arXiv:2603.13422v1 [eess.IV] 12 Mar 2026

投影引导的低剂量CT去噪个性化联邦学习

AnasZafar[1], Muhammad Waqas[1], Amgad Muneer[1],
Rukhmini Bandyopadhyay[1],和 Jia Wu[1]

美国德克萨斯州休斯敦，德克萨斯大学MD安德森癌症中心

摘要。低剂量 CT（低剂量CT）可减少辐射暴露，但会引入协议相关噪声和伪影，且这些噪声和伪影在不同机构之间存在差异。联邦学习能够在不集中存储患者数据的情况下进行协作训练，但现有方法在图像空间进行个性化，因此难以区分扫描仪噪声与患者解剖结构。我们提出 ProFed（**投影**引导的个性化**联邦**学习），这是一种在图像空间方法基础上进一步在投影空间实现双层个性化的框架；在 CT 测量过程中，噪声首先在投影空间中产生，而后重建过程会将协议和解剖结构的影响结合起来。ProFed 包括：(i) 解剖结构感知网络和协议感知网络，可针对患者和扫描仪特有的特征个性化 CT 重建；(ii) 多约束投影损失，确保结果与 CT 测量保持一致；(iii) 不确定性引导的选择性聚合，根据预测置信度对客户端加权。在梅奥诊所2016数据集上进行的大量实验表明，ProFed 使用 CNN骨干网络时可达到 42.56 dB 的峰值信噪比，使用 Transformer 时可达到 44.83 dB，优于 11 种联邦学习基线方法，其中包括物理信息驱动的 SCAN-PhysFed，高出 $+1.42$ dB。

1 引言

计算机断层扫描（CT）是一种重要的医学成像模态，与常规放射摄影相比，它能够提供解剖结构的精细横断面图像，并具有更高的对比度分辨率 [5]。然而，它涉及辐射暴露，而辐射暴露与癌症风险增加有关 [2]。低剂量 CT（低剂量 CT） [34]通过降低管电流并减少采集的投影视图来降低辐射剂量，从而解决这一问题 [18, 19, 29]。然而，降低剂量会引入复杂噪声和伪影，并导致解剖细节丢失，从而限制其临床应用价值。

深度学习方法在低剂量CT重建方面取得了显著成果[6, 13, 25, 27, 40, 45, 50], ，但需要大规模集中式数据集，而由于隐私约束，这类数据集难以获取 [16, 55, 56]。联邦学习 [8, 36] 能够在不共享患者数据的情况下实现跨机构协同训练，从而解决这一局限。然而，现有的低剂量CT联邦学习方法 [1, 20, 36, 43, 47]是在重建后于图像空间进行个性化，此时协议相关噪声与患者解剖结构已经融合在一起。这使得适应

异构扫描协议 [14]并将扫描仪伪影与解剖结构分离变得困难。

CT图像质量取决于两个相互关联的因素：患者解剖结构和所采用的扫描协议。患者解剖结构决定了X射线被不同组织吸收的方式，而扫描协议则控制辐射剂量和噪声特征。CT扫描中的噪声源自图像重建之前的原始测量（正弦图）。我们的关键洞见是，扫描协议噪声与解剖结构在投影空间中天然分离。噪声表现为不一致的测量值，而解剖结构则在不同观察角度下保持一致的模式。因此，与在图像空间中运行的方法相比，这种方式能够实现更有效的个性化。

现有联邦方法将这些因素视为相互独立，或仅适应其中一个 [15, 35, 47], ，却忽略了噪声在图像重建之前的光子探测过程中、正弦图空间内就已产生，此时扫描协议和解剖结构的影响已经融合。当前方法要么针对患者差异进行个性化，要么在图像空间中适应扫描协议差异，这限制了它们区分与扫描协议相关的伪影和解剖结构的能力，尤其是在面对未见过的扫描协议配置时。

为解决这些局限，我们提出 ProFed（投影引导的个性化联邦学习），该方法利用来自CT扫描仪的正弦图测量值，在投影空间中运行。与图像空间方法相比，这种投影域方法能够更好地区分扫描仪噪声和患者解剖结构。我们的方法结合了针对患者和扫描仪特征的双重适应、与CT测量相结合的投影域一致性损失，以及用于鲁棒联邦学习的不确定性加权聚合。

我们的主要贡献如下：

– **投影引导联邦学习：** 据我们所知，我们是首个使用正弦图测量值进行基于物理的监督的联邦低剂量CT方法，相较于仅使用图像的方法，能够更清晰地将扫描仪噪声与患者解剖结构分离。– **具有投影一致性的双重适应：** 结合解剖结构感知网络和协议感知网络，并采用多约束损失，确保重建结果与CT测量一致。– **多约束投影一致性：** 我们引入了基于CT正弦图的正向投影、反向投影和循环一致性损失，相较于仅使用图像的方法提供了更强的监督。– **不确定性引导聚合：** 采用不确定性引导方法，在不同医院之间平衡个性化与协作学习。

在梅奥诊所2016数据集上进行的大量实验表明，ProFed 的峰值信噪比达到 42.56 dB（卷积神经网络）和 44.83 dB（Transformer），优于 11 种联邦学习基线方法，其中包括物理信息引导的 SCAN- PhysFed，领先 $+1.42$ dB。

2 相关工作

用于低剂量CT重建的深度学习。 早期方法侧重于采用手工设计先验的基于模型的迭代方法，包括字典学习 [49], 惩罚加权最小二乘 [54], 以及学习变换集合正则化 [44]。深度学习方法通过残差编码器-解码器网络 RED-CNN [6],生成对抗网络（GAN） [9, 25, 45], Transformer架构 TransCT [52],RegFormer [42], 以及基于扩散的模型 [11,12,51]取得了显著进展。然而，这些监督式方法需要配对的低剂量CT和常规剂量CT数据。自监督替代方法利用切片间冗余 [4], 小波变换 [53], 和矢量量化码本 [33]来降低数据需求。尽管这些方法在单一机构内效果良好，但难以应对扫描协议异质性，且多机构部署需要数据集中化。

面向医学影像的联邦学习。 联邦学习 [31] 能够在不集中患者数据的情况下，实现跨机构协同训练。标准聚合方法包括 FedAvg [31], 、FedProx [23], 和 FedNova [37], ，它们对模型权重取平均，但假设数据分布同质。个性化方法通过本地自适应层 [3],、批归一化 [24], 、超网络 [48], 和特征分解 [7]来应对异质性。在医学影像领域，FedMRI [10] 处理解剖变异，而近期研究则探索了对比学习 [22] 和知识蒸馏 [41]。然而，这些方法都在图像空间中运行，未能利用扫描仪提供的CT测量数据。

基于物理的低剂量CT重建。近期研究将CT物理学和解剖结构融入重建。ALDEN [38] 根据解剖提示生成图像，而SCAN-PhysFed [46] 通过引入正交约束，提出物理感知的联邦学习方法，在图像空间中分离扫描协议特征与解剖结构特征。SUPER Learning [26]将监督式深度学习与无监督惩罚加权最小二乘更新相结合，用于迭代重建。尽管这些方法融入了物理信息和解剖结构信息，但它们在重建后于图像空间中运行，此时扫描协议噪声与患者解剖结构已经混杂。相比之下，ProFed使用正弦图测量值在投影空间中进行个性化，直接对测量域中的异质性建模；噪声在重建前便产生于此，因此能够更有效地将扫描协议伪影与解剖结构分离。

3 方法

ProFed 在投影空间中利用正弦图测量值进行个性化。该框架结合了：(i) 投影引导联邦学习，利用正弦图测量值进行基于物理的监督，从而更清晰地分离扫描仪噪声与患者解剖结构；(ii) 通过解剖结构感知网络和协议感知网络进行双层个性化适配；(iii) 通过前向投影、反向投影和循环一致性损失实现多约束投影一致性，确保重建结果与 CT

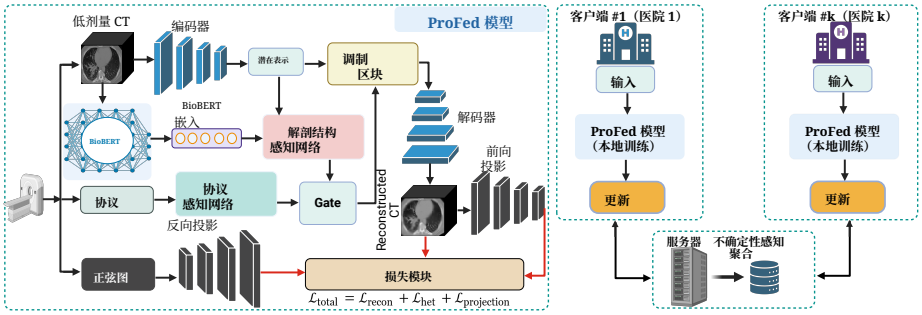

图 1： ProFed 框架：投影引导的个性化联邦学习的架构概览。

测量值保持一致；以及 (iv) 不确定性引导的选择性聚合，在异构机构协议下平衡个性化与协作学习。图 1 和算法 1 概述了所提出的 ProFed。

3.1 问题表述

给定 K 个分布式客户端，$\mathcal{D}_k = \{ (\mathbf{I}_{LD}^{(i)}, \mathbf{I}_{FD}^{(i)}, \mathbf{R}^{(i)}, \mathbf{p}^{(i)}, \mathbf{a}^{(i)}) \}_{i=1}^{N_k}$ 包含：– $\mathbf{I}_{LD}^{(i)}$、$\mathbf{I}_{FD}^{(i)} \in \mathbb{R}^{H \times W}$：低剂量和全剂量 CT 图像 – $\mathbf{R}^{(i)} \in \mathbb{R}^{N_\theta \times N_d}$：包含 N_θ 个投影角度和 N_d 个探测器单元的正弦图测量值– $\mathbf{p}^{(i)} \in [0,1]^7$：归一化协议向量– $\mathbf{a}^{(i)} \in \mathbb{R}^{768}$：解剖特征向量

我们的目标是学习一个重建函数 f_θ:

$$\hat{\mathbf{I}}_{\text{FD}} = f_\theta(\mathbf{I}_{\text{LD}}, \mathbf{p}, \mathbf{a}, \mathbf{R}) \tag{1}$$

3.2 双重适应与投影一致性

架构概述 我们的编码器-解码器架构将重建与双重适应相结合。编码器 E_θ 将低剂量图像处理为潜在特征:

$$\mathbf{z} = E_\theta(\mathbf{I}_{\text{LD}}) \in \mathbb{R}^{192 \times H/32 \times W/32} \tag{2}$$

其中 $\mathbf{z}$ 是具有 $C = 192$ 个通道的潜在表示，输入尺寸为 $W/32$。

解剖感知适应 我们通过两条路径提取患者特异性特征：基于图像的路径和基于文本的路径。基于图像的路径使用两个视觉骨干网络（RED-CNN 和 Uformer）：

$$\mathbf{a}_{\text{img}} = \text{Backbone}(\mathbf{I}) \in \mathbb{R}^{512} \tag{3}$$

文本通路生成合成医学描述，并使用 BioBERT [21] 对其进行编码：

$$\mathbf{a}_{\text{txt}} = \text{BioBERT}(\text{LLM}(\mathbf{I})) \in \mathbb{R}^{768} \tag{4}$$

我们将两者融合，并通过多层感知机投影模态：

$$\mathbf{a} = \text{MLP}_{\text{fusion}}([\mathbf{a}_{\text{img}}; \mathbf{a}_{\text{txt}}]) \in \mathbb{R}^{768} \tag{5}$$

解剖结构感知适配网络生成调制参数：

$$\boldsymbol{\gamma}_a, \boldsymbol{\beta}_a = H_\alpha(\mathbf{a}) \in \mathbb{R}^{192} \tag{6}$$

协议感知适配与低秩适配 扫描仪协议 $\mathbf{p} \in [0,1]^7$ en- 代码几何结构和剂量参数。我们通过多层感知机嵌入协议：

$$\mathbf{e}_p = \text{MLP}_\xi(\mathbf{p}) \in \mathbb{R}^{192} \tag{7}$$

为实现高效的解码器适配，我们采用秩为 $r = 8$ 的低秩适配（LoRA）：

$$\mathbf{W} = \mathbf{W}_0 + \mathbf{B}\mathbf{A} \tag{8}$$

其中 $\mathbf{B} \in \mathbb{R}^{d_{\text{out}} \times r}$ 和 $\mathbf{A} \in \mathbb{R}^{r \times d_{\text{in}}}$。协议调制参数为：

$$\boldsymbol{\gamma}_p, \boldsymbol{\beta}_p = \text{LinearProj}(\mathbf{e}_p) \in \mathbb{R}^{192} \tag{9}$$

门控特征调制 由于解剖结构特征可能不可靠，我们引入了一个可学习的可靠性门控：

$$g = \sigma(\text{FC}_g(\mathbf{a})) \in [0,1] \tag{10}$$

最终的调制参数结合了两个适配层级：

$$\boldsymbol{\gamma} = g \cdot \boldsymbol{\gamma}_a + (1-g) \cdot \boldsymbol{\gamma}_p, \quad \boldsymbol{\beta} = g \cdot \boldsymbol{\beta}_a + (1-g) \cdot \boldsymbol{\beta}_p \tag{11}$$

应用逐通道调制：

$$\mathbf{f}_{\text{mod}} = \boldsymbol{\gamma} \odot \mathbf{z} + \boldsymbol{\beta} \tag{12}$$

解码器生成重建图像：

$$\hat{\mathbf{I}}_{\text{FD}} = D_\phi(\mathbf{f}_{\text{mod}}) \tag{13}$$

然后，我们将该重建结果投影到正弦图空间，并应用三个互补的一致性约束。

可微投影算子 我们使用坐标旋转和双线性插值实现可微拉东变换 $\mathcal{R}_\Theta$ 和滤波反投影 $\mathcal{R}_\Theta^\dagger$ 。对于图像 $I(x,\ y)$，拉东变换计算线积分：

$$\mathcal{R}_\Theta(\mathbf{I})[\theta, s] = \int_{-\infty}^{\infty} \mathbf{I}(s\cos\theta - t\sin\theta, s\sin\theta + t\cos\theta)\, dt \tag{14}$$

3.3 多约束投影一致性

我们利用正弦图测量值$\mathbf{R}$施加三种互补的一致性损失。

正向投影一致性确保预测的正弦图与 CT测量相匹配：

$$\mathcal{L}_{\text{forward}} = \|\mathcal{R}_\Theta(\hat{\mathbf{I}}_{\text{FD}}) - \mathbf{R}\|_2^2 \tag{15}$$

反向投影一致性确保重建结果与 CT 数据的前向反投影相匹配：

$$\mathcal{L}_{\text{backward}} = \|\hat{\mathbf{I}}_{\text{FD}} - \mathcal{R}_\Theta^\dagger(\mathbf{R})\|_2^2 \tag{16}$$

循环一致性对重建结果进行正则化：

$$\mathcal{L}_{\text{cycle}} = \|\hat{\mathbf{I}}_{\text{FD}} - \mathcal{R}_\Theta^\dagger(\mathcal{R}_\Theta(\hat{\mathbf{I}}_{\text{FD}}))\|_2^2 \tag{17}$$

组合投影损失为：

$$\mathcal{L}_{\text{projection}} = \lambda_f \mathcal{L}_{\text{ forward}} + \lambda_b \mathcal{L}_{\text{backward}} + \lambda_c \mathcal{L}_{\text{cycle}} \tag{18}$$

3.4 不确定性引导的联邦聚合

我们将不确定性加权扩展到 FedAvg。每个客户端使用蒙特卡洛丢弃计算预测不确定性：

$$u_k = \mathbb{E}_{(\mathbf{I},\mathbf{p})\sim\mathcal{D}_k^{\text{val}}}\left[\text{Var}(\hat{\mathbf{I}})\right] \tag{19}$$

3.5 训练目标

我们结合三个损失分量。**图像重建损失**：

$$\mathcal{L}_{\text{recon}} = \|\hat{\mathbf{I}}_{\text{FD}} - \mathbf{I}_{\text{FD}}\|_2^2 \tag{20}$$

算法 1： ProFed：投影域个性化联邦学习

输入： 客户端 $\mathcal{C}=\{1,\dots,K\}$、数据集 $\{\mathcal{D}_k\}$、轮次 T、本地训练轮数 E
输出： 全局模型 θ_{global}
随机初始化 θ_{global}
// 离线预计算解剖结构特征
遍历客户端 k **执行**
  对于 $(\mathbf{I}_{LD},\ \mathbf{I}_{FD},\ \mathbf{R},\ \mathbf{p})\in\mathcal{D}_k$ **执行**
    $\mathbf{a}_{\text{img}}\leftarrow \text{UformerCNN}(\mathbf{I}_{FD})$
    报告 $\leftarrow$图像描述生成器$(\mathbf{I}_{FD})$
    $\mathbf{a}_{\text{txt}}\leftarrow$BioBERT（报告）
    $\mathbf{a}\leftarrow$ 多层感知机$_{\text{fusion}}([\mathbf{a}_{\text{img}};\ \mathbf{a}_{\text{txt}}])$
    将$\mathbf{a}$与样本一起存储
对于 $t=1$ **到** T **执行**
  向所有客户端广播 θ_{global}
  遍历客户端 $k\in\{1,\dots,K\}$ 并行**执行**
    $\theta_k\leftarrow\theta_{\text{global}}$
    对于 $e=1$ **到** E **执行**
      对于 批次 $(\mathbf{I}_{\text{LD}},\ \mathbf{I}_{\text{FD}},\ \mathbf{R},\ \mathbf{p},\ \mathbf{a})\in\mathcal{D}_k$ **执行**
        // 双层个性化
        $(\boldsymbol{\gamma}_a,\ \boldsymbol{\beta}_a)\leftarrow H_\alpha(\mathbf{a})$
        $(\boldsymbol{\gamma}_p,\ \boldsymbol{\beta}_p)\leftarrow H_\beta(\mathbf{p})$
        $g\leftarrow\sigma(\text{FC}_g(\mathbf{a}))$
        $\boldsymbol{\gamma}\leftarrow g\,\boldsymbol{\gamma}_a+(1-g)\,\boldsymbol{\gamma}_p$
        $\boldsymbol{\beta}\leftarrow g\,\boldsymbol{\beta}_a+(1-g)\,\boldsymbol{\beta}_p$
        // 使用调制进行前向传播
        $\mathbf{z}\leftarrow E_\theta(\mathbf{I}_{\text{LD}})$
        $\mathbf{f}_{\text{mod}}\leftarrow\boldsymbol{\gamma}\odot\mathbf{z}+\boldsymbol{\beta}$
        $\hat{\mathbf{I}}_{\text{FD}}\leftarrow D_\phi(\mathbf{f}_{\text{mod}})$
        // 投影引导的一致性损失
        $\hat{\mathbf{R}}\leftarrow\mathcal{R}_\Theta(\hat{\mathbf{I}}_{\text{FD}})$
        $\mathbf{I}_{\text{FBP}}\leftarrow\mathcal{R}_\Theta^{\dagger}(\mathbf{R})$
        $\mathcal{L}_{\text{forward}}\leftarrow\|\hat{\mathbf{R}}-\mathbf{R}\|_2^2$
        $\mathcal{L}_{\text{backward}}\leftarrow\|\hat{\mathbf{I}}_{\text{FD}}-\mathbf{I}_{\text{FBP}}\|_2^2$
        $\mathcal{L}_{\text{cycle}}\leftarrow\|\hat{\mathbf{I}}_{\text{FD}}-\mathcal{R}_\Theta^{\dagger}(\mathcal{R}_\Theta(\hat{\mathbf{I}}_{\text{FD}}))\|_2^2$
        $\mathcal{L}_{\text{proj}}\leftarrow\lambda_f\mathcal{L}_{\text{forward}}+\lambda_b\mathcal{L}_{\text{backward}}+\lambda_c\mathcal{L}_{\text{cycle}}$
        // 图像域损失
        $\mathcal{L}_{\text{recon}}\leftarrow\|\hat{\mathbf{I}}_{\text{FD}}-\mathbf{I}_{\text{FD}}\|_2^2$
        $\hat{\sigma}^2\leftarrow\text{VarianceNet}(\mathbf{I}_{\text{LD}},\ \mathbf{p})$
        $\mathcal{L}_{\text{het}}\leftarrow\sum_{x,\ y}\left[\frac{(\hat{\mathbf{I}}_{\text{FD}}-\mathbf{I}_{\text{FD}})^2}{2\sigma^2}+\frac{1}{2}\log\sigma^2\right]$
        // 总损失与更新
        $\mathcal{L}_{\text{total}}\leftarrow\lambda_{\text{recon}}\mathcal{L}_{\text{recon}}+\lambda_{\text{het}}\mathcal{L}_{\text{het}}+\lambda_{\text{proj}}\mathcal{L}_{\text{proj}}$
        反向传播 $\mathcal{L}_{\text{total}}$ 并更新 θ_k
    // 使用蒙特卡洛 Dropout 计算客户端的不确定性
    $u_k\leftarrow 0$
    对于 $(\mathbf{I},\mathbf{p},\mathbf{a})\in\mathcal{D}_k^{val}$ **执行**
      $\{\hat{\mathbf{I}}^{(m)}\}_{m=1}^{M}\leftarrow$ 蒙特卡洛 Dropout 预测
      $u_k\leftarrow u_k+$方差$(\{\hat{\mathbf{I}}^{(m)}\})$
    $u_k\leftarrow u_k/|\mathcal{D}_k^{\text{val}}|$
    将 $(\theta_k^{\text{shared}},u_k,N_k)$ 发送至服务器
  // 服务器端不确定性加权聚合
  遍历客户端 k **执行**
    $w_k\leftarrow\frac{N_k}{N_{\text{总计}}(u_k+\epsilon)}$
  归一化：$w_k\leftarrow w_k/\sum_j w_j$
  // 选择性聚合：共享层与本地层
  $\theta_{\text{全局}}\leftarrow\sum_k w_k\theta_k$（聚合 $E_\theta,\ D_\phi,\ H_\beta$）
  保留本地：H_α，FC_g
  $\eta\leftarrow$余弦退火$(\eta,\ t,\ T)$
返回 $\theta_{\text{全局}}$

表1：基于CNN的定量性能（峰值信噪比/结构相似性指数）

	客户端#1		客户端#2		客户端#3		客户端#4		客户端#5		客户端#6		客户端#7		客户端#8		平均值	
	峰值信噪比	结构相似性指数	峰值信噪比	结构相似性指数	峰值信噪比	结构相似性指数	峰值信噪比	结构相似性指数	峰值信噪比	结构相似性指数	峰值信噪比	结构相似性指数	峰值信噪比	结构相似性指数	峰值信噪比	结构相似性指数	峰值信噪比	结构相似性指数
FedAvg [31]	29.99	82.20	32.82	78.23	34.68	86.99	32.30	80.63	36.87	92.06	37.36	89.02	32.73	80.66	35.46	87.65	34.03	84.70
FedProx [23]	29.94	83.12	32.69	75.46	36.95	91.58	32.32	80.91	38.95	95.34	37.58	88.13	32.94	81.62	35.86	88.65	34.65	85.60
FedNova [37]	29.95	82.29	32.57	80.57	37.77	92.16	32.09	78.98	34.42	88.69	36.05	89.57	32.81	81.41	35.89	88.71	33.94	85.30
MOON [22]	32.50	75.61	35.55	85.41	35.72	80.30	35.69	82.10	35.38	78.47	36.31	84.35	35.70	81.17	35.62	80.40	35.31	80.98
FedDG [28]	33.37	81.40	34.01	82.39	33.56	76.37	34.43	81.49	34.06	76.70	33.97	80.17	34.75	80.87	34.25	79.23	34.05	79.83
FedKD [41]	29.74	83.11	32.17	71.65	36.65	90.93	32.10	79.19	40.58	96.71	37.07	82.55	32.88	81.30	36.28	89.08	34.68	84.31
FedPer [3]	33.23	88.20	35.06	84.89	38.79	92.70	35.58	86.12	41.76	96.97	36.85	89.96	35.69	86.30	38.48	91.69	36.93	89.60
FedBN [24]	32.55	84.59	34.76	84.15	38.18	90.30	34.77	83.30	41.24	96.11	38.66	91.19	34.74	83.35	37.89	90.35	36.60	87.92
FedMRI [10]	33.28	83.43	34.51	85.81	38.62	92.47	35.86	87.21	41.49	96.27	38.22	91.32	35.87	86.34	38.09	91.94	36.99	89.35
HyperFed [48]	33.74	88.57	34.83	85.05	38.87	92.78	35.44	85.40	42.94	97.48	39.15	92.96	34.99	85.19	38.12	91.29	37.26	89.84
FedFDD [7]	36.18	93.67	38.43	94.19	39.72	96.47	38.51	95.30	45.56	98.73	42.72	97.61	40.74	96.01	38.54	94.39	40.05	95.79
SCAN-PhysFed [46]	34.49	96.40	39.21	96.09	40.45	97.93	40.51	97.61	47.81	99.14	44.08	98.51	42.54	97.86	40.02	97.37	41.14	97.62
ProFed（我们的方法）	**36.63**	**97.18**	**41.79**	**97.88**	**42.43**	**98.31**	**42.29**	**98.25**	**47.87**	**98.91**	**43.82**	**98.54**	**42.94**	**98.36**	**42.69**	**98.19**	**42.56**	**98.23**

表 2：基于Transformer的定量性能（峰值信噪比/结构相似性指数）

	客户端#1		客户端#2		客户端#3		客户端#4		客户端#5		客户端#6		客户端#7		客户端#8		平均值	
	峰值信噪比	结构相似性指数	峰值信噪比	结构相似性指数	峰值信噪比	结构相似性指数	峰值信噪比	结构相似性指数	峰值信噪比	结构相似性指数	峰值信噪比	结构相似性指数	峰值信噪比	结构相似性指数	峰值信噪比	结构相似性指数	峰值信噪比	结构相似性指数
FedAvg [31]	34.31	87.88	38.06	90.54	43.51	97.56	41.05	95.43	45.24	98.47	43.15	97.09	41.45	95.95	42.88	96.16	41.21	94.89
FedProx [23]	34.32	87.01	37.74	88.89	43.73	97.95	41.12	93.92	45.39	98.61	42.99	97.08	41.38	94.31	42.10	94.55	41.10	94.04
FedNova [37]	29.55	78.44	31.38	68.13	37.07	82.47	31.79	73.45	40.61	88.80	35.46	79.77	32.38	73.66	35.77	82.22	34.25	78.37
MOON [22]	34.28	93.20	38.09	91.17	43.64	97.77	41.09	95.66	45.25	98.43	42.82	96.91	41.42	95.97	42.20	96.18	41.10	95.66
FedKD [41]	35.92	89.93	38.70	91.21	44.26	98.13	42.30	95.99	45.93	98.75	43.57	97.41	42.54	96.22	43.51	96.23	42.09	95.48
FedPer [3]	35.37	93.18	39.03	93.55	42.75	97.13	40.88	96.20	46.55	98.83	42.87	96.68	41.87	96.70	40.79	94.78	41.26	95.82
FedMRI [10]	34.60	93.67	38.04	94.55	42.94	97.44	39.34	95.78	46.79	98.91	42.82	97.30	40.81	95.32	40.85	95.70	40.78	96.01
HyperFed [48]	34.60	87.59	38.62	91.08	44.13	97.61	42.25	96.24	45.92	98.59	43.71	97.37	42.44	96.66	43.56	96.63	41.90	95.22
FedFDD [7]	37.35	96.20	39.67	95.18	44.31	98.26	39.00	95.21	47.89	99.20	43.81	98.06	42.17	97.40	40.50	95.49	41.84	96.89
SCAN-PhysFed [46]	38.55	94.06	41.74	96.20	45.52	98.52	42.48	96.55	49.50	99.39	45.32	97.93	43.35	96.73	42.71	96.79	43.65	97.03
ProFed（我们的方法）	**39.26**	**96.18**	**44.33**	**98.63**	**44.90**	**98.95**	**44.60**	**98.89**	**48.91**	**99.40**	**46.58**	**99.02**	**45.30**	**98.97**	**44.76**	**98.84**	**44.83**	**98.61**

异方差损失： 低剂量 CT 中的噪声方差取决于辐射剂量和扫描方案，并且在投影域中遵循泊松统计。我们对每个像素的方差进行建模，以考虑这种异方差噪声：

$$\mathcal{L}_{\text{het}} = \sum_{x,y} \left[\frac{\left(\hat{\mathbf{I}}_{\text{FD}}(x,y) - \mathbf{I}_{\text{FD}}(x,y)\right)^2}{2\,\sigma^2(x,y)} + \frac{1}{2}\log \sigma^2(x,y) \right], \tag{21}$$

其中 $\sigma^2(x,\ y)$ $=$VarianceNet$(\mathbf{I}_{\text{LD}},\ \mathbf{p})$ 根据低剂量图像和方案参数，对空间变化的噪声方差进行预测。

总训练目标： 完整的损失函数结合了图像域项、剂量感知项和投影域项：

$$\mathcal{L}_{\text{total}} = \lambda_{\text{recon}}\mathcal{L}_{\text{recon}} + \lambda_{\text{het}}\mathcal{L}_{\text{het}} + \lambda_{\text{proj}}\mathcal{L}_{\text{projection}}. \tag{22}$$

4 实验与结果

4.1 数据集

ProFed 使用 NIH-AAPM-Mayo Clinic 2016数据集对低剂量 CT [30]进行评估。该基准包含来自十位患者的 5,936 次 CT扫描。我们采用了与 SCAN PhysFed [46] 类似的实验设置；其中八位患者用于训练，另外 2 位留作测试。为模拟多机构协作，我们将 8 位训练患者分配给 K$=8$ 个虚拟

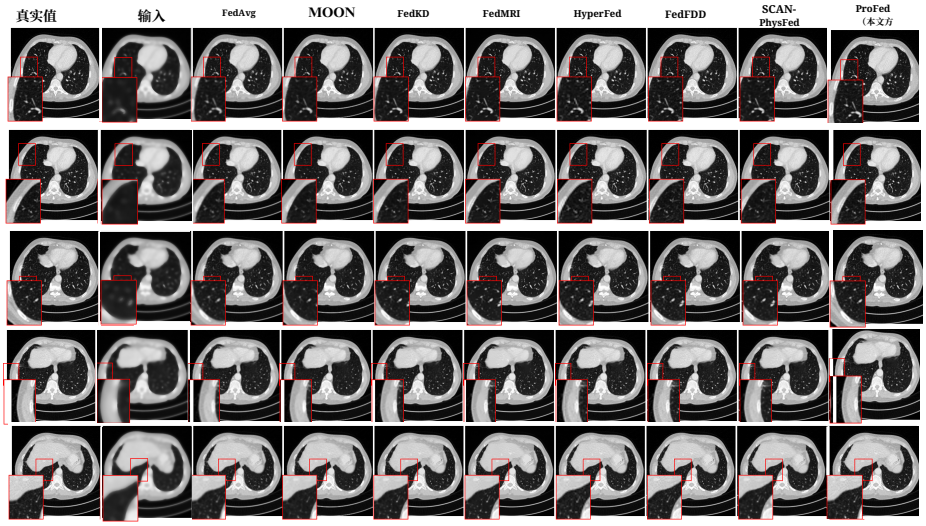

图2： 使用经典的基于卷积的低剂量CT成像网络，在不同客户端上对六种选定的对比方法和我们的方法进行定性结果比较。第一至第五行分别表示客户端#2、客户端#3、客户端#5、客户端#6和客户端#7

客户端，每个客户端分配不同的扫描协议配置。对于未见客户端评估，我们使用训练期间未见过的 4 种新扫描协议配置（NV：100–896 个视图，PN：9×10^4–1.1×10^6）对留出的 2 位测试患者进行前向投影，同时评估解剖结构泛化（未见患者）和协议泛化（未见扫描配置）。

表3： 未见客户端上的定量评估：峰值信噪比和结构相似性指数

	未见客户端#1 峰值信噪比 结构相似性指数	未见客户端#2 峰值信噪比 结构相似性指数	未见客户端#3 峰值信噪比 结构相似性指数	未见客户端#4 峰值信噪比 结构相似性指数	平均值 峰值信噪比 结构相似性指数
FedAvg [31]	35.57 88.68	34.00 85.26	32.52 76.71	36.86 91.44	32.89 81.35
FedProx [23]	36.69 91.16	34.30 86.39	32.58 72.13	39.13 94.87	34.74 85.52
FedNova [37]	35.45 88.83	34.23 86.29	32.39 69.20	35.40 89.99	34.38 83.58
MOON [22]	35.21 78.19	35.30 79.81	34.55 83.07	35.56 78.94	35.16 80.00
FedDG [28]	34.86 79.54	34.79 80.91	33.15 80.31	34.49 77.42	34.32 79.55
FedKD [41]	36.82 91.60	34.27 86.37	32.49 70.54	40.73 95.90	36.08 86.10
FedPer [3]	36.86 88.58	35.46 87.02	31.96 71.64	38.56 90.90	35.71 84.53
FedBN [24]	37.84 89.95	36.16 88.46	33.67 81.63	40.21 94.89	36.97 88.73
FedMRI [10]	31.12 82.42	31.95 79.95	31.72 71.96	32.04 81.63	31.71 78.99
HyperFed [48]	36.18 89.60	33.47 82.49	31.94 65.52	41.70 94.85	35.90 83.12
FedFDD [7]	37.80 92.33	37.06 91.77	33.71 80.26	40.53 95.12	37.27 89.87
SCAN-PhysFed 40.77 97.69		38.77 95.75	34.38 81.80	40.27 96.92	38.55 93.04
ProFed（我们的方法）41.26 97.85		**39.31 96.06**	**35.27 82.23**	**40.83 97.18**	**39.17 93.33**

4.2 评估指标

我们使用低剂量 CT 重建领域的两种常用图像质量指标来评估我们的方法。

峰值信噪比（PSNR）。PSNR 以分贝（dB）为单位计算像素级重建准确性，用于衡量重建的低剂量图像与参考全剂量图像之间的相似度：

$$\mathrm{PSNR}(\mathbf{I}_{\mathrm{FD}}, \hat{\mathbf{I}}_{\mathrm{FD}}) = 10 \cdot \log_{10}\left(\frac{\mathrm{MAX}^2}{\mathrm{MSE}(\mathbf{I}_{\mathrm{FD}}, \hat{\mathbf{I}}_{\mathrm{FD}})}\right) \tag{23}$$

ˆ其中，$\mathbf{I}_{\mathrm{FD}}$ 表示参考完整剂量CT图像，$\mathbf{I}_{\mathrm{FD}}$ 表示由低剂量输入重建得到的图像，MAX为最大可能像素值，MSE $= \frac{1}{HW}\|\mathbf{I}_{\mathrm{FD}} - \hat{}\mathbf{I}_{\mathrm{FD}}\|_2^2$ 为均方误差。PSNR值越高，表示重建误差越低；临床研究表明，PSNR ≥ 35



Fig.3: 使用基于Transformer的重建网络，在不同客户端上对各方法进行定性比较。第1—5行分别展示客户端#2、#3、#5、#6和#7的结果。

在低剂量CT成像中，通常需要达到 [6] dB才能满足诊断质量要求。

结构相似性指数（SSIM）。SSIM通过比较重建CT图像与参考CT图像的亮度、对比度和结构细节来评估图像质量 [32]:

$$\mathrm{SSIM}(\mathbf{I}_{\mathrm{FD}}, \hat{\mathbf{I}}_{\mathrm{FD}}) = \frac{(2\mu_{\mathbf{I}}\mu_{\hat{\mathbf{I}}} + C_1)(2\sigma_{\mathbf{I}\hat{\mathbf{I}}} + C_2)}{(\mu_{\mathbf{I}}^2 + \mu_{\hat{\mathbf{I}}}^2 + C_1)(\sigma_{\mathbf{I}}^2 + \sigma_{\hat{\mathbf{I}}}^2 + C_2)} \tag{24}$$

其中，$\mu_{\mathbf{I}}$ 和$\mu_{\hat{\mathbf{I}}}$ 是平均亨氏单位（HU）值，$\sigma_{\mathbf{I}}$ 和$\sigma_{\hat{\mathbf{I}}}$ 是标准差，$\sigma_{\mathbf{I}\hat{\mathbf{I}}}$ 是协方差，$C_1 = （0.01 \cdot L）^2$、$C_2 = （0.03 \cdot L）^2$ 是用于保证数值稳定性的常数，其中 L 是动态范围。SSIM的取值范围为0到1，越接近1表示对以下内容的保留效果越好：

结构信息和组织对比度，这些对于在低剂量CT重建中保留器官边界、血管结构和软组织分辨等诊断特征至关重要。

4.3 实现细节

ProFed 使用 PyTorch 实现，并采用 Adam [17]进行优化，学习率为 0.001。我们进行了 200 个联邦通信轮次，批次大小为 20。我们评估了两种重建骨干网络：用于基于卷积神经网络的实验的 RED-CNN [6]，以及用于基于Transformer的实验的 Uformer [39]。解剖结构特征使用 BioBERT [21]计算。所有实验均在 4 块 NVIDIA H100 GPU 上进行。与我们比较的所有 11 种基线方法一样，ProFed 使用标准临床采集中获得的配对低剂量CT/常规剂量CT数据 [46]；我们的投影域一致性损失与监督类型正交，并且兼容自监督扩展。

4.4 与其他方法的比较

我们将 ProFed 与 11 种联邦学习基线方法进行比较，涵盖标准聚合（FedAvg [31], FedProx [23], FedNova [37]）、表示学习（MOON [22],FedDG [28]）、知识蒸馏（FedKD [41]）、个性化（FedPer [3], FedBN [24], FedMRI [10], HyperFed [48]）、特征解耦（FedFDD [7]）以及物理信息方法（SCAN-PhysFed [46]）。表1和表2展示了基于卷积神经网络的（RED-CNN）和基于Transformer的（Uformer）架构在 8 个联邦客户端上的结果，而表3评估了对 4 个未见客户端的泛化能力。ProFed 在所有设置中均取得最佳性能：42.56 dB/98.23%（卷积神经网络）、44.83 dB/98.61%（Transformer）以及 39.17 dB/93.33%（未见客户端）。与 SCAN-PhysFed（采用图像空间物理约束的最强基线方法）相比，ProFed 分别提升了 $+1.42$ dB（卷积神经网络）、$+1.18$ dB（Transformer）和 $+0.62$ dB（未见客户端），验证了投影引导的个性化能够通过确保与正弦图测量的一致性，提供更强的监督。通用个性化方法（FedPer：36.93 dB，HyperFed：37.26 dB）和特征解耦方法（FedFDD：40.05 dB）的表现都明显较差，这表明有效的 CT重建需要额外采用基于物理的监督方法，而非仅依赖通用领域自适应方法。图2和图3中的定性结果表明，在异质扫描协议下，ProFed 能够生成更清晰的解剖边界和更干净的软组织区域，同时减少伪影。SCAN-PhysFed 虽能有效抑制噪声，但会过度平滑低对比度区域；而 ProFed 通过确保重建结果符合投影空间中的实际 CT测量，保留了纹理细节。在不同架构（卷积神经网络和Transformer）、评估场景（训练客户端和未见客户端）及视觉质量方面均取得的稳定提升证实，投影引导的双层个性化能够在测量域中成功分离扫描协议相关噪声与患者特异性解剖结构，而二者本就共同存在于该域中。

表4： ProFed 中不同组件的消融研究。

组件					平均值
个性化 域 投影 一致性 原型 解剖结构 不确定性					峰值信噪比 结构相似性指数
					感知权重（dB）（%）
图像	✗	✗	✗	✗	40.72 97.92
图像	✗	✓	✗	✗	40.98 97.98
图像	✗	✗	✓	✗	41.07 98.01
图像	✗	✓	✓	✗	41.12 98.03
图像	✗	✓	✓	✓	41.16 98.05
投影	✓	✗	✗	✗	41.62 98.12
投影	✓	✓	✗	✗	42.02 98.18
投影	✓	✗	✓	✗	42.18 98.20
投影	✓	✓	✓	✗	42.43 98.22
投影	✓	✓	✓	✓	**42.56 98.23**

表5： 单项投影损失的消融研究

配置	**峰值信噪比（dB）**	**结构相似性指数（%）**
仅图像损失	41.16	98.05
+ 前向投影	41.37	98.09
+ 反向投影	41.29	98.07
+ 循环一致性	41.33	98.08
+ 全部三项（$\lambda_f = 1,\ \lambda_b = 1,\ \lambda_c = 1$）	**41.62**	**98.12**

4.5 消融研究

表4和表5使用基于卷积神经网络的架构，系统评估了各组件的贡献。我们从图像域个性化开始，观察到协议感知网络（+0.26 dB）和解剖结构感知网络（+0.35 dB）都能提升性能，二者结合后达到 41.12 dB。加入不确定性引导加权后，性能达到 41.16 dB，与 SCAN-PhysFed 的方法相当。加入投影引导后，一致性损失得到改善，性能提升至 41.62 dB（比图像域基线高 +0.90 dB），这验证了该方法能够提供更强的监督。加入协议感知网络（42.02 dB）、解剖结构感知网络（42.18 dB）以及二者结合（42.43 dB）后，性能提升幅度更大，因为在正弦图空间中，扫描协议噪声和解剖积分更容易自然解耦。完整 ProFed 模型达到 42.56 dB，比最佳图像域配置提升了 +1.40 dB。

消融研究揭示了三个关键发现：(1) 投影引导的优越性在投影空间中执行相同的个性化操作（第6–10行），始终比在图像空间中执行（第1–5行）高出0.9–1.4 dB，这证实了在此处对异质性进行建模时，CT物理学得到直接表征，并提供了更强的归纳偏置；(2) 互补组件协议网络适应扫描仪相关噪声，而解剖网络处理患者特异性解剖结构，两者结合使用（42.43 dB）显著优于单独使用各组件（42.02 dB或42.18 dB）；(3) 不确定性带来的增益有限，尽管不确定性加权有所帮助（+0.13 dB），但通过投影引导的个性化在模型层面处理异质性

表6： 计算量比较

	性能	架构与规模			计算量			
方法	峰值信噪比	参数	参数 (K=8)	参数 (K=100)	规模	训练	推理	提取 通信
SCAN	43.65	1.5M	18.8M		$O(K)$	Base	骨干网络 每轮	Full
ProFed	**44.83**	3.0M	**3.0M**		$O(1)$	+投影 (+0.46 dB)	Same	**离线 -14%**

所带来的贡献更大（+1.27 dB），而不仅仅是采用聚合层策略。表6进一步显示，与SCAN-PhysFed不同，其参数量随 $O(K)$扩展，在 $K=100$ 个客户端时达到18.8M；ProFed则保持恒定的 $O(1)$扩展性，参数量为3.0M，不受联邦规模影响，同时通过离线解剖特征提取将通信开销降低14%。

5 局限性

ProFed 使用协议元数据（千伏峰值、毫安秒、扫描仪几何参数）进行协议感知适配；这些信息通常可从临床DICOM头信息中获取，也是联邦CT部署中的标准信息。虽然我们的可靠性门控融合机制能够处理元数据不完整的情况，但未来的工作可以探索直接从正弦图测量值中进行更稳健的协议推断。此外，专门的自监督解剖结构编码器若直接在CT体数据上训练，或许能够捕捉到比当前基于BioBERT 的方法更细微的解剖变异。

6 结论

我们提出了 ProFed，这是一种投影引导的个性化联邦学习框架，旨在解决分布式低剂量CT重建中的异质性问题。该框架在正弦图空间中进行双层个性化，而协议相关噪声和患者特异性解剖结构正是自然存在于这一空间中的因素。ProFed在梅奥诊所2016数据集上取得了42.56 dB的峰值信噪比（卷积神经网络）和44.83 dB的峰值信噪比（Transformer），优于11种联邦学习基线方法，并比物理信息引导的SCAN-PhysFed方法提升了 +1.42 dB。ProFed有三项关键贡献：第一，我们提出了投影引导联邦学习；据我们所知，这是首个利用正弦图测量进行基于物理监督的联邦低剂量CT方法，与仅基于图像的方法相比，它能更清晰地将扫描仪噪声与患者解剖结构分离。第二，我们提出了双重适配网络，将解剖结构感知和协议感知的个性化与多约束投影损失（正向、反向、循环）相结合，确保重建结果与CT测量保持一致。第三，我们开发了不确定性引导聚合，在个性化与协作学习之间取得平衡，

以促进异构医院站点之间的协作学习。系统性消融实验表明，投影引导的个性化（+1.40 dB）通过在物理测量空间中分离异质性来源，显著优于独立的基于图像的方法。ProFed对未见客户端表现出良好的泛化能力（39.17 dB），并且在卷积神经网络和Transformer骨干网络上均持续有效。这些结果展示了一种实用的隐私保护医疗人工智能框架，能够处理异构医院数据，同时保持临床应用所需的图像质量。

参考文献

1. Al-Saleh, A., Tejani, G.G., Mishra, S., Sharma, S.K., Mousavirad, S.J.: 一种基于联邦学习的隐私保护图像处理框架，用于从CT扫描中检测脑肿瘤。Scientific Reports **15**(1), 23578（2025年） 2. Ali, Y.F., Cucinotta, F.A., Ning-Ang, L., Zhou, G.: 低剂量电离辐射的癌症风险。Frontiers in Physics **8**, 234（2020年） 3. Arivazhagan, M.G., Aggarwal, V., Singh, A.K., 等：具有个性化层的联邦学习。arXiv预印本 arXiv:1912.00818（2019年） 4. Bera, S., Biswas, P.K.: 利用层间一致性的可逆网络进行自监督低剂量计算机断层扫描图像去噪。载于：IEEE/CVF冬季计算机视觉应用会议论文集。第5614–5623页（2023年） 5. Buzug, T.M.: 计算机断层扫描。载于：Springer医学技术手册，第311–342页。施普林格（2011年） 6. Chen, H., Zhang, Y., Kalra, M.K., Lin, F., Chen, Y., Liao, P., Zhou, J., Wang, G.: 基于残差编码器-解码器卷积神经网络的低剂量CT。IEEE医学影像汇刊 **36**(12), 2524–2535（2017年） 7. Chen, X., Li, Z., Xu, Z., Ouyang, C., Qin, C., 等：FedFDD：采用频域分解的联邦学习，用于低剂量CT去噪。载于：深度学习医学影像会议（2024年） 8. Darzidehkalani, E., Ghasemi-Rad, M., Van Ooijen, P.: 医学影像中的联邦学习：第一部分：迈向多中心医疗生态系统。美国放射学会杂志 **19**(8), 969–974（2022年） 9. Du, W., Chen, H., Yang, H., Zhang, Y.: 用于低剂量CT的解耦生成对抗网络。EURASIP信号处理进展杂志 **2021**(1), 34（2021年） 10. Feng, C.M., Yan, Y., Wang, S., Xu, Y., Shao, L., Fu, H.: 用于磁共振图像重建的特异性保持联邦学习。IEEE医学影像汇刊 **42**(7), 2010–2021（2022年） 11. Gao, Q., Chen, Z., Zeng, D., Zhang, J., Ma, J., Shan, H.: 噪声启发扩散模型用于可泛化的低剂量CT重建。arXiv预印本 arXiv:2506.22012（2025年） 12. Gao, Q., Li, Z., Zhang, J., Zhang, Y., Shan, H.: CoreDiff：用于低剂量CT去噪和泛化的上下文误差调制广义扩散模型。IEEE医学影像汇刊 **43**(2), 745–759（2023年） 13. Gu, J., Yang, T.S., Ye, J.C., Yang, D.H.: 利用小波辅助噪声解耦的CycleGAN极低剂量心脏CT去噪。医学图像分析**74**, 102209（2021年）

14. Guo, B., Lu, D., Szumel, G., Gui, R., Wang, T., Konz, N., Mazurowski, M.A.: 扫描仪域偏移对医学影像中深度学习性能的影响：一项实验研究。arXiv预印本 arXiv:2409.04368（2024年） 15. Guo, P., Wang, P., Zhou, J., Jiang, S., Patel, V.M.: 利用联邦学习开展多机构协作，以改进基于深度学习的磁共振图像重建。载于：IEEE/CVF计算机视觉与模式识别会议论文集。第2423–2432页（2021年） 16. Gupta, S., Kumar, S., Chang, K., Lu, C., Singh, P., Kalpathy-Cramer, J.: 利用多机构数据进行分布式深度学习的协作式隐私保护方法。RadioGraphics **43**(4), e220107（2023年） 17. Kingma, D.P.: Adam：一种随机优化方法。arXiv预印本 arXiv:1412.6980（2014年） 18. Kniep, I., Mieling, R., Gerling, M., Schlaefer, A., Heinemann, A., Ondruschka, B.: 低剂量计算机断层扫描的贝叶斯重建算法尚不适用于临床环境。Journal of Imaging **9**(9), 170（2023年） 19. Kudo, H., Suzuki, T., Rashed, E.A.: 稀疏视角CT和内部CT图像重建——压缩感知与微分反投影简介。Quantitative imaging in medicine and surgery **3**(3), 147（2013年） 20. Kumar, R., Zeng, S., Kumar, J., Mao, X., 等：用于提升PET-CT成像中肝脏病灶分割效果的隐私保护联邦迁移学习。Artificial Intelligence in Medicine，第103245页（2025年） 21. Lee, J., Yoon, W., Kim, S., Kim, D., Kim, S., So, C.H., Kang, J.: BioBERT：用于生物医学文本挖掘的预训练生物医学语言表征模型。Bioinformatics **36**(4), 1234–1240（2020年） 22. Li, Q., He, B., Song, D.: 模型对比联邦学习。载于：IEEE/CVF计算机视觉与模式识别会议（CVPR）论文集。第10713–10722页（2021年） 23. Li, T., Sahu, A.K., Zaheer, M., 等：异构网络中的联邦优化。载于：机器学习系统会议（MLSys）论文集。第2卷，第429–450页（2020年） 24. Li, X., JIANG, M., Zhang, X., Kamp, M., Dou, Q.: FedBN：通过局部批归一化针对非独立同分布特征进行联邦学习。载于：国际学习表征会议（2021年） 25. Li, Z., Zhou, S., Huang, J., Yu, L., Jin, M.: 使用非配对深度学习方法研究低剂量CT图像去噪。IEEE辐射与等离子体医学科学汇刊 **5**(2), 224–234（2020年） 26. Li, Z., Ye, S., Long, Y., Ravishankar, S.: SUPER Learning：用于低剂量CT图像重建的监督-无监督框架。载于：IEEE/CVF国际计算机视觉会议研讨会论文集。第0–0页（2019年） 27. Lin, W.A., Liao, H., Peng, C., Sun, X., Zhang, J., Luo, J., Chellappa, R., Zhou, S.K.: DudoNet：用于CT金属伪影去除的双域网络。载于：IEEE/CVF计算机视觉与模式识别会议论文集。第10512–10521页（2019年） 28. Liu, Q., Chen, C., Qin, J., Dou, Q., Heng, P.A.: FedDG：通过连续频率空间中的情景式学习进行医学图像分割的联邦域泛化。载于：IEEE/CVF计算机视觉与模式识别会议论文集。第1013–1023页（2021年） 29. Lu, S., Yang, B., Xiao, Y., Liu, S., Liu, M., Yin, L., Zheng, W.: 基于微分稀疏的低剂量CT迭代重建。Biomedical Signal Processing and Control **79**, 104204（2023年） 30. McCollough, C.: TU-FG-207A-04：低剂量CT大挑战概述。Medical physics **43**(6Part35), 3759–3760（2016年）

31. McMahan, B., Moore, E., Ramage, D., 等：基于去中心化数据的深度网络通信高效学习。载于：人工智能与统计。第1273–1282页。PMLR（2017年） 32. Mudeng, V., Kim, M., Choe, S.w.：结构相似性指数在医学图像分析中的应用前景。《应用科学》**12**(8), 3754（2022年） 33. Su, B., Xu, J., Hu, X., Deng, K., Li, J., Lu, Z.：Vq-scd：向量量化与未知扫描条件下的自监督低剂量CT去噪相结合。载于：医学图像计算与计算机辅助干预国际会议。第673–683页。施普林格（2025年） 34. Team, N.L.S.T.R.：低剂量计算机断层扫描筛查降低肺癌死亡率。《新英格兰医学杂志》**365**(5), 395–409（2011年） 35. Wang, H., He, R., Zhang, X., Bian, Z., Zeng, D., Ma, J.：一种点对点联邦持续学习网络，用于提升多家机构的CT成像。arXiv预印本 arXiv:2306.02037（2023年） 36. Wang, H., Zhang, X., Ren, X., Zhang, Z., Yang, S., Lian, C., Ma, J., Zeng, D.：通过服务器轮换式联邦机器学习实现协作式隐私保护跨厂商联合诊断成像。《通信工程》**4**(1), 148（2025年） 37. Wang, J., Liu, Q., Liang, H., Joshi, G., Poor, H.V.：解决异构联邦优化中的目标不一致问题。载于：神经信息处理系统进展**33**，7611–7623（2020年） 38. Wang, R., Chen, Z., Song, Z., Fang, W., Zhang, J., Tu, D., Tang, Y., Xu, M., Ye, X., Lu, L. 等：利用预训练视觉模型和语义引导对比学习实现解剖结构感知低剂量CT去噪。载于：医学图像计算与计算机辅助干预国际会议。第13–23页。施普林格（2025年） 39. Wang, Z., Cun, X., Bao, J., Zhou, W., Liu, J., Li, H.：Uformer：一种通用的U形图像复原变换器。载于：IEEE/CVF计算机视觉与模式识别会议论文集。第17683–17693页（2022年） 40. Wolterink, J.M., Leiner, T., Viergever, M.A., Išgum, I.：用于降低低剂量CT噪声的生成对抗网络。IEEE医学影像汇刊**36**(12), 2536–2545（2017年） 41. Wu, C., Wu, F., Lyu, L., Huang, Y., Xie, X.：通过知识蒸馏实现通信高效的联邦学习。《自然·通讯》**13**(1), 2032（2022年） 42. Xia, W., Yang, Z., Lu, Z., Wang, Z., Zhang, Y.：Regformer：一种基于局部–非局部正则化的稀疏视角CT重建模型。《IEEE辐射与等离子体医学科学汇刊》**8**(2), 184–194（2023年） 43. Xu, J., Zhu, Y.n., Zhang, X., Ding, Q.：用于多机构低剂量CT重建的个性化伪影建模与联邦学习。《反问题与成像》**19**(5), 858–876（2025年） 44. Xu, Q., Yu, H., Mou, X., Zhang, L., Hsieh, J., Wang, G.：通过字典学习实现低剂量X射线CT重建。IEEE医学影像汇刊**31**(9), 1682–1697（2012年） 45. Yang, Q., Yan, P., Zhang, Y., Yu, H., Shi, Y., Mou, X., Kalra, M.K., Zhang, Y., Sun, L., Wang, G.：使用结合Wasserstein距离和感知损失的生成对抗网络进行低剂量CT图像去噪。IEEE医学影像汇刊**37**(6), 1348–1357（2018年） 46. Yang, Z., Chen, Y., Wang, Z., Shan, H., Chen, Y., Zhang, Y.：患者级解剖结构与扫描级物理特性相结合：大语言模型赋能的个性化联邦低剂量CT去噪。载于：计算机视觉与模式识别会议论文集。第5154–5163页（2025年）

47. Yang, Z., Xia, W., Lu, Z., Chen, Y., Li, X., Zhang, Y.：用于多机构CT成像的基于超网络的个性化联邦学习。arXiv预印本 arXiv:2206.03709（2022年） 48. Yang, Z., Xia, W., Lu, Z., Chen, Y., Li, X., Zhang, Y.：用于CT成像的基于超网络、物理驱动的个性化联邦学习。IEEE神经网络与学习系统汇刊（2023年） 49. Ye, S., Ravishankar, S., Long, Y., Fessler, J.A.：Spultra：结合统计模型与学习型图像模型的低剂量CT图像重建。IEEE医学影像汇刊**39**(3), 729–741（2019年） 50. Yin, Z., Xia, K., Wang, S., He, Z., Zhang, J., Zu, B.：通过改进的循环一致对抗网络与注意力集成进行非配对低剂量CT去噪。《The Visual Computer》**39**(10), 4423–4444（2023年） 51. Zhang, W., Huang, B., Chen, S., Xu, X., Wu, W., Liu, Q.：用于少样本低剂量CT重建的分块Hankel扩散模型。arXiv预印本 arXiv:2405.17167（2024年） 52. Zhang, Z., Yu, L., Liang, X., Zhao, W., Xing, L.：TransCT：用于低剂量计算机断层扫描的双路径变换器。载于：医学图像计算与计算机辅助干预国际会议。第55–64页。施普林格（2021年） 53. Zhao, H., Gu, Y., Zhao, Z., Du, B., Xu, Y., Yu, R.：WIA-LD2ND：基于小波的图像配准，用于自监督低剂量CT去噪。载于：医学图像计算与计算机辅助干预国际会议。第764–774页。施普林格（2024年） 54. Zheng, X., Ravishankar, S., Long, Y., Fessler, J.A.：PWLS-Ultra：一种用于低剂量三维CT图像重建的高效聚类与学习方法。IEEE医学影像汇刊**37**(6), 1498–1510（2018年） 55. Zhou, S.K., Greenspan, H., Davatzikos, C., Duncan, J.S., Van Ginneken, B., Madabhushi, A., Prince, J.L., Rueckert, D., Summers, R.M.：医学影像深度学习综述：成像特征、技术趋势、进展亮点案例研究及未来展望。IEEE会刊 **109**(5), 820–838（2021年） 56. Ziller, A., Mueller, T.T., Stieger, S., Feiner, L.F., Brandt, J., Braren, R., Rueckert, D., Kaissis, G.：协调医学影像人工智能中的隐私与准确性。Nature Machine Intelligence**6**(7), 764–774（2024年）