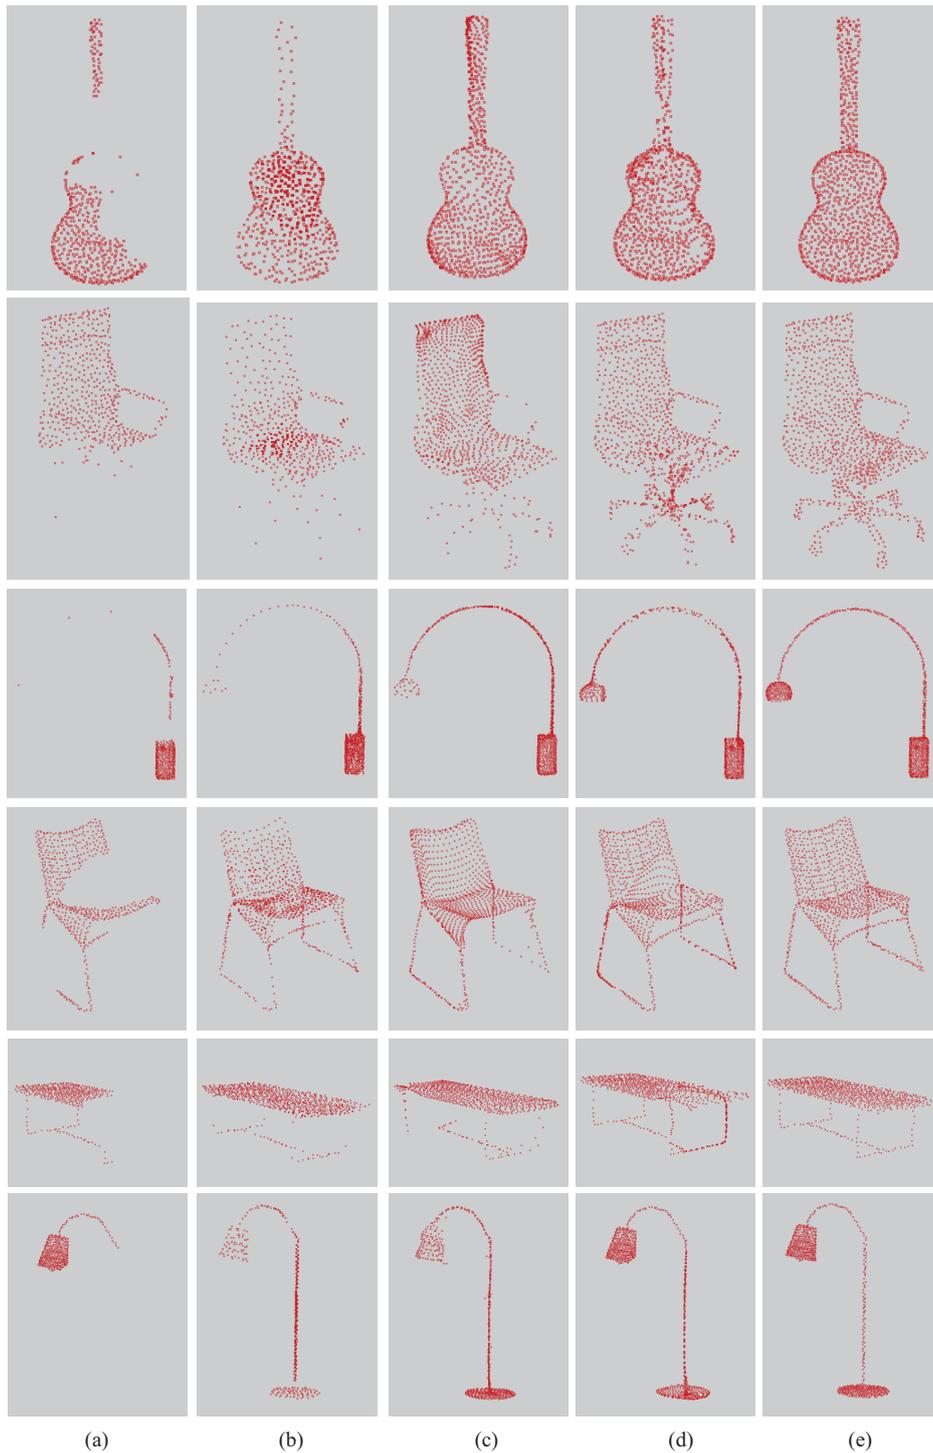


图 7 (网络版彩图) 针对稀疏点云数据集的修复补全效果比较

**Figure 7** (Color online) Comparisons of shape completion results for sparse point cloud models. (a) Input point cloud; (b)~(d) shape completion results using PCN method<sup>[17]</sup>, FoldingNet method<sup>[18]</sup>, and our proposed method respectively; (e) ground truth.

表 2 不同修复方法的 ECD 统计<sup>a)</sup>  
**Table 2** Statistics of ECD error via different shape completion methods<sup>a)</sup>

Data types	Point cloud models	PCN method <sup>[17]</sup>	FoldingNet method <sup>[18]</sup>	Our method
Dense point clouds	Desk lamp	0.00549	0.00471	<b>0.00159</b>
	Round table	0.00406	0.00326	<b>0.00112</b>
	Computer chair	0.00630	0.00622	<b>0.00208</b>
	Ceiling lamp	0.00370	0.00334	<b>0.00196</b>
	Basket	0.01027	0.00781	<b>0.00317</b>
	Bedside lamp	0.00884	0.00536	<b>0.00153</b>
	Headset	0.01037	0.01322	<b>0.00379</b>
	Flower vase	0.00957	0.00993	<b>0.00293</b>
Sparse point clouds	Guitar	0.01029	<b>0.00761</b>	0.00812
	Bar chair	0.01638	<b>0.01346</b>	0.01498
	Desk lamp	0.01099	0.00699	<b>0.00693</b>
	Bow chair	<b>0.00960</b>	0.01284	0.01074
	Bow-foot table	0.02761	0.02428	<b>0.01866</b>
	Floor lamp	0.01614	0.01092	<b>0.00811</b>

a) The bold numbers represent the optimal results.

游离异常点, 其修复补全效果欠佳. 综上所述, 本文方法修复效果在稀疏数据集上的表现优于 PCN 网络, 但与 FoldingNet 网络基本持平.

表 2 给出了利用不同方法分别对若干稠密和稀疏点云模型修复补全的 ECD 统计. 实验表明, 在稠密数据集上针对具有相同缺失点云数据的修复补全中, 本文方法的 ECD 误差通常比利用 PCN 网络<sup>[17]</sup>和 FoldingNet 网络<sup>[18]</sup>的 ECD 误差低, 说明本文方法修复补全的点云形状与真实点云形状更加接近; 在稀疏数据集上针对具有相同缺失点云数据的修复补全中, 本文方法的 ECD 误差与利用 FoldingNet 网络的 ECD 误差相差不大, 但两者均优于 PCN 网络, 说明本文方法与 FoldingNet 网络修复补全的点云形状与真实点云形状较接近.

## 6 结束语

针对三维点云形状的修复补全, 本文提出了一种有效的点云形状补全神经网络, 该网络直接以离散点云数据作为输入, 通过生成对抗网络框架实现三维形状的修复补全. 该网络的生成器采用自编码器架构, 由于其结合了输入点云数据的结构信息, 能够生成保持输入点云的精细结构特征的修复点云; 判别器则通过优化减少生成点云数据和真实点云数据之间的 Wasserstein 距离并用以指导生成器的不断优化, 最终实现输入点云形状的保结构修复补全. 实验表明本文提出的点云形状补全网络针对稠密点云数据集和稀疏点云数据集均取得了较好的修复补全效果, 在修复形状的同时很好地保持了原有形状的精细结构信息, 并且对于不同程度的模型缺失, 具有很好的鲁棒性.

然而, 本文网络结构中编码器生成高维码字时仅考虑了模型各采样点的全局特征, 而忽略了其局部特征, 对于某些局部采样点稀疏且结构非常精细的模型缺失部位, 利用本文方法难以达到预期的修补效果. 未来将考虑准确提取各采样点特征并结合其局部特征, 以实现异常稀疏点云形状的鲁棒修复.

## 参考文献

- 1 Gross M, Pfister H. Point Based Graphics. Burlington: Morgan Kaufmann Publisher, 2007
- 2 Miao Y W, Xiao C X. Geometric Processing and Shape Modeling of 3D Point-Sampled Models. Beijing: Science Press, 2014 [缪永伟, 肖春霞. 三维点采样模型的几何处理和形状造型. 北京: 科学出版社, 2014]
- 3 Henry P, Krainin M, Herbst E, et al. RGB-D mapping: using Kinect-style depth cameras for dense 3D modeling of indoor environments. *Int J Robot Res*, 2012, 31: 647–663
- 4 Nealen A, Igarashi T, Sorkine O, et al. Laplacian mesh optimization. In: *Proceedings of the 4th International Conference on Computer Graphics and Interactive Techniques in Australasia and Southeast Asia*, Kuala Lumpur, 2006. 381–389
- 5 Zhao W, Gao S M, Lin H W. A robust hole-filling algorithm for triangular mesh. *Visual Comput*, 2007, 23: 987–997
- 6 Kazhdan M, Hoppe H. Screened poisson surface reconstruction. *ACM Trans Graph*, 2013, 32: 29
- 7 Wu J X, Gao B B, Wei X S, et al. Resource-constrained deep learning: challenges and practices. *Sci Sin Inform*, 2018, 48: 501–510 [吴建鑫, 高斌斌, 魏秀参, 等. 资源受限的深度学习: 挑战与实践. *中国科学: 信息科学*, 2018, 48: 501–510]
- 8 Chang A X, Funkhouser T, Guibas L, et al. ShapeNet: an information-rich 3D model repository. 2015. ArXiv:1512.03012
- 9 Su H, Maji S, Kalogerakis E, et al. Multi-view convolutional neural networks for 3D shape recognition. In: *Proceedings of IEEE International Conference on Computer Vision*, Santiago, 2015. 945–953
- 10 Sharma A, Grau O, Fritz M. VConv-DAE: deep volumetric shape learning without object labels. In: *Proceedings of European Conference on Computer Vision*, Amsterdam, 2016. 236–250
- 11 Chen X Z, Ma H M, Wan J, et al. Multi-view 3D object detection network for autonomous driving. In: *Proceedings of IEEE Conference on Computer Vision and Pattern Recognition*, Honolulu, 2017. 1907–1915
- 12 Qi C R, Su H, Nießner M, et al. Volumetric and multi-view CNNs for object classification on 3D data. In: *Proceedings of IEEE Conference on Computer Vision and Pattern Recognition*, Las Vegas, 2016. 5648–5656
- 13 Nguyen D T, Hua B S, Tran K, et al. A field model for repairing 3D shapes. In: *Proceedings of IEEE Conference on Computer Vision and Pattern Recognition*, Las Vegas, 2016. 5676–5684
- 14 Dai A, Qi C R, Nießner M. Shape completion using 3D-encoder-predictor CNNs and shape synthesis. In: *Proceedings of IEEE Conference on Computer Vision and Pattern Recognition*, Honolulu, 2017. 5868–5877
- 15 Wang W Y, Huang Q G, You S Y, et al. Shape inpainting using 3D generative adversarial network and recurrent convolutional networks. In: *Proceedings of IEEE International Conference on Computer Vision*, Venice, 2017. 2298–2306
- 16 Qi C R, Su H, Mo K, et al. PointNet: deep learning on point sets for 3D classification and segmentation. In: *Proceedings of IEEE Conference on Computer Vision and Pattern Recognition*, Honolulu, 2017. 652–660
- 17 Yuan W T, Khot T, Held D, et al. PCN: point completion network. In: *Proceedings of the 6th IEEE International Conference on 3D Vision*, Verona, 2018. 728–737
- 18 Yang Y Q, Feng C, Shen Y R, et al. FoldingNet: point cloud auto-encoder via deep grid deformation. In: *Proceedings of IEEE Conference on Computer Vision and Pattern Recognition*, Salt Lake City, 2018. 206–215
- 19 Goodfellow I, Pouget-Abadie J, Mirza M, et al. Generative adversarial nets. In: *Proceedings of Advances in Neural Information Processing Systems*, Montreal, 2014. 2672–2680
- 20 Radford A, Metz L, Chintala S. Unsupervised representation learning with deep convolutional generative adversarial networks. 2015. ArXiv:1511.06434
- 21 Zhang H, Goodfellow I, Metaxas D, et al. Self-attention generative adversarial networks. 2018. ArXiv:1805.08318
- 22 Arjovsky M, Chintala S, Bottou L. Wasserstein generative adversarial networks. In: *Proceedings of the 34th International Conference on Machine Learning*, Sydney, 2017. 214–223
- 23 Gulrajani I, Ahmed F, Arjovsky M, et al. Improved training of wasserstein GANs. In: *Proceedings of Advances in Neural Information Processing Systems*, Long Beach, 2017. 5767–5777
- 24 Pauly M, Mitra N J, Wallner J, et al. Discovering structural regularity in 3D geometry. *ACM Trans Graph*, 2008, 27: 43
- 25 Li Y Y, Dai A, Guibas L, et al. Database-assisted object retrieval for real-time 3D reconstruction. *Comput Graph Forum*, 2015, 34: 435–446

- 26 Kim V G, Li W, Mitra N J, et al. Learning part-based templates from large collections of 3D shapes. *ACM Trans Graph*, 2013, 32: 70
- 27 Pauly M, Mitra N J, Giesen J, et al. Example-based 3D scan completion. In: *Proceedings of the 3rd Eurographics Symposium on Geometry Processing*, Vienna, 2005. 23–32
- 28 Rock J, Gupta T, Thorsen J, et al. Completing 3D object shape from one depth image. In: *Proceedings of IEEE Conference on Computer Vision and Pattern Recognition*, Boston, 2015. 2484–2493
- 29 Liu J, Yu F, Funkhouser T. Interactive 3D modeling with a generative adversarial network. In: *Proceedings of IEEE International Conference on 3D Vision (3DV)*, 2017. 126–134
- 30 Fan H Q, Su H, Guibas L J. A point set generation network for 3D object reconstruction from a single image. In: *Proceedings of IEEE Conference on Computer Vision and Pattern Recognition*, Honolulu, 2017. 605–613
- 31 Wu Z R, Song S R, Khosla A, et al. 3D ShapeNets: a deep representation for volumetric shapes. In: *Proceedings of IEEE Conference on Computer Vision and Pattern Recognition*, Boston, 2015. 1912–1920

## Structure-preserving shape completion of 3D point clouds with generative adversarial network

Yongwei MIAO<sup>1\*</sup>, Jiazong LIU<sup>1</sup>, Jiahui CHEN<sup>1</sup> & Zhenyu SHU<sup>2</sup>

1. *College of Information Science and Technology, Zhejiang Sci-Tech University, Hangzhou 310018, China;*
2. *School of Computer and Data Engineering, Ningbo Institute of Technology, Zhejiang University, Ningbo 315100, China*

\* Corresponding author. E-mail: ywmiao@zstu.edu.cn

**Abstract** Due to the difficulty in maintaining the fine structures of 3D point cloud in shape completion, this study, with the help of the generative adversarial network framework, proposes a novel neural network for automatically repairing and completing the 3D shape of point clouds. This network consists of a generator and a discriminator. The generator of the proposed neural network adopts an encoder-decoder structure and takes the missing 3D point cloud shape data as the input. Firstly, it aligns the sampling point position and feature information of the input point cloud data by the input transform and feature transform. Then the weighted shared multi-layer perceptron extracts the local shape features for each sampling point and also extracts its feature codewords using the maximum pool layer and multi-layer perceptron coding. Secondly, it adds the feature codewords of sampling points with the grid coordinate data, and the decoder converts the grid data into the missing data of the underlying point cloud using two successive three-layer perceptron folding operations. Finally, it merges the missing completion data and the input data to get the complete 3D point cloud shape. Meanwhile, the proposed neural network discriminator receives the real and the completed point cloud data generated by the generator. The same encoder structure as the generator is also adopted to distinguish the true or false of the point cloud data, while the classification results are a feedback for optimizing the generator. Also, the generator will generate the “real” point cloud shape data. Experimental results illustrate that, for both the dense and sparse incomplete point cloud data, the proposed method effectively maintains the fine structures of the input point clouds while repairing the missing part of the underlying shapes.

**Keywords** generative adversarial network (GAN), encoder-decoder structure, point cloud, shape completion, folding operation



**Yongwei MIAO** was born in 1971. He received his Ph.D. degree in computer graphics from State Key Laboratory of CAD & CG, Zhejiang University in 2007. Currently, he is a professor at Zhejiang Sci-Tech University. His research interests include computer graphics, digital geometry processing, computer vision, machine learning, and deep learning.



**Jiazong LIU** was born in 1994. Currently, he is a master's candidate at Zhejiang Sci-Tech University. His research interests include computer graphics, digital geometry processing, and deep learning.



**Jiahui CHEN** was born in 1995. Currently, she is a master's candidate at Zhejiang Sci-Tech University. Her research interests include 3D computer vision and deep learning.



**Zhenyu SHU** was born in 1979. He received his Ph.D. degree from College of Mathematics, Zhejiang University in 2010. Currently, he is a professor at Ningbo Institute of Technology, Zhejiang University. His research interests include computer graphics, digital geometry processing, and machine learning.