PPC-MT：基于 Mamba-Transformer混合架构的并行点云补全

Jie Li*、Shengwei Tian*、Long Yu*和Xin Ning† *新疆大学，乌鲁木齐，中国 †中国科学院半导体研究所，北京，中国

arXiv:2603.00870v1 [cs.CV] 1 Mar 2026

摘要——现有点云补全方法难以兼顾高质量重建与计算效率。为解决这一问题，我们提出了 PPC-MT，这是一种利用 Mamba-Transformer混合架构的新型点云补全并行框架。我们提出了一种创新的并行补全策略，该策略以主成分分析（PCA）为指导，为无序点云施加具有几何意义的结构，将其转换为有序点集并分解为多个子集。随后，使用多头重建器并行重建这些子集。这种结构化并行合成范式显著提升了点分布的均匀度和细节保真度，同时保持了计算效率。PPC-MT 将 Mamba 在线性复杂度下高效提取特征的能力融入编码过程，并利用 Transformer 在解码过程中建模细粒度多序列关系的能力，从而有效兼顾效率与重建精度。在包括 PCN、ShapeNet-55/34 和 KITTI 在内的基准数据集上开展的大量定量和定性实验表明，PPC-MT 在多项指标上均优于最先进方法，验证了所提框架的有效性。

索引词—点云补全、主成分分析、Mamba、Transformer。

I. 引言

点云作为三维场景和物体的核心表示，在自动驾驶、机器人导航、增强现实和三维建模等领域发挥着不可或缺的作用 [1]–[5]。然而，受传感器精度有限、物体间相互遮挡以及视点限制等因素影响，在真实场景中采集的点云数据往往存在不完整或区域缺失的问题。这些数据缺陷显著限制了目标检测、场景理解和姿态估计等下游任务的性能。因此，开发高效且稳健的点云补全算法已成为三维计算机视觉领域的重要研究方向。

多年来，随着点云补全研究的不断进展，基于编码器-解码器架构的神经网络方法逐渐成为主流。早期的单阶段方法 [6]–[9] 通常通过编码器从输入的不完整点云中提取全局特征，再由解码器直接映射这些特征，生成完整点云。然而，由于过度依赖全局特征，单阶段方法在恢复精细局部细节和处理大范围缺失区域方面的能力相对有限，泛化性能也常常面临挑战。随着 PCN 开创性地引入 [10] 两阶段点云补全策略，首先

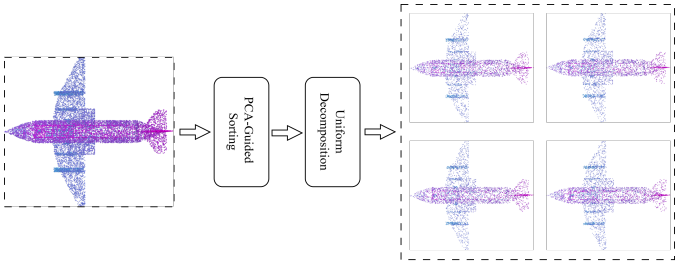

图 1. PCA引导的分解示意图。首先根据主成分分析（PCA）对目标点云进行排序，然后将其均匀分解为若干结构化片段。

通过编码器从不完整点云中提取特征，生成作为形状骨架的低分辨率粗点云；然后以此为基础，结合编码器特征，由解码器进一步细化，生成高分辨率完整点云。受此方法启发，后续研究 [11]–[13] 进一步探索了多阶段级联解码或层次化生成策略，通过多步迭代或层次化细化提升补全的准确性和鲁棒性。尽管多阶段方法的性能通常优于单阶段和两阶段方法，但当中间点云表示依赖大量点时，计算成本和复杂度会显著增加，从而给实际应用带来挑战。

为克服现有点云补全方法在处理复杂缺失区域以及平衡质量与效率方面的瓶颈，本文提出并行点云补全框架 PPC-MT。受分治法启发，我们将重建完整点云的目标分解为易于处理的子问题。如图 1 所示，我们利用主成分分析（PCA）引导目标点云的均匀分解，将其划分为多个子目标点云，分别进行重建，最终共同完成原始点云的重建。此外，我们引入状态空间模型 Mamba，以提高特征提取效率，同时保留 Transformer 结构来建模多个序列之间的关系，从而确保特征重建精度。

现有方法在评估点云补全结果时采用两套定量评估体系。对于有监督补全数据集（如 PCN 和 ShapeNet55/34），大多数研究仅采用倒角距离（CD）[14] 和 F 分数 [15] 作为评估指标；而对于

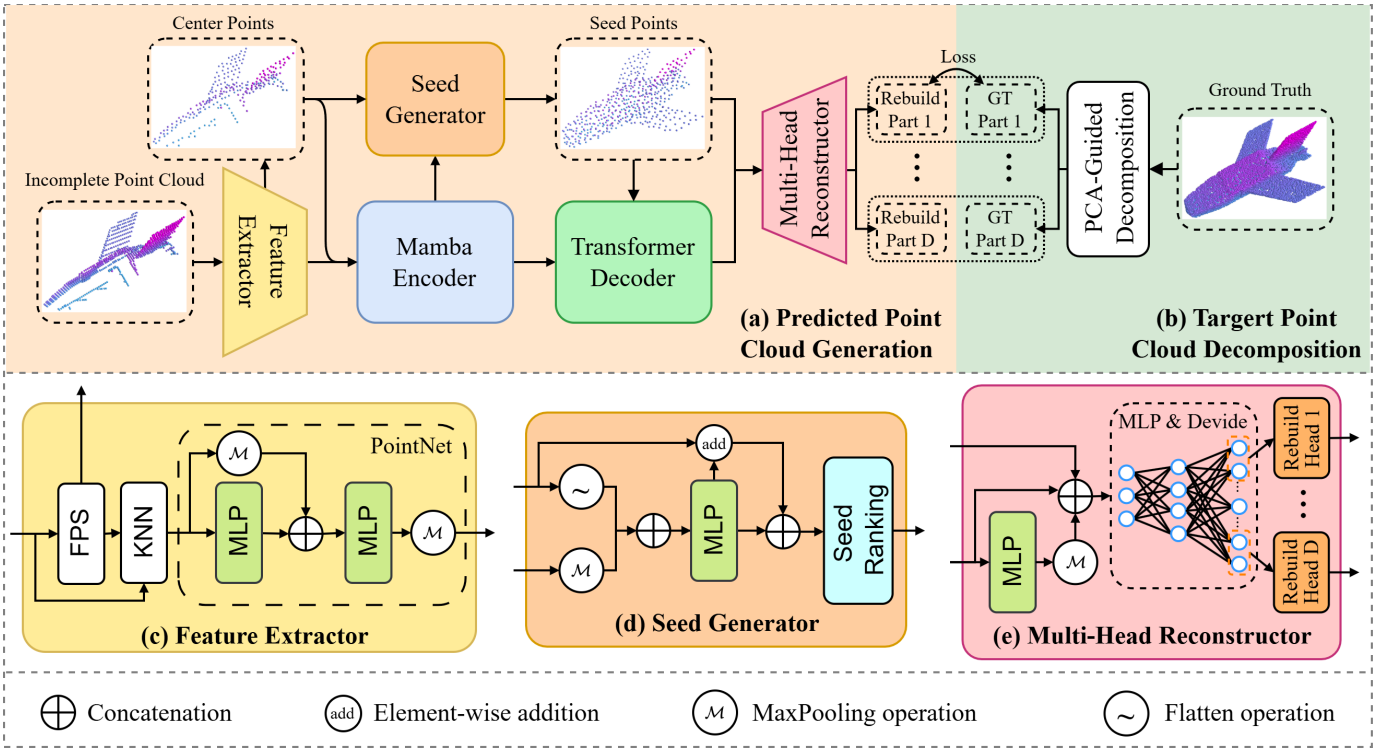

图2。PPCMT框架由两个主要部分组成：(a) 预测点云生成和 (b) 目标点云分解。预测点云生成部分包含多个模块，图中展示了其中三个：(c) 特征提取器、(d) 种子生成器和 (e) 多头重建器。

无监督补全数据集（如 KITTI），则使用保真度和最大均值差异（MMD）[10] 作为评估指标。实际上，这两套评估体系既不全面，也不完全适用。因此，对于前者，我们认为还应引入 DCD [16]和 EMD [14]来评估补全结果；对于后者，我们仅额外提供一致性和均匀度等评估方法供参考。

总体而言，我们的贡献可概括如下：

- 我们提出了一种PCA引导的分解方法，为无序点云赋予顺序，并将目标点云均匀分解为多个子目标；在此基础上，我们设计了一种多头并行重建机制，以克服传统串行方法的局限性。

- 我们首次将 Mamba 与 Transformer 结合用于点云补全，利用 Mamba 的线性复杂度高效编码全局上下文，同时使用 Transformer 精确建模多个序列之间的关系。

- 针对有监督和无监督数据集，我们提供了更全面的指标评估，旨在从形状、细节和分布等多个维度，对补全质量进行更稳健的评估。

- 在多个公开点云补全数据集（包括 PCN、ShapeNet-55/34 和 KITTI）上进行的大量实验表明，与现有最先进的

最先进的方法。

II. 相关工作

A. 点云补全

点云补全是三维视觉中的一项基础任务，近年来受到了广泛关注。早期工作[17], [18] 主要依赖几何先验或传统优化方法，但这些方法在处理复杂形状和大规模缺失数据时表现有限。随着深度学习的发展，基于神经网络的方法已成为主流，大致可分为单阶段方法和多阶段方法。单阶段补全方法通常采用编码器-解码器架构，直接将不完整点云端到端映射为完整点云。FoldingNet [6] 和 AtlasNet [9]等代表性工作引入了基于二维参数化流形的可变形模板思想，通过学习折叠操作或映射多个表面片来生成点云。TopNet [7] 设计了具有层次结构的树状解码器，以生成点云结构。MSN [8] 生成多个点簇中心并采样点以覆盖完整形状。尽管单阶段方法因其结构简洁、计算效率高而受到青睐，但全局特征向量可能成为信息瓶颈，限制其准确重建复杂几何细节的能力。为提高重建质量，PCN [10] 首次提出“两阶段”策略：先生成低分辨率粗点云，再将其细化为高分辨率结果。

这一思路催生了一系列多阶段方法。GRNet[19] 利用体素网格进行渐进式细化。PoinTr[20] 将Transformer引入集合到集合的转换过程，通过自注意力捕捉全局-局部相关性。SnowflakeNet [21]采用“雪花”式点分裂机制，使点云逐层逐步生长。SeedFormer [22] 和AdaPoinTr [23]通过种子点扩展和自适应注意力进一步增强了细节保持与形状一致性。ProxyFormer [24]通过对代理对齐和对缺失部分敏感的Transformer优化补全，融合已有与缺失的点特征，在保持高效推理的同时生成高精确率点云。SVDFormer [25] 利用自视图增强和双生成器，结合多视图全局形状与局部结构先验，在无需额外配对信息的情况下实现高质量补全。这些方法更优的准确性证实了多阶段方法的有效性。这些方法更优的准确性证实了多阶段方法的有效性。然而，从两阶段方法开始，许多方法通过增加补全阶段的数量来提高准确性。这种串行方式显著增加了计算复杂度。相比之下，所提出的PPC-MT旨在从并行视角解决这一问题。

B. 状态空间模型

状态空间模型（SSM）已成为序列建模中极具潜力的技术，它通过隐藏状态连接输入与输出，从而对复杂系统进行建模 [26]。受结构化状态空间（S4） [27]模型的启发，多项研究 [28], [29] 探索了使用 SSM 建模长程依赖。尤其是近期提出的 Mamba 模型 [30], ，因其出色的全局感知性能而备受关注。与 Transformer 的 $O（n^2）$ 计算复杂度相比，Mamba 的复杂度为 $O（n）$，在处理长序列时展现出线性可扩展性。受 Mamba 成功的启发，研究人员提出了多种方法，以验证其在二维视觉任务 [31]–[33] 中的有效性。在三维点云领域，如何将最初为序列数据设计的 SSM 与点云固有的无序特性有效结合，是一项重大挑战。PointMamba[34]和 PCMamba [35] 提出了不同的策略，将点云转换为有序结构：PointMamba 沿坐标轴对点进行重排，而 PCMamba 则使用 Z序和希尔伯特序等多种排序方法重新组织数据。Mamba3D [36]通过通道翻转策略实现双向建模，有效解决了 Mamba 中由伪序列依赖关系导致的潜在偏差。此外，PoinTramba [37] 首次验证了在三维点云领域结合 Transformer 与 Mamba 的可行性。这些方法在点云分类和分割任务中取得了显著成果。然而，Mamba 在点云补全任务中的应用仍鲜有探索。具体而言，如何有效整合 Transformer 与 Mamba 各自的优势，以实现更优性能和更低计算复杂度，仍是一个有待研究的开放问题。

III. 方法

A. 概述

PPC-MT 由两个主要部分组成：预测点云生成（图 2（a））和目标点云分解（图 2（b））。预测部分包含五个模块：特征提取器、Mamba 编码器、种子生成器、Transformer 解码器和多头重建器。分解部分基于 PC A 方法。与 SeedFormer 和 AdaPoinTr 类似，我们将点云补全任务构建为集合到集合的转换问题。在这里，我们将这些集合称为“点代理”，每个点代理代表点云的一个局部区域。我们的目标是将输入点云的点代理转换为预测点云的点代理。与以往方法不同，我们使用多个头共同预测目标点云。

具体而言，给定输入点云 $\mathcal{P}_{in} \in \mathbb{R}^{N\times 3}$，特征提取器首先使用最远点采样（FPS）和K近邻（KNN）将其划分为G个局部组，并提取初始点代理特征 $\mathcal{F} = \{F_1, F_2, \ldots, F_G\}$。随后，我们采用高效的 Mamba 编码器代替传统的 Transformer，以捕获点云中的长程依赖，从而得到特征增强的点代理 $\mathcal{E} = \{E_1, E_2, \ldots, E_G\}$。基于 $\mathcal{E}$ 以及种子生成器生成的种子点 $\mathcal{P}_0$ ，我们生成 I 个种子点代理 $\mathcal{S} = \{S_1, S_2, \ldots, S_I\}$，再通过 Transformer 解码器将其转换为特征增强的点代理 $\mathcal{D} = \{D_1, D_2, \ldots, D_I\}$。最后，多头重建器将 $\mathcal{D}$ 重建为 U 组预测点代理 $\mathcal{O} = \{\mathcal{O}^i\}_{i=1}^{U}$，共同重建出完整点云$\mathcal{P} = \bigcup_{i=1}^{U} \mathcal{P}_i$。为提供更细粒度的监督信号，我们采用 PCA 引导的目标点云分解策略，将真实点云 $\mathcal{G}$ 划分为 U 个子点云 $\{\mathcal{G}_i\}_{i=1}^{U}$。整个框架通过多级损失函数进行端到端训练，其中包括中心点、局部点云和全局点云的损失。

B. 预测点云生成

特征提取器。 初始步骤将输入点云 $\mathcal{P}_{in} \in \mathbb{R}^{N\times 3}$ 重新组织为点代理，以降低后续计算复杂度，这是点云分析中的常见操作 [34], [36], [38]。如图 2 (c) 所示，我们首先使用最远点采样（FPS）从 $\mathcal{P}_{in}$ 中下采样 G 中心点 C。然后，对于每个中心点，我们使用 K近邻找到其 K 个最近邻，形成 G 点组 P。每组中的点都相对于对应的中心点进行归一化。最后，使用轻量级 PointNet[@PointNet]生成初始点代理 $\mathcal{F} = \{F_1, F_2, \ldots, F_G\}$:

$$C = \mathrm{FPS}\left(\mathcal{P}_{in}\right), \qquad C \in \mathbb{R}^{G\times 3} \tag{1}$$

$$P = \mathrm{KNN}\left(\mathcal{P}_{in}, C\right), \qquad P \in \mathbb{R}^{G\times K\times 3} \tag{2}$$

$$\mathcal{F} = \mathrm{PointNet}(P), \qquad \mathcal{F} \in \mathbb{R}^{G\times D} \tag{3}$$

其中 D 是网络的隐藏维度。轻量级 PointNet 主要由多层感知机和最大池化操作组成。

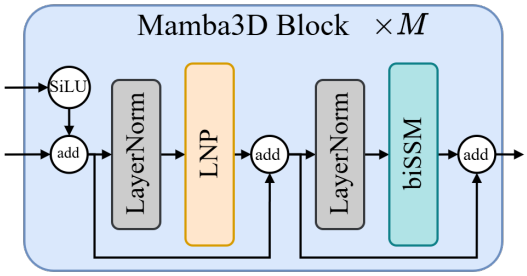

Fig. 3. Mamba 编码器的详细结构 .

Mamba 编码器。 Mamba [30] 旨在解决长序列建模中的计算效率问题，实现了线性复杂度 $O(n)$。Mamba2 [39]进一步展现了其作为自注意力高效替代方案的潜力。考虑到点代理继承了点云的无序特性，同时又具有空间坐标相关性，Mamba3D [36]引入了双向状态空间模型和 LNPBlock，以专门处理潜在的伪序列依赖关系并聚合局部空间几何特征，其有效性已通过实验得到验证。因此，我们采用 Mamba3D 模块捕获初始点代理 $\mathcal{F}$ 内部的组内依赖关系，并生成增强的点代理特征 $\mathcal{E}=\{E_1,E_2,\ldots,E_G\}$。具体而言，如图 3 所示，我们的 Mamba 编码器由 M 个 Mamba3D 模块构成。每个 Mamba3D 模块包含两个关键组件：LNP 和双向状态空间模型。其流程可由以下公式表示：

$$z_0=\mathcal{F}+\mathrm{SiLU}(C),\qquad z_0\in\mathbb{R}^{G\times D} \tag{4}$$

$$z'_l=\mathrm{LNP}(\mathrm{LN}(z_{l-1}+\mathrm{SiLU}(C)))+z_{l-1},\qquad l=1,\ldots \tag{5}$$

$$z_l=\text{bi-SSM}(\mathrm{LN}(z'_l))+z'_l,\qquad l=1,\ldots,M \tag{6}$$

$$\mathcal{E}=z_M,\qquad \mathcal{E}\in\mathbb{R}^{G\times D} \tag{7}$$

其中， z_l 是第 l层的输出，LN 表示层归一化。值得注意的是，由于 $\mathcal{F}$ 仅表示局部语义模式，每个 Mamba3DBlock 都包含一个标准的可学习位置编码 SiLU(C)，用于显式编码点代理的全局位置，其中 SiLU 操作源自 [40]。

种子生成器。 种子生成器旨在生成初始点云种子，作为解码器的起点。这些种子点分布在目标形状的关键位置，为后续细粒度生成奠定基础。为充分利用输入点云的坐标信息，我们提出的种子生成模块采用图2（d）所示的设计。具体而言，该模块首先分别对点代理特征 $\mathcal{E}$ 和中心点 C执行最大池化和展平操作。随后，多层感知机预测过量的候选点$\hat{\mathcal{P}}_0\in R^{I'\times 3}$（通常为 $I'=768$）。为增强特征表示，对前256个预测点引入残差连接。接着，评分网络评估所有候选种子点的质量，并根据分数选出最优种子点集合 $\mathcal{P}_0\in R^{I\times 3}$（通常为 $I=512$）。该过程的数学描述如下：

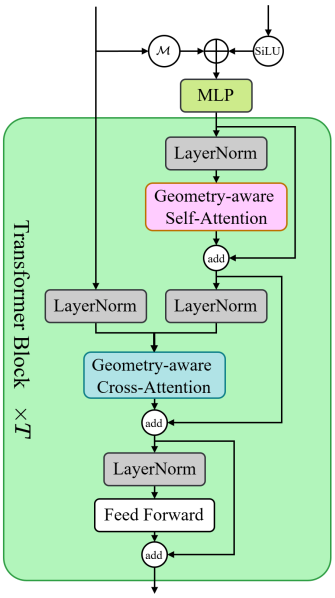

图 4. Transformer 解码器的详细结构 er.

$$\hat{\mathcal{P}}_0=\mathrm{MLP}\left(\mathcal{M}\left(\mathcal{E}\right),\mathrm{Flatten}\left(C\right)\right),\qquad \hat{\mathcal{P}}_0\in\mathbb{R}^{I'\times 3} \tag{8}$$

$$\mathcal{P}_0=\mathrm{TopK}(\mathcal{P}_0,\Omega(\mathcal{P}_0)),\qquad P_0\in\mathbb{R}^{I\times 3} \tag{9}$$

其中， $\mathcal{M}$ 为最大池化操作，Flatten为展平操作，Ω表示由多层感知机和Sigmoid操作组成的评分网络，TopK表示选择得分最高点的操作。

Transformer 解码器。我们的模块借鉴了 AdaPoinTr [23], ，引入几何感知注意力，以适应点云数据的无序特性。我们在解码器中继续使用 Transformer，因为需要交叉注意力机制来显式建模来自 Mamba3D 编码器的点代理特征 $\mathcal{E}=\{E_1,E_2,\ldots,E_G\}$ 与种子点代理$\mathcal{S}=\{S_1,S_2,\ldots,S_I\}$之间的关系。如图 4 所示，我们的 Transformer 解码器通过堆叠的注意力层，将种子点代理 $\mathcal{S}$逐步转换为点代理 $\mathcal{D}=\{D_1,D_2,\ldots,D_I\}$。每一层都包含几何感知自注意力和交叉注意力模块。前者使种子点代理 $\mathcal{S}$ 能够相互交换信息，后者旨在从编码器的点代理特征 $\mathcal{E}$中提取相关特征。该过程表述为：

$$w_0=\mathcal{S}=\mathrm{MLP}(\mathcal{M}(\mathcal{E}),\mathrm{SiLU}(P_0)),\qquad w_0\in\mathbb{R}^{I\times D} \tag{10}$$

$$w'_l=w_{l-1}+\mathrm{SelfAtt}(\mathrm{LN}(w_{l-1})),\qquad l=1,\ldots,T \tag{11}$$

$$w''_l=w'_l+\mathrm{CrossAtt}(\mathrm{LN}(w'_l),\mathrm{LN}(\mathcal{E})),\qquad l=1,\ldots,T \tag{12}$$

$$w_l=w''_l+\mathrm{FFN}(\mathrm{LN}(w''_l)),\qquad l=1,\ldots, \tag{13}$$

$$\mathcal{D}=w_T,\qquad \mathcal{D}\in\mathbb{R}^{I\times D} \tag{14}$$

其中，SelfAtt 和 CrossAtt 分别表示几何感知自注意力和交叉注意力。有关几何感知注意力模块的更多细节，请参阅 AdaPoinTr。

多头重建器。为了与第 III-C 节所述分解后的目标点云相对应，我们提出了多头重建器，如图 2(e) 所示。其核心组件是 MLP与划分模块，它将 Transformer 的点代理特征 $\mathcal{D}$ 重塑为 U组点代理 $\mathcal{O} = \{\mathcal{O}^i\}_{i=1}^{U}$。这样既能使这些点代理彼此独立，又能保持它们之间的关联。每个对应于一组点代理 $\mathcal{O}^i$ 的重建头都会学习相对于种子点 $\mathcal{P}_0$的局部坐标偏移。将这些偏移量加到种子点上，即可得到 U 预测点云 $\{\mathcal{P}_i\}_{i=1}^{U}$。合并所有预测点云，即可得到最终的完整预测点云$\mathcal{P}_{out} \in R^{N_c \times 3}$。这种多头设计的优势在于，它将学习全局特征的难度分散到多个重建头中，从而提高重建的准确性和完整性。该过程可由以下公式表示:

$$\mathcal{O} = \psi([\mathcal{M}(\mathrm{MLP}(D)), \mathcal{D}, P_0]), \qquad \mathcal{O} \in \mathbb{R}^{U \times I \times D} \tag{15}$$

$$\mathcal{P}_i = \mathcal{P}_0 + \phi_i(\mathcal{O}^i), \qquad \mathcal{P}_i \in \mathbb{R}^{\frac{N_c}{U} \times 3}, i = 1, \ldots, U \tag{16}$$

$$\mathcal{P} = \bigcup_{i=1}^{U} \mathcal{P}_i, \qquad \mathcal{P} \in \mathbb{R}^{N_c \times 3} \tag{17}$$

其中，ψ 表示 MLP与划分模块，ϕ_i 表示第 i 个重建头。这里，我们采用简单的基于 MLP 的重建头。N_c 表示完整输出点云中的点数。

C. 目标点云分解

现有的点云补全方法通常依赖全局监督信号来引导最终点云的生成。这类信号通常基于所有点对之间的平均距离，例如倒角距离（CD）或推土机距离（EMD）。然而，单一的全局监督信号很容易使模型陷入局部最优，从而限制补全质量。受分而治之策略的启发，如图1所示，我们提出了一种新方法，将点云分解，并对每个子集分别施加监督。

点云无序的特性使得直接进行分解会产生随机且缺乏语义意义的子集。为解决这一问题，我们首先设计了一种基于主成分分析（PCA）的点云排序算法。该算法首先计算目标点云 $\mathcal{G}$的三个主成分。随后按照以下规则对点进行排序：优先依据点在第一主成分上的投影值；如果第一主成分的投影值相同，则依据第二主成分上的投影值排序；如果这些投影值也相同，则依据第三主成分上的投影值排序。此方法将无序点云转换为有序点集，为后续分解提供了结构化基础。

算法1PCA引导的点云分解

输入： 点云 $\mathcal{G} \in \mathbb{R}^{N_c \times 3}$，子集数量 U
输出： 子集 $\{\mathcal{G}_1, \ldots, \mathcal{G}_U\}$

$\boldsymbol{\mu} \leftarrow \frac{1}{N_c}\sum_{i=1}^{N_c} \mathcal{G}[i,:]$ {质心}
$\mathcal{G}_c \leftarrow \mathcal{G} - \boldsymbol{\mu}$ {居中}
$\boldsymbol{\Sigma} \leftarrow \frac{1}{N_c-1}\mathcal{G}_c^\top \mathcal{G}_c$ {协方差}
$(\mathbf{V}\ \boldsymbol{\Lambda}) \leftarrow \mathrm{eig}(\boldsymbol{\Sigma})$ {特征值分解}
按降序排列$\mathbf{V}\ \boldsymbol{\Lambda}$
$\mathbf{q} \leftarrow \mathbf{V}^\top \mathcal{G}_c$ {投影点}
$\mathcal{B} \leftarrow [(q_i, i) \mid q_i = \mathbf{q}[i,:], i = 1, \ldots, N_c]$
按 $\mathcal{B}$ 字典序 q_i 排序
$\mathcal{I} \leftarrow [i_1, i_2, \ldots, i_{N_c}]$ 来自 $\mathcal{B}$
$\mathcal{G}_s \leftarrow \mathcal{G}[\mathcal{I},:]$ {重排}
对于 $u = 0$ 至 $U-1$ **执行**
    $\mathcal{G}_{u+1} \leftarrow \{\mathcal{G}_s[j,:] \mid j \bmod U = u, 1 \le j \le N_c\}$
结束循环
返回 $\{\mathcal{G}_1, \ldots, \mathcal{G}_U\}$

为更好地监督点云生成，在获得有序点云后，我们进一步提出了一种均匀点云分解策略。由于我们的点云补全任务主要依赖于预测相对于种子点的偏移量，因此我们将排序后的点云 $\mathcal{G}_s$均匀划分为 U 个子点云，其数量与重建头的数量相对应。具体而言，每个子点云 $\mathcal{G}_i$ 通过以 U为间隔从排序后的点云 $\mathcal{G}_s$中采样点生成，从而确保各子集的均衡性和代表性。每个子点云都可以接受独立监督，从而提高局部几何结构的精确度和整体补全效果。点云排序与分解的详细步骤见算法1。

D. 灵活训练损失

倒角距离 (CD) 是点云补全中最常用的损失函数，以计算高效且具有顺序不变性著称。它计算生成点云 $\mathcal{P}$ 与真实点云 $\mathcal{G}$之间双向最近邻距离平方和:

$$CD(\mathcal{P}, \mathcal{G}) = \frac{1}{|\mathcal{P}|}\sum_{p \in \mathcal{P}} \min_{g \in \mathcal{G}} \|p - g\|_2 + \frac{1}{|\mathcal{G}|}\sum_{g \in \mathcal{G}} \min_{p \in \mathcal{P}} \|g - p\|_2 \tag{18}$$

然而，根据我们之前的工作 [41], ，我们发现，在引导点云生成时，倒角距离的两个组成部分关注的重点不同。我们定义:

$$CD_g(\mathcal{P}, \mathcal{G}) = \frac{1}{|\mathcal{G}|}\sum_{g \in \mathcal{G}} \min_{p \in \mathcal{P}} \|g - p\|_2 \tag{19}$$

$$CD_l(\mathcal{P}, \mathcal{G}) = \frac{1}{|\mathcal{P}|}\sum_{p \in \mathcal{P}} \min_{g \in \mathcal{G}} \|p - g\|_2 \tag{20}$$

其中，CD_g 计算真实值点与生成点之间的距离，引导生成过程趋向良好的全局分布，但容易陷入局部最优。
CD_l 计算生成点与真实值点之间的距离，并

必须与 CD_g 结合使用，以引导生成更优的局部细节。我们认为，采用相同权重进行训练并非最佳选择；这两个组件的使用应根据训练目标灵活调整，通常应为CD_g 分配更高的权重。本文的重点并非讨论如何设置权重，因此我们仅采用通常适用的权重设置。本文有三个需要监督的目标：种子点$\mathcal{P}_0$、每个部件的预测点 $\{\mathcal{P}_i\}_{i=1}^{U}$，以及最终预测的完整点云 $\mathcal{P}$。对于种子点 $\mathcal{P}_0$ ，我们只要求其具备初始全局结构，因此仅使用 CD_g。对于后两个目标，全局分布和局部结构都很重要。因此，我们将总体损失函数设定如下：

$$\mathcal{L} = \mathcal{L}_{\mathcal{P}_0} + \frac{1}{U}\sum_{i=1}^{U}\mathcal{L}_{\mathcal{P}_i} + \mathcal{L}_{\mathcal{P}_{out}} \tag{21}$$

其中

$$\mathcal{L}_{\mathcal{P}_0} = CD_g(\mathcal{P}_0, \mathcal{G}) \tag{22}$$

$$\mathcal{L}_{\mathcal{P}_i} = CD_l(\mathcal{P}_i, \mathcal{G}_i) + 2CD_g(\mathcal{P}_i, \mathcal{G}_i) \tag{23}$$

$$\mathcal{L}_{\mathcal{P}_{out}} = CD_l(\mathcal{P}_{out}, \mathcal{G}) + 2CD_g(\mathcal{P}_{out}, \mathcal{G}) \tag{24}$$

IV. 评估

本节中，我们评估 PPC-MT 在两个常见点云补全基准 PCN [10] 和 KITTI [42] 上的补全能力。我们还在 PoinTr [20], 提出的另外两个数据集 ShapeNet-55 和 ShapeNet-34 上进行训练和测试。最后，通过消融研究，我们验证了 PPC-MT 中所提出方法的有效性。

*A. PCN*数据集上的实验

数据集。 PCN数据集是从 ShapeNet数据集中选取的一个包含 8 个类别的子集，应用广泛。按照以往的工作 [10], ，我们的训练集包含 28,974 个样本，测试集包含 1,200 个样本。完整点云（16,384 个点）通过从网格模型表面均匀采样获得。不完整点云则由 8 个不同视点的深度图反向投影生成，再填充至 2,048 个点作为输入。

评估指标。 当前研究大多关注 CD [14] 和 F 分数 [15] 指标，但这些指标并不能全面反映点云生成结果的质量。为进行清晰、全面的比较，我们采用了更广泛的互补评估指标。具体而言，我们使用倒角距离 ℓ_1 (CD-ℓ_1)、推土机距离 (EMD) [14], 、密度感知倒角距离 (DCD) [16], 和 F 分数进行定量评估。CD-ℓ_1 衡量两个点云之间的平均最近邻距离，主要关注局部几何细节的重建质量；数值越低，表示局部重建越准确。EMD 衡量将一个点云转换为另一个点云所需的最小“代价”，能更好地反映全局形状分布的相似度；数值越低越好。DCD 是倒角距离的一种密度感知变体，它会考虑

表 I PCN数据集上的结果。（倒角距离-$\ell_1 \times 10^3$，EMD$\times 10^3$ 和 F1 分数@1%）

方法	倒角距离-$\ell_1\downarrow$	DCD↓	EMD↓	F1↑
FoldingNet [6]	14.31	-	-	-
TopNet [7]	12.15	-	-	-
AtlasNet [9]	10.85	-	-	0.616
CRN [12]	8.51	-	-	0.652
PCN [10]	9.64	-	-	0.695
GRNet [19]	8.83	0.622	-	0.708
NSFA [43]	8.06	-	-	0.734
PMP-Net++ [44]	7.56	0.611	-	0.781
PoinTr [20]	7.26	0.571	24.57	0.797
SnowflakeNet [21]	7.21	0.585	-	0.801
SeedFormer [22]	6.74	0.567	27.91	0.821
ProxyFormer [24]	6.77	0.555	-	-
SVDFormer [25]	6.54	0.532	24.58	0.841
AdaPoinTr [23]	**6.53**	0.536	24.12	0.845
PPC-MT（我们的方法）	6.60	**0.491**	**17.43**	**0.860**

局部密度分布，在评估局部细节的同时确保区域密度一致性，尤其适用于评估非均匀采样点云；数值越低越好。F 分数结合精确率和召回率，计算给定阈值下点云匹配的 F1 分数，兼顾对重建完整性和准确性的评估；通常数值越高，整体重建质量越好。结合使用这些指标，可以从不同角度全面评估点云补全模型。

定量比较。如表 I 所示，PPC-MT 在 PCN数据集上取得了显著的性能提升。具体而言，我们的方法在三项关键指标上达到了最先进的结果：DCD（0.491）、EMD（17.43）和 F 分数（ 0.860 ），表明 PPC-MT 生成的点云在几何形状上更接近真实值。尽管 CD-ℓ_1 分数（6.60）略高于 SVDFormer（6.54）和 AdaPoinTr（6.53），但差异很小。值得注意的是，与当前最先进的方法 AdaPoinTr 相比，我们的方法将 F 分数提高了 1.5%（从 0.845 提升至 0.860），将 EMD 降低了 27.7%（从 24.12 降至 17.43），并将 DCD 降低了 8.4%（从 0.536 降至 0.491）。这些结果充分证明了我们提出的方法在捕捉点云的局部细节和全局结构方面具有优越性，为点云补全任务提供了一种新的解决方案。

定性比较。图 5 展示了不同方法在 PCN数据集全部八个类别上的补全结果。与其他方法相比，我们的方法不仅生成了更接近真实值的分布，还展现出更强的细节恢复能力（例如第一行飞机的尾翼、第二行柜子的腿、第三行汽车的后视镜等）。

B. ShapeNet-55/34 上的实验

数据集。我们还在 PoinTr [20] 提出的另外两个数据集 ShapeNet-55 和 ShapeNet-34 上评估了模型。在这两个数据集中，输入的不完整点云包含

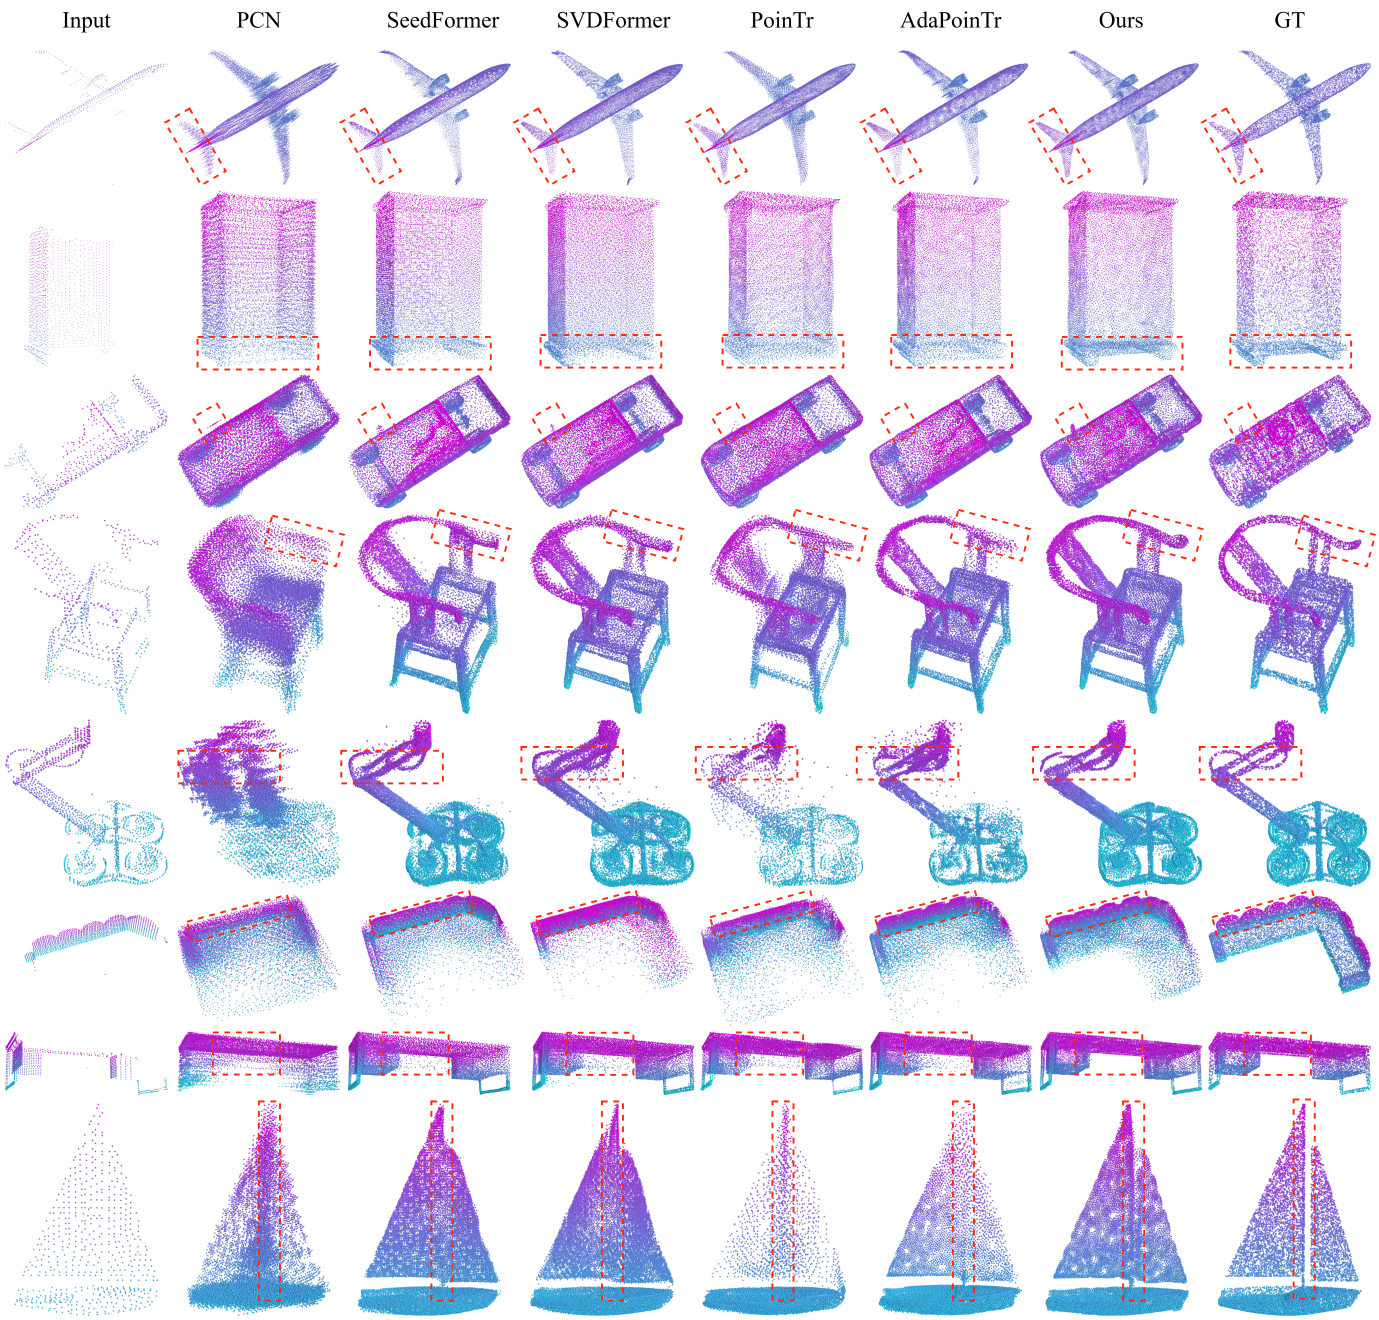

图 5. PCN数据集的定性比较。所有方法均以第一列中的点云作为输入。我们用红色边界框标出了一些区域，以清晰展示我们方法的有效性。

表 II ShapeNet55 上的结果。所有报告结果均为三个难度级别上的平均值。（CD-$\ell_1 \times 10^3$、CD-$\ell_2 \times 10^3$、EMD$\times 10^3$ 和 F1 分数@1%）

方法	倒角距离-ℓ_1 ↓	倒角距离-ℓ_2↓	DCD↓	EMD↓	F1(mCls)↑	F1(Ova)↑
FoldingNet [6]	-	3.12	0.082	-	-	0.082
TopNet [7]	-	2.91	0.126	-	-	0.126
PCN [10]	-	2.66	0.618	-	-	0.133
GRNet [19]	-	1.97	0.592	-	-	0.238
PoinTr [20]	13.95	1.05	0.539	38.86	0.468	0.499
SeedFormer [22]	13.97	0.92	0.552	37.09	0.444	0.473
ProxyFormer [24]	-	0.93	0.549	-	-	0.483
SVDFormer [25]	13.92	0.82	0.542	35.36	0.444	0.474
AdaPoinTr [23]	12.94	**0.81**	0.635	27.58	0.402	0.433
PPC-MT（本文方法）	**12.71**	0.82	**0.523**	27.11	**0.509**	**0.539**

2,048 个点，完整的真实值包含 8,192 个点。与 PoinTr 类似，在训练期间，我们随机选择一个视点，并删除 2,048 到 6,144 个点（相当于完整点云的 25% 到 75%）。随后将剩余点下采样至 2,048 个，作为训练输入。被删除的部分下采样至 1,536 个点，并作为缺失部分的真实值。在测试期间，我们选取 8 个固定视点，并将不完整点的数量设为 2,048、4,096 或 6,144（分别占完整点云的 25%、50% 或 75%），对应三个难度级别（简单、中等、困难）。

评估指标。 为与以往研究保持

表 III ShapeNet34 上的结果。所有报告的结果均为三个难度级别的平均值。（倒角距离-$\ell_1 \times 10^3$、倒角距离-$\ell_2 \times 10^3$、EMD$\times 10^3$ 和 F1 分数@1%）

方法	34 个已见类别					21 个未见类别					
	倒角距离-ℓ_1↓	倒角距离-ℓ_2↓	DCD↓	EMD↓	F1↑	倒角距离-ℓ_1↓	倒角距离-ℓ_2↓	DCD↓	EMD↓	F1（类别平均值）↑	F1（0va）↑
FoldingNet [6]	-	2.35	-	-	0.139	-	3.62	-	-	-	0.095
TopNet [7]	-	2.31	-	-	0.171	-	3.50	-	-	-	0.121
PCN [10]	-	2.22	0.624	-	0.154	-	3.85	0.644	-	-	0.101
GRNet [19]	-	1.74	0.600	-	0.251	-	2.99	0.625	-	-	0.216
PoinTr [20]	15.07	1.09	0.604	42.35	0.402	17.64	1.75	0.629	46.30	0.370	0.360
SnowflakeNet [21]	13.80	0.81	0.594	27.86	0.414	14.43	1.00	0.588	28.03	0.399	0.378
SeedFormer [22]	-	0.83	0.561	-	0.452	-	1.34	0.586	-	-	0.402
SVDFormer [24]	13.40	0.74	0.540	35.35	0.458	15.53	1.29	0.555	38.83	0.424	0.404
ProxyFormer [24]	-	0.81	0.556	-	0.466	-	1.42	0.583	-	-	0.415
AdaPoinTr [23]	-	0.73	-	-	0.469	-	1.23	-	-	-	0.416
PCD-MT（我们的方法）	**12.11**	**0.70**	**0.520**	**26.38**	**0.523**	**14.12**	**1.27**	**0.533**	**28.74**	**0.490**	**0.472**

一致，除了 CD-ℓ_1、推土机距离 (EMD) 和密度感知倒角距离 (DCD)，我们还将 CD-ℓ_2 作为一项评估指标。值得注意的是，ShapeNet-55 测试数据和 ShapeNet-34 未见类别中的不同类别，其实例数量各不相同。以往研究通常报告其他指标的类别平均值，而 F 分数则通常报告实例平均值，这可能会造成混淆。因此，对于实例数量不平衡的测试数据，我们同时报告类别平均 F1 分数 (mCls) 和总体实例平均 F1 分数 (Ova)。除非另有说明，本文报告的所有平均指标均为类别平均值。

定量比较。 表 II 和表 III 分别列出了多种方法在 ShapeNet-55 和 ShapeNet-34 上的定量表现。所有指标均取简单、中等和困难设置下的平均值。表 II 显示，PPC-MT 在所有指标上均表现出色且稳定，没有出现类似 SVDFormer 在 EMD 或 AdaPoinTr 在 DCD 和 F1 表现上的明显失衡。尤为突出的是，该方法的 F1 分数显著提升，表明补全后的点云在精确率和召回率之间取得了更好的平衡，也体现了其卓越的点云补全能力。表 III 显示，在 34 个已见类别上，PPC-MT 在所有报告指标上均取得了优异表现。为评估泛化能力，我们在 21 个未见类别上测试了模型表现。PPC-MT 依然表现强劲，在 CD-L1、DCD、EMD 和 F1 指标上均取得了最先进的结果。这凸显了模型有效补全训练期间未见类别形状的能力。这些实验结果证明了 PPC-MT 的整体优越性能，尤其是其在 DCD 和 F1 分数方面的领先优势，充分验证了我们方法的稳健性和强大泛化能力。

定性比较。图 6 展示了 ShapeNet-55 数据集中八个不属于 PCN 数据集的类别的可视化结果。所有可视化结果都清楚地表明，我们的方法生成的结果更接近真实分布，且局部细节更好。这些较少见类别上的出色结果进一步证明了我们方法的广泛适用性。

*C. KITTI*上的实验

数据集。 为展示我们的方法在真实场景中的泛化性能，我们在 KITTI数据集上进行了实验。遵循先前的方法 [19], [20]，[23]，我们使用 ShapeNetCars 数据集（ShapeNet 的汽车子集）对在 PCN数据集上预训练的模型进行微调，然后在 KITTI Car 数据集上评估其性能，以进行公平比较。

评估指标。 由于KITTI数据集缺少完整的真实点云，因此很难从定量角度评估补全结果的质量。因此，我们从多个角度提供评估结果以供参考。除了采用PCN [10], 中的保真度、一致性和最小匹配距离（MMD）外，我们还将均匀度 [19], [45]作为评估指标。所有评估指标均遵循数值越低、性能越好的原则。尽管GRNet指出，保真度和MMD不太适合评估KITTI数据集上的结果，但它们仍能在一定程度上反映补全结果的分布特征，因此我们仍提供这些结果。具体而言，保真度计算输入中每个点到输出中其最近邻的平均距离，用于衡量输入的保留程度；MMD计算输出与ShapeNet中最接近该输出点云的汽车点云之间的倒角距离（CD），用于衡量输出与典型汽车的相似程度；一致性计算同一实例在连续帧中的补全输出之间的平均倒角距离，用于衡量网络输出对输入变化的一致性；均匀度通过采样M个输出点（本文设为1000个）并分析其局部分布来衡量整体分布的均匀程度，可表示为：

$$\text{Uniformity}(p) = \frac{1}{M}\sum_{i=1}^{M} \text{U}_{\text{imbalance}}(S_i)\text{U}_{\text{clutter}}(S_i) \quad (25)$$

其中，$S_i (i = 1, 2, ..., M)$ 是通过半径为 $\sqrt{p}$ 的球查询，从输出 $\mathcal{P}$ 中经最远点采样获得的 M 个种子点所得到的点子集。$\text{U}_{\text{imbalance}}$ 和 $\text{U}_{\text{clutter}}$ 分别表示全局分布均匀度和局部分布均匀度。

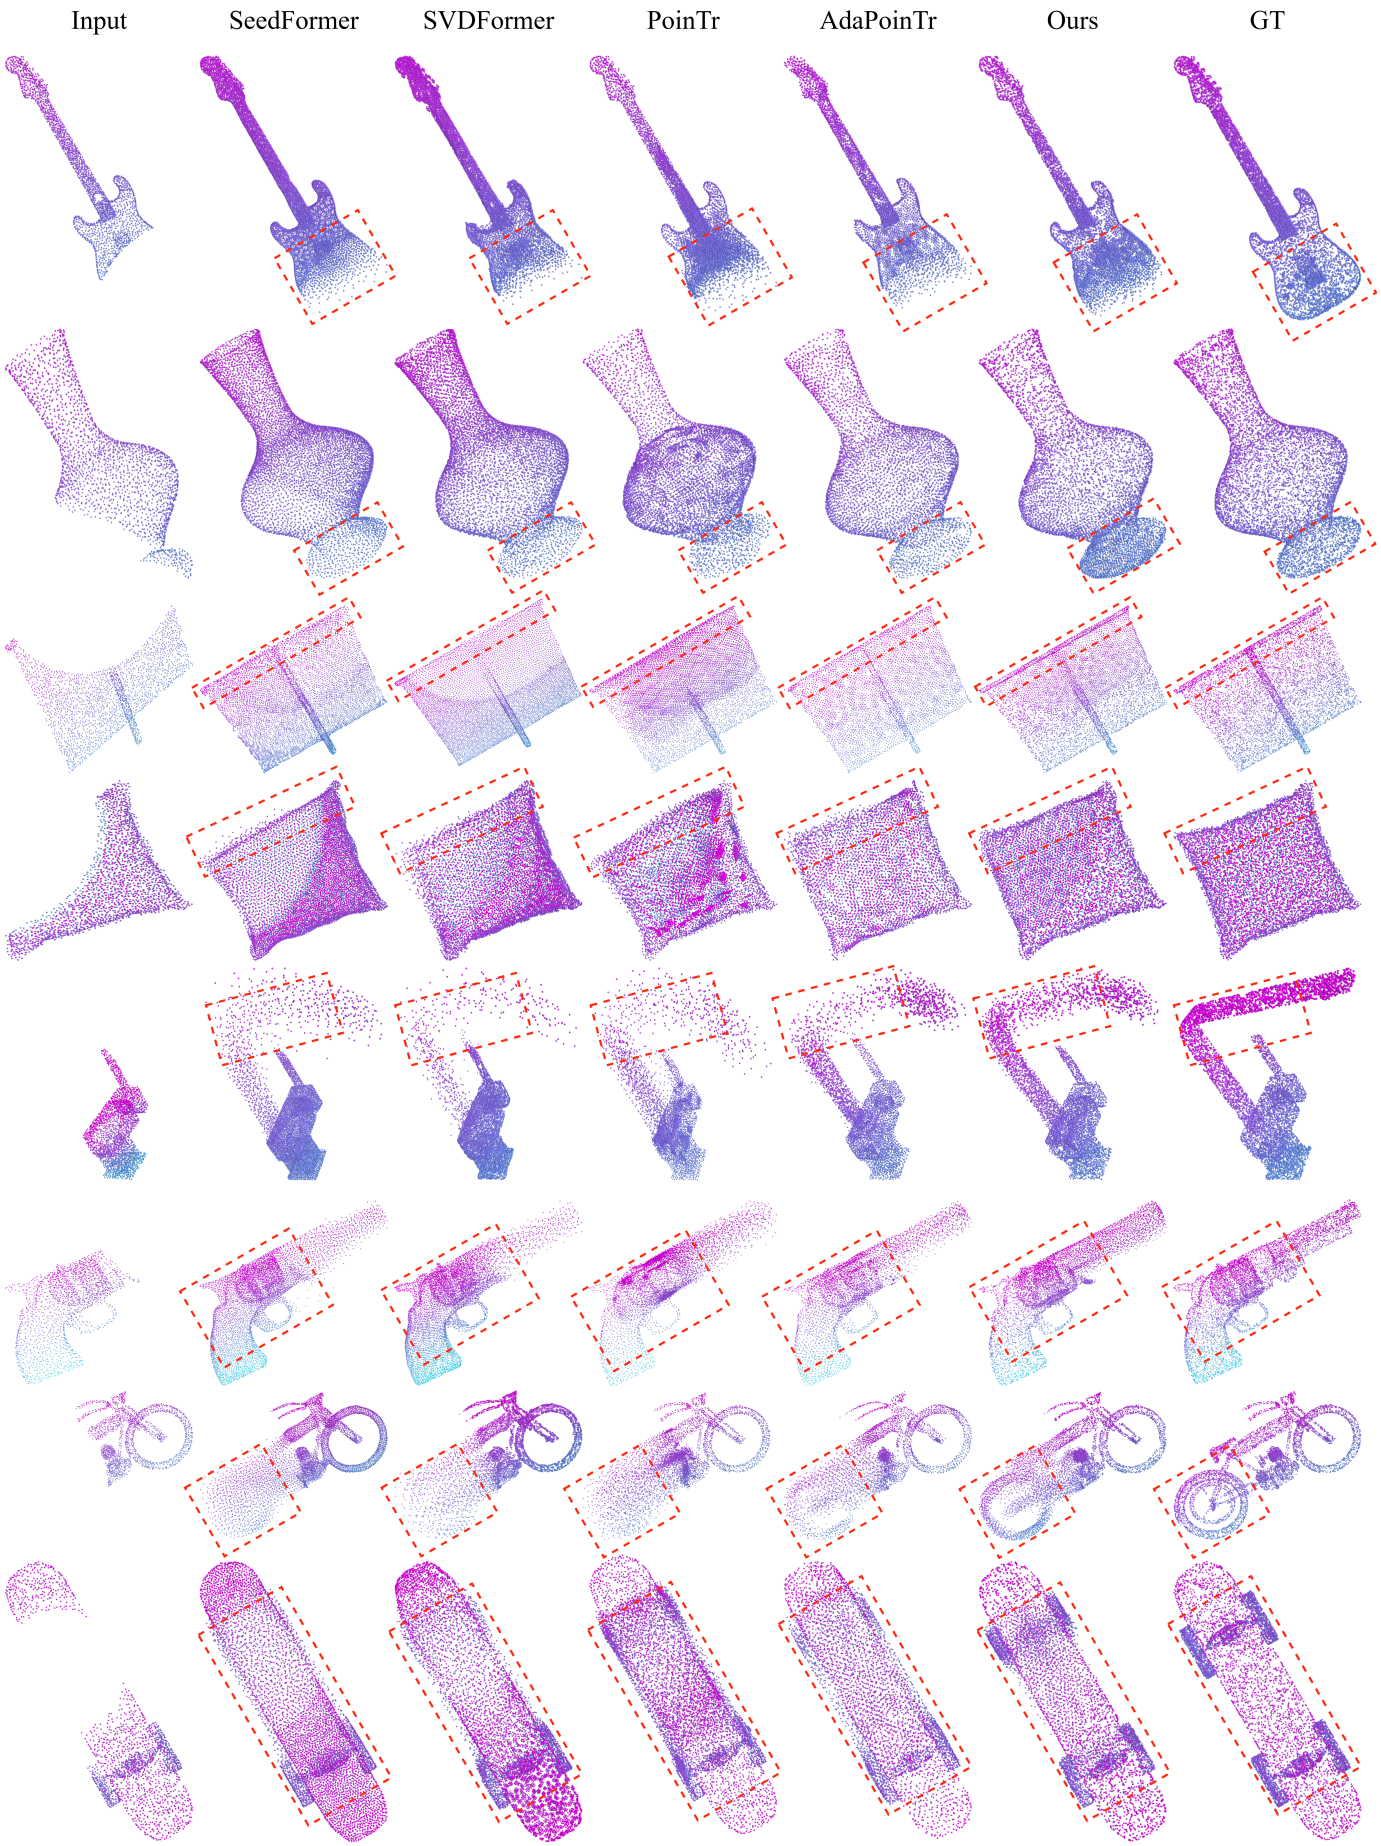

图 6. ShapeNet55 的定性比较。以上所有方法均以第一列中的点云作为输入。我们用红色边界框标出了一些区域，清楚地展示了我们方法的有效性。

表 IV KITTI数据集上的结果。（保真度 $\times 10^3$，最大均值差异 $\times 10^3$，一致性 $\times 10^3$）

方法	保真度↓	MMD↓	一致性↓	不同 p的均匀度↓				
				0.4%	0.6%	0.8%	1.0%	1.2%
GRNet [19]	0.816	0.568	0.407	2.69	4.98	7.42	9.93	12.46
PoinTr [20]	0.000	0.526	0.512	4.21	7.55	11.46	15.77	20.44
AdaPoinTr [23]	1.439	**0.366**	0.569	15.17	21.87	28.56	35.09	41.62
PPC-MT（我们的方法）	1.487	0.374	**0.403**	**1.46**	**3.19**	**5.45**	**8.16**	**11.24**

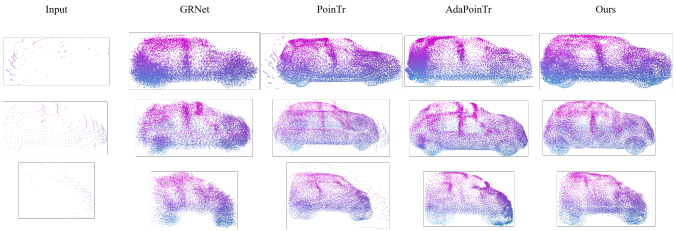

图 7. KITTI 的定性比较。上述所有方法均以第一列中的点云作为输入。

$$\mathrm{U}_{\mathrm{imbalance}}(S_i) = \frac{(|S_i| - \hat{n})^2}{\hat{n}} \tag{26}$$

其中$\hat{n} = p|\mathcal{P}|$ 是 S_i中的期望点数。

$$\mathrm{U}_{\mathrm{clutter}}(S_i) = \frac{1}{|S_i|} \sum_{j=1}^{|S_i|} \frac{(d_{i,j} - \hat{d})^2}{\hat{d}} \tag{27}$$

其中$d_{i,j}$ 表示 S_i中第 j个点到其最近邻的距离，且当 S_i 呈均匀分布时，$\hat{d}$ 近似为 $\sqrt{\frac{2\pi p}{|S_i|\sqrt{3}}}$。

定量比较。表 IV 给出了 PPC-MT 方法与 GRNet、PoinTr 和 AdaPoinTr 在 KITTI数据集上四项关键评估指标的定量比较。GRNet 和 PoinTr 的结果基于原作者提供的预训练权重；而 AdaPoinTr 缺乏公开可用的预训练模型，我们按照其官方代码重新训练模型以获得结果。就保真度指标而言，PoinTr 得分为 0，因其结构设计保留了所有输入点。PPC-MT 在保真度和最大均值差异上的表现表明，其补全结果倾向于重建输入点云，并生成与 PCN 数据集中汽车类别更为相似的结果。在一致性上的最优表现表明，我们的网络在保持输出一致性方面具有稳健性。尤其值得注意的是，PPC-MT 在均匀度指标评估中表现突出，在所有评估的邻域参数 p 上均取得最佳结果，显著优于其他对比方法。这充分证明了我们的方法在生成均匀分布点云方面的卓越能力。

定性比较。图7展示了各种方法的定性比较结果。从视觉效果可以直观地看出，PPC-MT生成的点云不仅在整体形态上呈现出更真实的结构，而且在局部细节上展现出更平滑、更清晰的几何特征。相比之下，其他方法在细节保真度和结构完整性方面存在一定局限。

表 V 不同数量重建头的影响。（倒角距离-$\ell_1 \times 10^3$，EMD$\times 10^3$ 和 F1 分数@1%）

重建头数量	倒角距离-ℓ_1↓	DCD↓	EMD↓	F1↑
2	**6.58**	0.502	18.59	0.857
4（本文方法）	6.60	**0.491**	17.43	**0.860**
8	6.71	0.494	**17.09**	0.855

表 VI 分解策略的影响。（倒角距离-$\ell_1 \times 10^3$，EMD $\times 10^3$ 和 F1 分数@1%）

方法	倒角距离-ℓ_1↓	DCD↓	EMD↓	F 分数↑
随机分解	6.61	0.495	17.57	0.858
均匀分解（我们的方法）	**6.60**	**0.491**	**17.43**	**0.860**

D. 消融研究

在本小节中，我们使用PCN数据集 [10] 对PPC-MT 进行消融研究，以证明所提出组件的有效性。默认情况下，所有实验设置均与第 IV-A 节中的设置相同。

重建头的数量。并行重建策略是 PPC-MT 框架的关键。与串行策略决定最佳补全阶段数量的方式类似，并行策略需要确定最佳重建头数量。如表 V 所示，我们比较了重建头数量不同的变体。结果表明，当重建头数量为 4 时，重建性能最佳，DCD、EMD 和 F1 均取得了最佳分数。

分解策略。 重建头针对的是预测点云，而分解策略针对的是真实点云。在我们的 PPC-MT 框架中，分解策略对于重建结果也至关重要。为验证分解策略的有效性，我们比较了不同的方法。我们的框架要求分解后的点云具有良好的全局覆盖。一些分解方法表现不佳，因此我们仅展示随机分解与基于 PCA 的排序后进行均匀分解之间的比较。表 VI 中的结果证明了我们所提出策略的有效性。

混合架构。 为验证 PPC-MT 中所提出混合架构的有效性，我们设计了一种网络变体，仅将编码器替换为 Transformer，同时保持其他所有模块不变。如表 VII 所示，Mamba 编码器在参数量和浮点运算次数方面均优于 Transformer 编码器，同时也取得了更好的结果。

E. 复杂度分析

表 VIII 给出了复杂度分析，展示了参数数量、浮点运算次数以及在 PCN数据集上的结果，均在单块 NVIDIA 3090 GPU 上测得。比较结果表明，我们的方法在成本与性能之间取得了良好的权衡。

表 VII 不同架构的影响。（倒角距离-$\ell_1 \times 10^3$，EMD $\times 10^3$ 和 F1 分数@1%）

方法	层数	参数量	浮点运算次数	倒角距离-L1↓	DCD↓	EMD↓	F1↑
Transformer 编码器	6	62.81M	33.48G	6.74	0.509	19.02	0.846
Transformer 编码器	12	75.43M	36.71G	6.63	0.494	17.69	0.857
Mamba 编码器（我们的方法）	12	55.50M	30.68G	**6.60**	**0.491**	**17.43**	**0.860**

表 VIII 复杂度分析。（倒角距离-$\ell_1 \times 10^3$，EMD$\times 10^3$ 和 F1 分数@1%）

方法	参数量	浮点运算次数	倒角距离-L1↓	DCD↓	EMD↓	F1↑
SeedFormer [22]	3.31M	53.76G	6.74	0.567	27.91	0.821
SVDFormer [25]	32.63M	39.26G	6.54	0.532	24.58	0.841
AdaPoinTr [23]	32.49M	15.08G	6.53	0.536	24.12	0.845
Ours	55.50M	30.68G	**6.60**	**0.491**	**17.43**	**0.860**

V. 结论

本文提出了 PPC-MT，一种专门面向点云补全任务的新型并行框架。通过引入基于 Mamba 与 Transformer 的混合架构，以及由基于 PCA 的分解所引导的并行重建策略，PPC-MT 在多个点云补全基准上取得了最先进（SOTA）的性能，展现出显著效果，尤其是在提升点分布均匀性与细节恢复方面。这验证了我们的方法可作为点云补全领域的一种新解决方案，在高效率与高质量之间取得平衡。

此外，我们认为，PPC-MT 所体现的核心技术原理具有超越补全任务本身、应用于计算机图形学的更广泛价值。该混合架构为平衡全局与局部特征学习提供了一种有效范式。基于 PCA 的几何结构化方法，为处理图形学中常见的无序几何数据（如点云和网格）提供了新思路。并行合成策略则展现出一种颇具前景的方向，可用于大规模生成日益复杂的数字资产。这些原理有望启发计算机图形学多个领域的未来研究，包括三维形状生成、几何分析和高效表示学习。未来的工作可以探索更先进的几何结构化方法，并将这一并行范式扩展到其他三维表示。

参考文献

[1] Y. Guo、H. Wang、Q. Hu、H. Liu、L. Liu 和 M. Bennamoun，《三维点云深度学习：综述》，IEEE 模式分析与机器智能汇刊，第43卷，第12期，第4338–4364页，2020年。[2] S. Chen、B. Liu、C. Feng、C. Vallespi-Gonzalez 和 C. Wellington，《面向自动驾驶的三维点云处理与学习：对地图创建、定位和感知的影响》，IEEE 信号处理杂志，第38卷，第1期，第68–86页，2020年。[3] F. Pomerleau、F. Colas、R. Siegwart 等，《移动机器人学中的点云配准算法综述》，《机器人学基础与趋势》，第4卷，第1期，第1–104页，2015年。[4] Y. Chen、Q. Wang、H. Chen、X. Song、H. Tang 和 M. Tian，《增强现实技术概述》，载于《物理学杂志：会议系列》，第1237卷，第2期。IOP 出版社，2019年，第022082页。[5] J. Li、W. Gao、Y. Wu、Y. Liu 和 Y. Shen，《利用 RGB-D 相机进行高质量室内场景三维重建：简要综述》，《计算视觉媒体》，第8卷，第3期，第369–393页，2022年。[6] Y. Yang、C. Feng、Y. Shen 和 D. Tian，《FoldingNet：三维点云上的可解释无监督学习》，arXiv 预印本 arXiv:1712.07262，第2卷，第3期，第5页，2017年。[7] L. P. Tchapmi、V. Kosaraju、H. Rezatofighi、I. Reid 和 S. Savarese，《TopNet：结构化点云解码器》，载于 IEEE/CVF 计算机视觉与模式识别会议论文集，2019年，第383–392页。[8] M. Liu、L. Sheng、S. Yang、J. Shao 和 S.-M. Hu，《用于稠密点云补全的变形与采样网络》，载于 AAAI 人工智能会议论文集，第34卷（第07期），2020年，第11 596–11 603页。[9] T. Groueix、M. Fisher、V. G. Kim、B. C. Russell 和 M. Aubry，《一种用于学习三维表面生成的纸浆塑形方法》，载于 IEEE 计算机视觉与模式识别会议论文集，2018年，第216–224页。´ W. Yuan、T. Khot、D. Held、C. Mertz 和 M. Hebert，《PCN：点云补全网络》，载于2018年国际三维视觉会议（3DV）。IEEE，2018年，第728–737页。[10] X. Wen、P. Xiang、Z. Han、Y.-P. Cao、P. Wan、W. Zheng 和 Y.-S. Liu，《PMP-Net：通过学习多步点移动路径进行点云补全》，载于 IEEE/CVF 计算机视觉与模式识别会议论文集，2021年，第7443–7452页。[11] X. Wang、M. H. Ang 和 G. H. Lee，《用于自监督点云补全的级联细化网络》，IEEE 模式分析与机器智能汇刊，第44卷，第11期，第8139–8150页，2021年。[12] Z. Huang、Y. Yu、J. Xu、F. Ni 和 X. Le，《PF-Net：用于三维点云补全的点分形网络》，载于 IEEE/CVF 计算机视觉与模式识别会议论文集，2020年，第7662–7670页。[13] H. Fan、H. Su 和 L. J. Guibas，《用于从单幅图像进行三维物体重建的点集生成网络》，载于 IEEE 计算机视觉与模式识别会议论文集，2017年，第605–613页。[14] M. Tatarchenko、S. R. Richter、R. Ranftl、Z. Li、V. Koltun 和 T. Brox，《单视图三维重建网络学到了什么？》，载于 IEEE/CVF 计算机视觉与模式识别会议论文集，2019年，第3405–3414页。[15] T. Wu、L. Pan、J. Zhang、T. Wang、Z. Liu 和 D. Lin，《密度感知倒角距离：点云补全的综合度量指标》，arXiv 预印本 arXiv:2111.12702，2021年。[16] M. Kazhdan、M. Bolitho 和 H. Hoppe，《泊松表面重建》，载于第四届欧洲图形学几何处理研讨会论文集，第7卷，第4期，2006年。[17] W. Wang、H. Pottmann 和 Y. Liu，《通过基于曲率的平方距离最小化将 B样条曲线拟合到点云》，《ACM 图形学汇刊》（ToG），第25卷，第2期，第214–238页，2006年。[18] H. Xie、H. Yao、S. Zhou、J. Mao、S. Zhang 和 W. Sun，《GRNet：用于稠密点云补全的网格化残差网络》，载于欧洲计算机视觉会议。施普林格，2020年，第365–381页。[19] X. Yu、Y. Rao、Z. Wang、Z. Liu、J. Lu 和 J. Zhou，《PoinTr：利用几何感知变换器进行多样化点云补全》，载于 IEEE/CVF 国际计算机视觉会议论文集，2021年，第12 498–12 507页。[20] P. Xiang、X. Wen、Y.-S. Liu、Y.-P. Cao、P. Wan、W. Zheng 和 Z. Han，《SnowflakeNet：通过带有跳跃式 Transformer 的雪花点反卷积进行点云补全》，载于 IEEE/CVF 国际计算机视觉会议论文集，2021年，第5499–5509页。

[22] H. Zhou、Y. Cao、W. Chu、J. Zhu、T. Lu、Y. Tai 和 C. Wang，《SeedFormer：基于块种子的点云补全与上采样变换器》，载于欧洲计算机视觉会议。施普林格，2022年，第416–432页。[23] X. Yu、Y. Rao、Z. Wang、J. Lu 和 J. Zhou，《AdaPoinTr：利用自适应几何感知变换器进行多样化点云补全》，IEEE 模式分析与机器智能汇刊，2023年。[24] S. Li、P. Gao、X. Tan 和 M. Wei，《ProxyFormer：借助代理对齐和缺失部分敏感变换器进行点云补全》，载于 IEEE/CVF 计算机视觉与模式识别会议论文集，2023年，第9466–9475页。[25] Z. Zhu、H. Chen、X. He、W. Wang、J. Qin 和 M. Wei，《SVD-Former：通过自视图增强和自结构双生成器补全点云》，载于 IEEE/CVF 国际计算机视觉会议论文集，2023年，第14 508–14 518页。[26] R. Xu、S. Yang、Y. Wang、Y. Cai、B. Du 和 H. Chen，《视觉Mamba：综述与新展望》，arXiv 预印本 arXiv:2404.18861，2024年。[27] A. Gu、K. Goel 和 C. R´e，《利用结构化状态空间高效建模长序列》，arXiv 预印本 arXiv:2111.00396，2021年。[28] J. T. Smith、A. Warrington 和 S. W. Linderman，《用于序列建模的简化状态空间层》，arXiv 预印本 arXiv:2208.04933，2022年。[29] D. Y. Fu、T. Dao、K. K. Saab、A. W. Thomas、A. Rudra 和 C. R´e，《Hungry Hungry Hippos：探索基于状态空间模型的语言建模》，arXiv 预印本 arXiv:2212.14052，2022年。[30] A. Gu 和 T. Dao，《Mamba：利用选择性状态空间进行线性时间序列建模》，arXiv 预印本 arXiv:2312.00752，2023年。[31] L. Zhu、B. Liao、Q. Zhang、X. Wang、W. Liu 和 X. Wang，《Vision Mamba：利用双向状态空间模型进行高效视觉表征学习》，2024年。 [在线]。获取地址：https://arxiv.org/abs/2401. 09417[32] Y. Liu、Y. Tian、Y. Zhao、H. Yu、L. Xie、Y. Wang、Q. Ye、J. Jiao 和 Y. Liu，《VMamba：视觉状态空间模型》，2024年。 [在线]。获取地址：https://arxiv.org/abs/2401 10166 。J. Zhou、C. Wei、L. Wang、[33] C. Zhang、D. Yang、Y. Zhang、Y. Fan 和 J. Feng，《U-Mamba：增强生物医学图像分割中的长程依赖》，arXiv 预印本 arXiv:2401.05955，2024年。 [在线]。获取地址：https://arxiv.org/abs/2401 05955 。D. Liang、X. Zhou、W. Xu、[34] X. Zhu、Z. Zou、X. Ye、X. Tan 和 X. Bai，《PointMamba：用于点云分析的简单状态空间模型》，载于《神经信息处理系统进展》，2024年。 [在线]。获取地址：https://arxiv.org/abs/2402 10739 。[35] A. H. Zhang、Z. Gu、C. Lassner、X. Tang、W. Sun、C. Zhang、X. Zhan、J. Gao、J. Wang 和 S. Tang，《Point Cloud Mamba：通过状态空间模型进行点云学习》，arXiv 预印本 arXiv: *2403 00762*, 。在线。获取地址：https://arxiv.org/abs/。2024 [ ] 2403 00762 [36] 3 X. Han、Y. Tang、Z. Wang 和 X. Li，《Mamba D：利用状态空间模型增强三维点云分析中的局部特征》，arXiv 预印本 arXiv:2404.14966，2024年。 [在线]。获取地址：https: //arxiv.org/abs/2404 14966 。Z. Wang、W. Li、Y. Zhang、Z. Wu、J. Wang[37] 和 P. Chen，《PoinTramba：用于点云分析的混合变换器-Mamba框架》，arXiv 预印本 arXiv:2405.15463，2024年。 [在线]。获取地址：https://arxiv.org/abs/2405 15463 。Y. Pang、W. Wang、F. E. Tay、W. Liu、Y. Tian[38] 和 L. Yuan，《用于点云自监督学习的掩码自编码器》，载于欧洲计算机视觉会议。施普林格，2022年，第604–621页。[39] T. Dao 和 A. Gu，《变换器即状态空间模型：通过结构化状态空间对偶性实现广义模型与高效算法》，arXiv 预印本 arXiv:2405.21060，2024年。[40] D. Hendrycks 和 K. Gimpel，《高斯误差线性单元（GELU）》，arXiv 预印本 arXiv:1606.08415，2016年。[41] J. Li、S. Tian、L. Yu 和 X. Ning，《灵活加权倒角距离：用于点云补全的增强目标函数》，arXiv 预印本 arXiv:2505.14218，2025年。[42] A. Geiger、P. Lenz、C. Stiller 和 R. Urtasun，《视觉与机器人学相遇：KITTI数据集》，《国际机器人研究杂志》，第32卷，第11期，第1231–1237页，2013年。[43] X. Zhang、Y. Feng、S. Li、C. Zou、H. Wan、X. Zhao、Y. Guo 和 Y. Gao，《视图引导的点云补全》，载于 IEEE/CVF 计算机视觉与模式识别会议论文集，2021年，第15 890–15 899页。[44] X. Wen、P. Xiang、Z. Han、Y.-P. Cao、P. Wan、W. Zheng 和 Y.-S. Liu，《PMP-Net：通过变换器增强的多步点移动路径进行点云补全》，IEEE 模式分析与机器智能汇刊，第45卷，第1期，第852–867页，2022年。

[45] R. Li、X. Li、C.-W. Fu、D. Cohen-Or 和 P.-A. Heng，“Pu-gan：一种点云上采样对抗网络”，载于*IEEE/CVF* 国际计算机视觉会议论文集，2019年，第7203–7212页。



Jie Li 于2019年在中国合肥工业大学获得学士学位。目前，他正在新疆大学计算机科学与技术学院攻读博士学位。其研究兴趣包括模式识别和三维视觉。



Shengwei Tian 分别于1997年、2004年和2010年获得中国乌鲁木齐新疆大学信息科学与工程学院的学士、硕士和博士学位。自2002年起，他在新疆大学软件学院任教，现为教授。其研究兴趣包括人工智能、自然语言处理和网络空间安全。

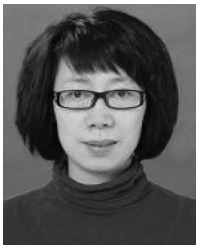

Long Yu 于1997年和2008年分别获得中国乌鲁木齐新疆大学信息科学与工程学院的学士学位和硕士学位。自2002年起，她一直在新疆大学信息科学与工程学院任教，目前为教授。她的研究兴趣包括人工智能、数据挖掘、自然语言处理和网络空间安全。

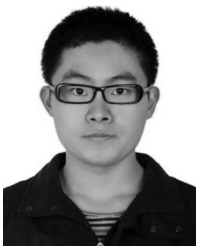

Xin Ning 于2017年获得中国科学院半导体研究所的博士学位。目前，他是中国科学院半导体研究所人工智能方向的助理教授。他的研究兴趣包括深度学习、机器艺术、模式识别和图像认知计算。他是IEEE会员。