arXiv:2303.05297v1 [eess.IV] 9 Mar 2023

基于透视投影的双平面 X 射线三维 CT 重建

Daeun Kyung[1], * *Kyungmin Jo*[1], * *JaegulChoo*[1] *JoonseokLee*[2,3] *EdwardChoi*[1], †[1]KAIST [2]首尔国立大学 [3]Google Research

摘要

X 射线计算机断层扫描（CT）是医学领域中用于诊断各种疾病的最常见成像技术之一。其较高的对比度灵敏度和空间分辨率使医生能够观察骨骼、软组织、血管等身体部位的细节。然而，由于该技术会使患者和外科医生暴露于可能有害的辐射中，从相互垂直的二维 X 射线图像重建三维 CT 体积被视为一种颇具前景的替代方案，因为它辐射风险更低且可及性更好。但这一任务极具挑战性，因为需要从视角有限且信息相互重叠的二维图像中重建三维解剖信息。本文提出 PerX2CT，这是一种基于 X 射线的新型 CT 重建框架，采用了透视投影方案。我们提出的方法为每个坐标提供不同的特征组合，使模型能够隐式获取三维位置信息。我们展示了通过恰当利用坐标级局部和全局特征，以高分辨率重建 CT 特定部位的潜力。我们的方法计算复杂度低、推理时间短，在多个评估指标上优于基线方法，展现出应用于临床的潜力。

索引 术语— X 射线计算机断层扫描，CT 重建 构

1. 引言

X 射线计算机断层扫描（CT）是一种医学成像技术，可根据围绕患者扫描获得的多视角 X 射线投影数据生成身体的横断面图像。凭借空间分辨率和密度分辨率高等优势，它被广泛应用于医学领域。具体而言，CT 有助于诊断疾病，因为它能同时显示骨骼、软组织等身体部位的细节。然而，与其他医学成像技术相比，CT 扫描的缺点是会造成更多辐射暴露 [1, 2, 3]。

以往的工作尝试通过减少 CT 投影数量来降低辐射剂量，同时利用传统方法 [4] 或深度学习方法 [5, 6, 7, 8]保持较高的重建质量。然而，这些研究仅能在有限程度上降低辐射剂量，仍需要从 CT 扫描仪获取数百张投影图像，以确保图像质量较高。此外，这些方法仍需使用 CT 扫描仪，而 CT 扫描仪的普及程度不如 X射线机。为解决这些问题，研究者开始尝试利用传统 X射线机获取的 X射线来重建 CT [9, 10, 11, 12, 13, 14, 15, 16]。

X射线成像是医院最常进行的放射学检查，因为它给患者带来的身体和经济负担较小。尤其是，与计算机断层扫描相比，X射线的辐射暴露更低，且无需额外准备，例如使用造影剂。计算机断层扫描需要患者躺在圆筒形设备中，而X射线检查没有这些限制，因此更适合行动不便的患者。因此，理想情况下，应能利用X射线重建三维人体内部信息。

从X射线重建CT体积的主要挑战在于缺乏深度信息；根据二维数据估计三维结构是一个众所周知的病态问题 [17]。随着使用的X射线数量减少，三维重建问题会变得更加模糊，因此传统CT重建方法更难解决这一问题。近年来，大规模数据和深度学习模型 [9, 10, 13, 14, 16]通过学习人体解剖结构的先验知识，能够应对这一超稀疏视角重建问题。

一些研究采用由二维编码器和三维解码器组成的二维到三维结构，从少量X射线图像中提供深度信息 [10, 13, 14, 16]。这些模型通常沿深度轴复制二维特征图，因为它们假设X射线是通过正交投影生成的（图2）。然而，由于X射线是通过透视投影生成的，正交投影会使X射线的特征处于错误的位置。为了向模型提供准确的特征以重建CT，我们使用透视投影方法将二维X射线特征放置在三维空间中，这与X射线图像的生成方式一致。近期研究 [10, 13, 14] 利用分割图来提高重建质量。这些方法的一个显著缺点是必须提供分割图，而获取分割图十分费力。相比之下，我们的模型仅使用两张X射线（后前位和侧位图像）即可重建三维 CT 体积，无需额外信息。我们使用两张X射线作为输入，因为单张X射线图像的深度信息不足以准确重建三维体积 [15, 16]。

以往研究的另一个局限是，由于采用了庞大的三维解码器，计算成本较高。由于正交投影会将相同特征置于整个深度轴上，模型接收到的信息不足。为弥补这一不足，以往的模型会同时使用三维解码器重建 CT 体积，因此计算成本显著增加。然而，我们表明，采用适用于 X 射线图像的透视投影时，二维解码器比三维解码器更足以重建准确的 CT。采用二维解码器可显著降低时间复杂度，并高效地逐张重建 CT 切片。尽管如此，与三维解码器相比，二维解码器可能缺少关于全身的信息。因此，我们还提供了 X 射线的全局特征以及.....的位置

* 前两位作者贡献相同。

† 通讯作者 本研究获得韩国政府（MSIT、MOTIE、MOHW、MFDS）资助，包括信息通信技术规划评估院（IITP）拨款（编号：2019-0-00075、2021-0-02068）、韩国保健产业振兴院（KHIDI）拨款（编号：HI21C1138）、韩国医疗器械开发基金拨款（项目编号：1711138160，KMDF_PR_20200901_0097）以及韩国国家研究基金会（NRF）拨款（NRF-2021H1D3A2A03038607）。

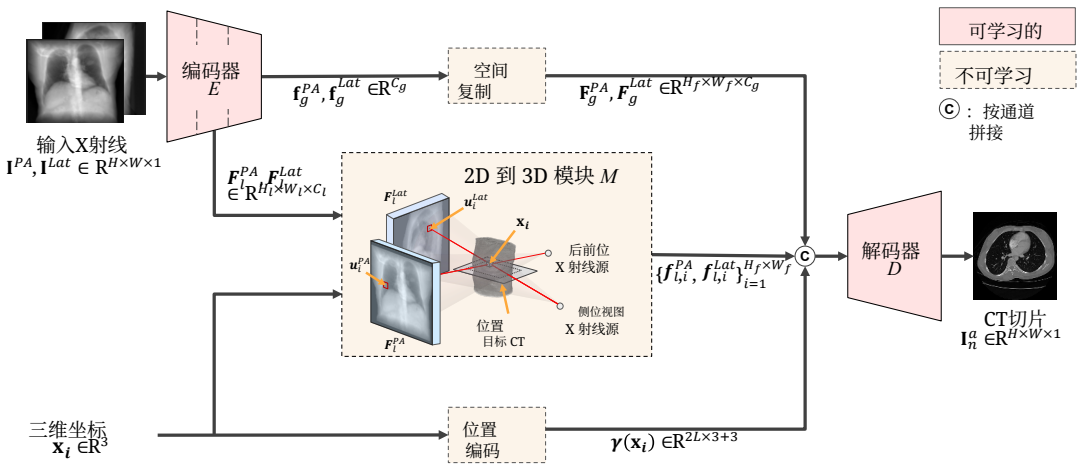


图1：PerX2CT 概览。编码器提取两张 X 射线图像的局部和全局特征，*2D* 到 *3D* 模块 提取目标切片的局部潜向量。解码器利用对应的局部特征图、全局特征图和位置编码重建输出图像块。

每个体素。

在这项工作中，我们提出了一种简单而高效的 CT 重建框架 PerX2CT，该框架体现了 X 射线透视投影方案。所提出的方法通过将从二维 X 射线中获取的信息准确地置于三维空间中，显著提升了重建 CT 的视觉质量。借助三维空间中的坐标级特征和二维解码器，我们不仅降低了模型复杂度，还将推理时间缩短至原来的十分之一。此外，得益于利用三维位置信息的能力，该方法还能以高分辨率对任意选定的图像块进行部分重建。

2. 方法论

本节介绍我们提出的基于两个垂直视角（PA 和侧位）X射线图像的 CT 重建框架（图1）。我们从X射线图像中提取图像特征，并通过透视投影方法将其放置到相应位置。随后，利用局部特征和全局特征重建目标 CT切片。

2.1. 从X射线中提取特征

我们使用编码器 E_θ 从两张X射线图像中提取图像特征，并将其放置在三维空间中，根据目标 CT切片生成特征图。为在尽可能减少输入X射线图像数量的同时最大限度地丰富信息，我们输入来自两个垂直视角的图像$\mathbf{I}^{PA}$、$\mathbf{I}^{Lat} \in \mathbb{R}^{H\times W\times 1}$至 E_θ，其中 $H\times W$表示X射线图像的空间分辨率。为简便起见，我们将图像的视角记为 $v \in \{PA, Lat\}$。

我们为每个视角编码局部特征和全局特征，分别表示由体素指定的信息和全身信息。由于X射线的每个像素值都是根据X射线束所穿过的体素独立计算的，沿每条射线路径恰当地分配局部特征有助于重建 CT中的每个体素。然而，由于局部特征仅提供位置相关的信息，X射线的额外全局特征有助于模型理解患者的全身信息。因此，我们从编码器中提取低级局部特征图$\mathbf{F}_l^v \in \mathbb{R}^{H_l\times W_l\times C_l}$和高级全局特征向量$\mathbf{f}_g^v \in \mathbb{R}^{C_g}$，并将其作为输入提供给解码器。 C_l 和 C_g 是每个特征的通道数

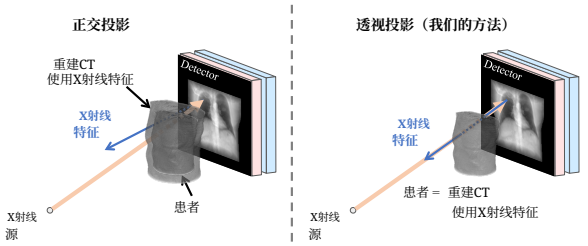


图2：（左）基于正交投影的特征扩展。（右）基于透视投影的特征延伸。

而（$H_l \times W_l$）表示局部特征图的空间维度。

$$E_\theta(\mathbf{I}^v) = (\mathbf{F}_l^v, \mathbf{f}_g^v), \tag{1}$$

2.2. 通过 2D 到 3D 模块重采样局部特征

2D 到 3D 模块的主要作用 M 是将从X射线局部特征图$\mathbf{f}^v_{,\,i}$ 中提取的坐标特征向量$\mathbf{F}_l^v$重新定位到三维CT空间（图1（中））。i 是目标CT切片上三维坐标$\mathbf{x}_i$ 的索引，详细说明如下。

$$\mathbf{f}_{l,i}^v = M(\mathbf{F}_l^v, \mathbf{x}_i). \tag{2}$$

该过程包含两个步骤：1）将体素的三维坐标 $\mathbf{x}_i$ 投影到每个 X 射线图像平面上对应的二维投影点$\mathbf{u}_i^v$；2）使用投影点$\mathbf{u}_i^v$，从每幅 X 射线图像的局部特征图 $\mathbf{F}_l^v$中重采样局部特征向量 $\mathbf{f}^v_{,\,i}$。

设 $\{\mathbf{x}_i\}_{i=1}^{H_f\times W_f} \in \mathbb{R}^3$ 为目标 CT 切片 $\mathbf{I}_n^a$上的网格采样点，其中 n 表示目标 CT 的切片编号， a 表示 CT 的成像平面（$a \in$ {轴向、冠状位、矢状位}）， H_f和 W_f表示重采样特征图的分辨率。

对于每个点$\mathbf{x}_i$，我们按如下方式计算其在图像坐标中的对应投影点 $\mathbf{u}_i^v \in \mathbb{R}^2$：

$$\mathbf{u}_i^v = [\mathbf{R}^v(\theta)|\mathbf{t}^v]\,\mathbf{x}_i, \tag{3}$$

其中，$\mathbf{R}^v(\theta) \in \mathbb{R}^{3\times 3}$ 是旋转矩阵，$\mathbf{t}^v \in \mathbb{R}^3$ 是平移向量，二者均为 X 射线源的外参。

	峰值信噪比(↑)	结构相似性指数(↑)	学习感知图像块相似度(↓)	参数量 (M)	浮点运算次数 (T)	推理时间 (ms)
二维卷积神经网络 [11]	25.398 ± 0.038	0.641 ± 0.001	0.483 ± 0.001	9.068	0.523	35.49 ± 1.73
X2CT-GAN-B [16]	26.013 ± 0.004	0.666 ± 0.003	0.349 ± 0.002	72.796	1.207	1560.87 ± 7.72
PerX2CT	$\mathbf{27.450 \pm 0.016}$	$\mathbf{0.732 \pm 0.000}$	$\mathbf{0.213 \pm 0.001}$	42.536	0.178	46.643 ± 1.43
PerX2CT$_{global}$	27.335 ± 0.004	0.725 ± 0.001	0.216 ± 0.003	70.131	0.190	52.82 ± 1.74

表1：测试集上的CT重建定量比较（均值 ± 标准差）。最佳和次佳结果以**粗体** 和下划线标示。

投影	PE	全局	解码器	峰值信噪比 (↑)	结构相似性指数 (↑)	学习感知图像块相似度 (↓)
正交	✓		2D	23.542 ± 0.118	0.576 ± 0.003	0.292 ± 0.003
透视	✓		2D	$\mathbf{27.751 \pm 0.076}$	$\mathbf{0.749 \pm 0.003}$	$\mathbf{0.200 \pm 0.002}$
透视	✓	✓	2D	27.706 ± 0.069	0.747 ± 0.003	0.202 ± 0.003
透视			2D	27.685 ± 0.116	0.748 ± 0.005	$\mathbf{0.200 \pm 0.003}$
透视			二维$_{mini}$	27.198 ± 0.175	0.727 ± 0.012	0.213 ± 0.008
透视			三维$_{mini}$	26.294 ± 0.196	0.699 ± 0.007	0.302 ± 0.005

表2：PerX2CT 在验证集上的消融研究（均值 ± 标准差）。最佳和次佳结果以**粗体** 和下划线标示。

全局位置编码	64×64			32×32		
	峰值信噪比 (↑)	结构相似性指数 (↑)	学习感知图像块相似度 (↓)	峰值信噪比 (↑)	结构相似性指数 (↑)	学习感知图像块相似度 (↓)
	25.563 ± 0.557	0.793 ± 0.030	0.325 ± 0.020	23.969 ± 0.499	0.735 ± 0.037	0.341 ± 0.013
✓	26.527 ± 0.017	0.841 ± 0.001	$\mathbf{0.295 \pm 0.001}$	25.029 ± 0.052	0.800 ± 0.003	0.314 ± 0.001
✓ ✓	$\mathbf{26.645 \pm 0.096}$	$\mathbf{0.846 \pm 0.004}$	0.294 ± 0.003	$\mathbf{25.701 \pm 0.118}$	$\mathbf{0.831 \pm 0.004}$	$\mathbf{0.307 \pm 0.003}$

表3：PerX2CT 在部分重建验证集上的消融研究（均值 ± 标准差）。最佳和次佳结果分别以**粗体** 和下划线标示。我们根据裁剪部分的大小，评估模型在 64×64 和 32×32分辨率下的表现。

之后，我们使用双线性插值提取与投影点$\mathbf{u}_i^v$对应的特征向量$\mathbf{f}_{\cdot,i}^v$：

$$\mathbf{f}_{l,i}^v = \mathbf{F}_l^v(\mathbf{u}_i^v). \tag{4}$$

通过为所有$\{\mathbf{x}_i\}_{i=1}^{H_f \times W_f}$计算$\mathbf{f}_{l,i}^v$，即可获得整个特征图，并将其作为输入提供给解码器。

2.3. CT切片解码

为提高模型效率，我们使用二维解码器而非三维解码器，分别重建每个CT切片。我们的解码器有五个输入：局部特征图 $\{\mathbf{f}_{l\ \cdot,i}^{PA}\}_{i=1}^{H_f \times W_f}$, $\{\mathbf{f}_{l\ \cdot,i}^{Lat}\}_{i=1}^{H_f \times W_f}$、全局特征图 $\mathbf{F}_g^{PA}$，$\mathbf{F}_g^{Lat}$，以及 $\{\mathbf{x}_i\}_{i=1}^{H_f \times W_f}$的位置编码。由于全局特征向量 $\mathbf{f}_g^v$的分辨率低于局部特征图，因此通过在空间维度上复制全局特征向量，使其具有与局部特征图相同的空间分辨率，

$$\mathbf{f}_g^v \in \mathbb{R}^{C_g} \rightarrow \mathbf{F}_g^v \in \mathbb{R}^{H_f \times W_f \times C_g}. \tag{5}$$

我们在两个视图上分别提取局部特征和全局特征，并沿通道维度将它们全部拼接起来。解码器 $\mathbf{D}_\phi$ 重建目标切片$\mathbf{I}_n^a$，

$$\hat{\mathbf{I}}_n^a = \mathbf{D}_\phi(\mathbf{F}_g^{PA}, \mathbf{F}_g^{Lat}, \{\mathbf{f}_{l,i}^{PA}, \mathbf{f}_{l,i}^{Lat}, \gamma(\mathbf{x}_i)\}_{i=1}^{H_f \times W_f}), \tag{6}$$

其中，$\gamma(\cdot)$ 是正弦位置编码 [18],，它将每个坐标从 $\mathbb{R}$ 映射到 $\mathbb{R}^{2L+3}$。为聚合全局上下文，我们对解码器中分辨率最低的特征图使用注意力层。

2.4. 部分重建

由于所提出的方法采用逐坐标特征向量来重建CT切片，因此它不仅可以重建CT切片

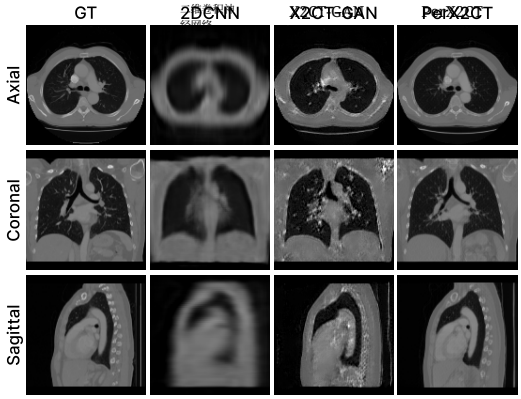


图3：CT重建的定性结果。

达到全分辨率（即，全帧），还可以重建任意选取的图像块。我们将裁剪后的CT切片作为训练数据，以训练模型进行部分重建。具体而言，在训练阶段，我们以 p_{part} 的概率随机裁剪选定的CT切片。裁剪分辨率从（H_{min}，W_{min}）到（H_{out}，W_{out}）的范围内选取，并采用双线性插值。H_{min}，W_{min} 是用于确定采样范围的超参数。如果将裁剪后的切片作为目标，2D 到 3D 模块 M 会在该区域内采样逐坐标局部特征$\mathbf{f}_{\cdot\ i}^v$。因此，PerX2CT可以通过密集采样相应特征，详细重建CT切片的该区域。

2.5. 总体目标

我们的总体目标函数定义为

$$\mathcal{L}_{tot} = \lambda_{rec}\mathcal{L}_{rec} + \lambda_p\mathcal{L}_p, \tag{7}$$

其中，$\mathcal{L}_{rec}$ 是重建损失，即每个切片的逐像素均方误差（MSE）；$\mathcal{L}_p$ 是感知损失 [19]。λ_{rec}，λ_p 控制这两种损失的相对重要性。

3. 实验

3.1. 实验设置

数据集。我们需要一个同时包含X射线和CT扫描的数据集，以便根据X射线重建CT。由于实际采集真实的配对数据集几乎不可行[1],，现有研究采用数字重建射线照片（DRR）技术，从真实CT体积生成合成X射线 [16]。我们按照Ying 等人的方法构建数据集 [16],，使用 LIDC-IDRI [20]。我们随机划分出916个样本用于训练、20个用于验证，82个用于测试。对于CT，我们使用三个平面（即，轴向、矢状位和冠状位）的切片图像，而非完整的三维数据。

评估指标。我们使用三种不同的指标来评估预测计算机断层扫描的定量质量：峰值信噪比

[1]我们需要一对X射线（后前位和侧位）以及一份同时采集的CT扫描，而这种情况在现实中很少发生。

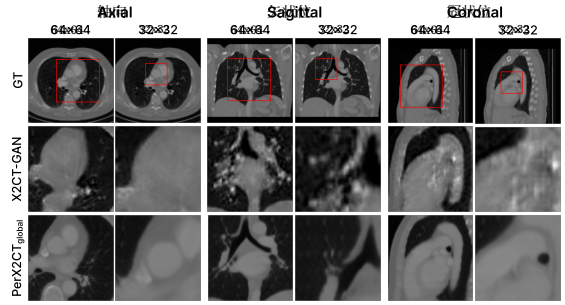


图4：部分重建的定性结果。红色边界框表示待重建的目标图像块，其分辨率为 64×64 和 32×32。

（PSNR）、结构相似性指数（SSIM） [21], 和学习感知图像块相似度（LPIPS） [19]。由于 PSNR 和 SSIM 无法恰当地反映透视质量， [19, 22, 23], 我们使用 LPIPS， [19]它侧重于潜在语义感知，且与人类视觉感知高度相关。

实现细节。 对于图像编码器，我们对在 ImageNet 上预训练的 ResNet-101[24]进行微调，并将其用作骨干网络。局部特征图 $\mathbf{F}_l^v$ 和全局向量 $\mathbf{f}_g^v$ 分别从第三和第四个层块中提取。各特征的通道数 C_l, C_g 分别为 512 和 256，局部特征图的空间维度 $H_l \times W_l$ 为 16×16。我们提出的模型将局部特征图 $\{\mathbf{f}_{l,i}^v\}_{i=1}^{H_f \times W_f}$ 从 $\mathbf{F}_l^v$ 重采样，并将其设为 $H_f \times W_f$ 32×32 分辨率。不使用全局特征时，我们使用截至第三层块的编码器，其余设置均相同。解码器架构遵循 [25], ，并将层块数量设为 3 。解码器的输出分辨率为 128×128。对于位置编码，我们使用 $L = 10$ 作为。式（7）中的权重为 $\lambda_{rec} = \lambda_p = 1$。每个模型训练 50 轮（部分重建训练 70 轮），批量大小为 40。我们使用 Adam优化器 [26] ，初始学习率为 4.5×10^{-6}。动量衰减率 β_1 和自适应项衰减率 β_2 分别为 0.5 和 0.9。我们在 RTX 3090 Ti 上使用 PyTorch [27] 。所有实验均重复三次，并报告均值和标准差。代码将在 https://github.com/dek924/PerX2CT 发布。

3.2 结果

我们将模型的定量和定性结果与两种基线方法进行比较 [11, 16]。定量结果汇总于表1。PerX2CT仅使用透视投影方法和位置编码，而PerX2CT$_{global}$ 还使用全局潜向量。结果表明，所提出的方法在总体指标、学习感知图像块相似度、峰值信噪比和结构相似性指数方面均优于基线方法。我们还比较了各模型的计算复杂度，并根据可训练参数数量、浮点运算次数以及推理速度进行分析。与X2CT-GAN相比，PerX2CT的浮点运算次数减少了6.8×，推理速度快了33.5×。在参数数量方面，二维卷积神经网络表现最佳

在参数量和推理速度方面，但浮点运算次数约为 PerX2CT 的 3 倍，且重建质量明显较差。

在图3中，我们比较了所提出模型与基线方法的视觉质量。图3显示，在轴向、冠状位和矢状位这三个视图中，我们的重建质量均优于所有基线方法。由于二维卷积神经网络只使用一张输入X射线图像，因此重建出的图像更加模糊。X2CT-GAN能够学习大型器官的边界，但无法

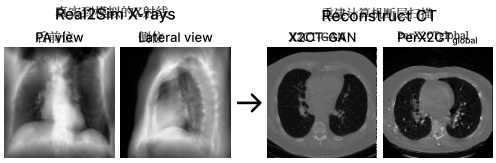


图5：真实X射线投影的定性结果。

准确重建。PerX2CT成功重建了小型解剖结构的细节，例如心房和主动脉，同时清晰地勾勒出器官边界。图4展示了PerX2CT$_{global}$ 与基线方法的部分重建视觉效果。我们展示了在 64×64 和 32×32 分辨率下所选部分的结果。基线方法的结果是从各模型重建的全帧切片中裁剪出来的，然后通过双线性插值放大至全帧分辨率。与此不同，PerX2CT$_{global}$ 直接重建目标部分，无需插值。我们只需在训练集中加入随机裁剪的数据即可实现这一点，而无需更改模型架构。

3.3. 消融研究

我们通过比较验证集上四种变体的性能，分析模型各组件的有效性。表2第1–2行展示了特征扩展策略——透视投影的有效性，其在所有指标上均带来了显著提升。我们在表2和表3中展示了位置编码的影响。位置编码同样提升了所有指标的性能。为阐明模型架构的优势，我们展示了将模型中的所有二维卷积层转换为三维卷积层后的性能。由于二维和三维设置均存在内存问题，我们使用较少的层数进行此实验，并去除了注意力层。如表2第5–6行所示，二维$_{mini}$ 模型优于三维$_{mini}$ 模型。全局特征对全幅CT切片的重建影响不显著（表2第2–3行），但对部分重建有效（表3第2–3行）。这是因为我们的解码器已通过自注意力层聚合了整个目标 CT 切片的全局上下文。然而，在进行部分重建时，解码器接收的只有局部特征，没有额外的全局特征。

3.4. 真实世界实验

在现实中，几乎不可能获得完全在同一时间拍摄的一对X射线（后前位和侧位）以及一次CT扫描。因此，我们分别从训练集和MIMIC-CXR中随机选取了500张合成和真实X射线，用于训练Real2Sim CycleGAN [28] 。随后，我们通过循环生成对抗网络转换真实X射线，并将其作为模型的输入。由于没有与这些X射线对应的真实CT，因此无法进行准确评估。作为替代，我们在图5中提供了定性结果。如图5所示，即使在真实世界场景中，PerX2CT也比X2CT-GAN呈现出更清晰的边界。

4. 结论

本文提出了 PerX2CT，这是一种基于透视投影的三维CT重建框架。PerX2CT 利用从二维双平面X射线特征中提取的依赖于三维坐标的局部特征，以体现透视投影。我们显著提升了

[2]MIMIC-CXR-JPG数据可通过项目网站获取：https://www.physionet.org/content/mimic-cxr-jpg/2.0.0/

全帧切片的重建性能，同时还能灵活地重建CT切片中所需的部分。我们验证了所提出的方法在所有指标上均优于现有模型。凭借出色的性能和轻量化特点，我们的方法在医学领域（例如放射治疗计划）展现出良好的应用潜力。未来，我们计划扩充数据集，以涵盖更贴近现实的情况，例如X射线上出现的金属。

5. 参考文献

[1] David J. Brenner 和 Eric J. Hall，《计算机断层扫描——辐射暴露日益增加的来源》，《新英格兰医学杂志》，第 2277–2284 页，2007年。[2] Stephen Power、Fiachra Moloney、Maria Twomey、Karl James、Owen O’Connor 和 Michael Maher，《计算机断层扫描与患者风险：事实、认知与不确定性》，《世界放射学杂志》，第 8 卷，第 902 页，2016年12月。[3] Charles Schmidt，《CT扫描：平衡健康风险与医疗益处》，《环境健康展望》，第 120 卷，第 A118–21 页，2012年3月。[4] H. Kudo 等，《稀疏视图 CT 与内部 CT 的图像重建——压缩感知与差分反投影简介》，载于《医学与外科定量成像》，2013年。[5] Dong Hye Ye、Gregery T. Buzzard、Max Ruby 和 Charles A. Bouman，《面向稀疏视图 CT 重建的深度反投影》，载于*GlobalSIP*，2018年。[6] Weiwen Wu、Dianlin Hu、Chuang Niu、Hengyong Yu、Varut Vardhanabhuti 和 Ge Wang，《Drone：用于稀疏视图 CT 重建的双域残差优化网络》，《*IEEE*医学影像汇刊》，第 40 卷，第 11 期，第 3002–3014 页，2021年。[7] Zhicheng Zhang、Xiaokun Liang、Xu Dong、Yaoqin Xie 和 Guohua Cao，《一种结合 DenseNet 与反卷积的稀疏视图 CT 重建方法》，《*IEEE*医学影像汇刊》，第 37 卷，第 1407–1417 页，2018年。[8] Luke Pfister 和 Yoram Bresler，《使用自适应稀疏变换进行断层重建》，载于*2014 IEEE*声学、语音与信号处理国际会议（*ICASSP*），2014年，第 6914–6918 页。[9] Abril Corona-Figueroa、Jonathan Frawley、Sam Bond-Taylor、Sarath Bethapudi、Hubert P. H. Shum 和 Chris G. Willcocks，《MedNeRF：利用单张 X 射线重建具备三维感知能力的 CT 投影的医学神经辐射场》，载于*IEEE*医学与生物学工程学会国际会议（*EMBC*）论文集，2022年。[10] Rongjun Ge、Yuting He、Cong Xia、Chenchu Xu、Weiya Sun、Guanyu Yang、Junru Li、Zhihua Wang、Hailing Yu、Daoqiang Zhang 等，《X-ctrsnet：直接从二维 X 射线图像重建并分割三维颈椎 CT》，《知识型系统》，第 236 卷，第 107680 页，2022年。[11] Phlipp Henzler、Volker Rasch、Timo Ropinski 和 Tobias Ritschel，《单图像断层成像：从二维 X 射线生成三维体数据》，《计算机图形学论坛》，第 37 卷，2017年10月。[12] Ling Jiang、Mengxi Zhang、Ran Wei、Bo Liu、Xiangzhi Bai 和 Fugen Zhou，《使用 CVAE-GAN 从单个 X 射线投影视图重建三维 CT》，载于*2021 IEEE*医学成像物理与工程国际会议（*ICMIPE*），2021年，第 1–6 页。

[13] Yoni Kasten、Daniel Doktofsky 和 Ilya Kovler，《利用端到端卷积神经网络从双平面 X 射线图像重建膝骨的三维结构》，载于医学图像重建机器学习国际研讨会，2020年。[14] Md Aminur Rab Ratul、Kun Yuan 和 WonSook Lee，《Ccx-raynet：一种用于将双平面 X 射线转换为 CT 体积的类别条件卷积神经网络》，载于*IEEE*生物医学成像国际研讨会（*ISBI*），2021年。[15] Liyue Shen、Wei Zhao 和 Lei Xing，《通过深度学习从单个投影视图重建患者特异性体积计算机断层扫描图像》，《自然-生物医学工程》，第 3 卷，2019年11月。[16] Heng Guo、Xingde Ying、Jian Wu Kai Ma、Zhengxin Weng 和 Yefeng Zheng，《X2ct-gan：利用生成对抗网络从双平面 X 射线重建 CT》，载于计算机视觉与模式识别会议，2019年。[17] Tomaso A. Poggio、Mario Bertero 和 Vincent Torre，《早期视觉中的不适定问题》，《*IEEE*会刊》，第 76 卷，第 8 期，第 869–889 页，1988年。[18]Ben Mildenhall、Pratul P Srinivasan、Matthew Tancik、Jonathan T Barron、Ravi Ramamoorthi 和 Ren Ng，《NeRF：将场景表示为用于视图合成的神经辐射场》，载于欧洲计算机视觉会议，2020年。[19] Phillip Richard、Eli Alexei 和 Oliver，《深层特征作为感知度量具有非凡效能》，载于计算机视觉与模式识别会议，2018年。[20] McLennan Armato、McNitt-Gray Bidaut L. 等，Meyer. C. R.，《肺部图像数据库联盟（LIDC）与图像数据库资源倡议（IDRI）：已完成的 CT扫描肺结节参考数据库》，载于《医学物理》，2011年。[21] Bovik A. C.、Wang Z.、Simoncelli E. P. 和 Sheikh H. R.，《图像质量评估：从误差可见性到结构相似性》，《*IEEE*图像处理汇刊》，第 600–612 页，2004年。[22] Daeho Lee 和 Sungsoo Lim，《用于图像可见质量测量的改进结构相似性指标》，《电子成像杂志》，第 25 卷，2016年12月。[23] Zhou Wang、A.C. Bovik、H.R. Sheikh 和 E.P. Simoncelli，《图像质量评估：从误差可见性到结构相似性》，《*IEEE*图像处理汇刊》，第 13 卷，第 4 期，第 600–612 页，2004年。[24] Kaiming He、X. Zhang、Shaoqing Ren 和 Jian Sun，《用于图像识别的深度残差学习》，计算机视觉与模式识别会议，第 770–778 页，2016年。[25] Björn Ommer、Patrick Esser、Robin Rombach，《驾驭 Transformer 以实现高分辨率图像合成》，载于计算机视觉与模式识别会议，2021年。[26] Diederik P. Kingma 和 Jimmy Ba，《Adam：一种随机优化方法》，载于国际学习表征会议，2015年。[27] Adam Paszke、Sam Gross、Francisco Massa、Adam Lerer、James Bradbury、Gregory Chanan、Trevor Killeen、Zeming Lin、Natalia Gimelshein、Luca Antiga、Alban Desmaison、Andreas Kopf、Edward Yang、Zachary DeVito、Martin Raison、Alykhan Tejani、Sasank Chilamkurthy、Benoit Steiner、Lu Fang、Junjie Bai 和 Soumith Chintala，《PyTorch：一种命令式风格的高性能深度学习库》，载于神经信息处理系统大会，2019年。[28] Jun-Yan Zhu 等，《使用循环一致性对抗网络进行非配对图像到图像转换》，载于国际计算机视觉大会，2017年。[29] Johnson 等，《Mimic-cxr：一个大型公开的标注胸部X线片数据库》，载于*arXiv*，2019年。