

DOI:10.19651/j.cnki.emt.2519203

# IADR-Net: 一种结合迭代优化与细节注意力增强的 稀疏角 CT 重建网络\*

杨林鹏 刘 祎 梁旭东 桂志国

(中北大学信息与通信工程学院 太原 030051)

**摘要:** 稀疏角 CT 是临床 CT 成像中减少 X 射线辐射剂量的有效方法。然而,由于稀疏采样造成的投影不完备,图像重建中含有明显的条纹伪影。为解决这一问题,本文提出一种基于迭代优化展开的稀疏角 CT 图像重建网络 IADR-Net,该网络采用独特的双路并行架构设计,包含迭代重建子网络和局部-全局注意力网络(GLONA)细节恢复子网络两个核心组件。其中,迭代重建子网络基于快速迭代软阈值算法框架,通过可学习非线性变换和自适应阈值实现投影到图像重建;GLONA 子网络则采用局部与全局特征并行的双分支结构,并通过自调节融合模块有效保持图像细节。两个子网络协同工作,分别专注于基于迭代展开的伪影消除和基于注意力机制的细节增强,最终通过特征融合输出高质量 CT 图像。在 Mayo 数据集的实验结果表明,该方法在伪影抑制和结构保持方面相较于若干代表算法展现出更有性能,为临床稀疏角 CT 成像提供了有效的解决方案。

**关键词:** 稀疏角 CT;迭代展开;局部-全局注意力;深度学习

**中图分类号:** TP391;TP381;TN91 **文献标识码:** A **国家标准学科分类代码:** 510.4050

## IADR-Net: A sparse-view CT reconstruction network with iterative optimization and dual-path attention enhancement

Yang Linpeng Liu Yi Liang Xudong Gui Zhiguo

(School of Information and Communication Engineering, North University of China, Taiyuan 030051, China)

**Abstract:** Sparse angle CT is an effective method to reduce X-ray radiation dose in clinical CT imaging. However, due to the incomplete projection caused by sparse sampling, the image reconstruction contains obvious fringe artifacts. In order to solve this problem, this paper proposes a sparse angle CT image reconstruction network based on iterative optimization deployment, IADR-Net, which adopts a unique dual-channel parallel architecture design, and includes two core components: Iterative reconstruction sub-network and global-local attention network (GLONA) detail recovery sub-network. Among them, the iterative reconstruction sub-network is based on the framework of fast iterative soft threshold algorithm, and realizes projection-to-image reconstruction through learnable nonlinear transformation and adaptive thresholding. The GLONA sub-network adopts a double-branch structure with parallel local and global features, and effectively maintains the image details through the self-adjusting fusion module. The two sub-networks work together to focus on artifact removal based on iterative expansion and detail enhancement based on attention mechanism, respectively, and finally output high-quality CT images through feature fusion. Experimental results on the Mayo dataset show that the proposed method has better performance than several representative algorithms in terms of artifact suppression and structure preservation, and provides an effective solution for clinical sparse angle CT imaging.

**Keywords:** sparse angle CT; iterative expansion; local-global attention; deep learning

## 0 引 言

X 射线计算机断层扫描(CT)技术作为重要的医学影

像学检查手段,已广泛应用于临床诊断和工业检测领域。该技术虽能清晰显示人体内部解剖结构,但其电离辐射可能导致的健康风险日益引发关注。为降低辐射剂量,稀疏

收稿日期:2025-06-26

\* 基金项目:自然科学基金面上项目(202303021211148)、山西省自然科学基金青年项目(202203021222038)、国家自然科学基金(62401517)项目资助

角 CT 技术通过减少投影数量有效控制了辐射暴露,同时提高了扫描效率。然而,投影数据的缺失使得传统滤波反投影(filtered back projection,FBP)重建算法产生明显条纹伪影,严重影响图像质量及其在精确诊断中的应用价值。因此,开发适用于稀疏采样条件的高质量 CT 重建算法成为当前医学影像领域的重要研究方向。

迭代重建算法在稀疏角 CT 重建中具有重要应用价值。传统迭代方法通过建立正向和反向投影的交替计算框架,在投影域和图像域之间进行多次迭代优化,典型算法包括代数重建算法和同步代数重建算法等。为提升重建质量,研究者引入了多种先验约束方法,如全变分(total variation,TV)和非局部均值。近期,董建等<sup>[1]</sup>提出一种基于非线性压缩感知的改进算法,通过将联合双边滤波器引入正则化项,并结合临近点算法构建加速迭代框架。然而,传统迭代算法仍存在参数选择困难、计算复杂度高等问题。

深度学习技术的引入为迭代重建算法带来了新的发展机遇。Chen 等<sup>[2]</sup>提出的 LEARN 框架创新性地将广义正则项约束引入迭代模型,通过设计的 CNN 模块实现参数的自动学习和更新。在此基础上,Xia 等<sup>[3-4]</sup>通过引入先进的图卷积和 Transformer 机制,提出了改进型网络 MAGIC 和 RegFormer,从而提升了重建图像的质量。此外,周先春等<sup>[5]</sup>提出的基于注意力机制的双卷积图像去噪网络,通过多尺度特征提取与动态特征精炼注意力机制,有效提升了特征表达能力与细节保真度,为深度重建模型的结构优化提供了有益参考。Zhang 等<sup>[6]</sup>提出了双域 CNN 正则项迭代模型,Wang 等<sup>[7]</sup>开发了基于 ADMM 的深度重建算法。在算法优化方面,Huang 等<sup>[8]</sup>提出的数据一致性伪影消除算法利用先验图像补充缺失的投影信息。柴世杰等<sup>[9]</sup>提出了一种基于多尺度生成对抗网络的锥束 CT 图像耦合伪影校正方法,通过引入特征金字塔结构与卷积块注意机制进一步提升了伪影去除效果和图像细节保真度。Zhang 等<sup>[10]</sup>设计的 JSR-Net 模型通过空间-子域联合重建框架显著提升了细节还原能力,Chun 等<sup>[11]</sup>提出的 Momentum-Net 通过结合回归神经网络有效加快了收敛速度。Xiang 等<sup>[12]</sup>将 FISTA 算法与 CNN 相结合优化迭代过程,Zhang 等<sup>[13]</sup>采用半二次分裂-共轭梯度算法作为骨干网络,这些方法都在保证重建质量的同时显著提升了计算效率。

然而,大多数基于深度学习的方法在追求主动去噪的同时,不能很好地恢复纹理和边缘信息,从而导致图像细节出现模糊现象和结构丢失。已有研究表明,相比单路径网络,双分支结构能更好地兼顾全局结构与局部细节,增强复杂纹理的表征能力<sup>[14]</sup>。因此本研究提出了一种新的双网络架构:一种结合迭代优化与细节注意力增强的稀疏角 CT 重建网络——迭代-注意力双通路重建网络(iterative optimization and attention dual-path reconstruction network, IADR-Net)。该方法首先设计初始值增强模块(initial enhancement module,IEM),用于对初始图像进行

结构补强与伪影抑制,为后续重建提供更高质量的初始估计,加速网络收敛。在此基础上,构建由基于 FISTA 算法展开的迭代重建子网络和局部-全局注意力网络(global-local attention network, GLONA)组成的双通路架构。前者通过可解释的迭代优化实现整体结构还原,后者利用局部-全局特征融合机制保持细节一致性与纹理清晰度。两个子网络并行协作并最终融合输出,在抑制伪影的同时显著提升细节保真度,克服了传统方法中过度平滑的缺陷。实验结果表明,IADR-Net 在保持重建效率的同时,能更好地恢复 CT 图像的细微结构。本文的主要创新在于:1)构建迭代优化与注意力机制融合的双通路网络结构;2)引入 IEM 模块以提升初始重建质量;3)通过局部-全局协同注意力机制有效增强细节与结构保持。

## 1 CT 重建模型

X 射线 CT 成像可表述为以下线性问题,即:

$$\mathbf{y} = \mathbf{A}\mathbf{x} \quad (1)$$

式中: $\mathbf{x} \in \mathbf{R}^{C_1}$  表示矢量化 CT 图像, $\mathbf{A} \in \mathbf{R}^{C_1 \times C_2}$  表示由扫描几何和重建图像尺寸决定的系统矩阵, $\mathbf{y} \in \mathbf{R}^{C_2}$  表示投影数据。CT 重建的主要任务是从投影数据  $\mathbf{y}$  中得到重建图像  $\mathbf{x}$ 。在投影数据完整且噪声较低的情况下,可采用滤波反投影(FBP)算法对式(1)进行解析反演。然而,在稀疏扫描条件下,FBP 重建图像往往伴随严重的条形伪影,影响图像质量和诊断可靠性。迭代重建算法是克服这些难题的有效方法,其通过最小化约束目标函数来进行求解。常用的目标函数为:

$$\mathbf{x} = \underset{\mathbf{x}}{\operatorname{argmin}} \frac{1}{2} \|\mathbf{A}\mathbf{x} - \mathbf{y}\|_2^2 + \delta R(\mathbf{x}) \quad (2)$$

式中:第 1 项是数据保真度,用于确保重建图像  $\mathbf{x}$  和测量数据  $\mathbf{y}$  之间的一致性。 $R(\mathbf{x})$  为包含图像先验信息的正则项,从而提升重建稳定性与质量。超参数用于平衡数据保真项和正则项之间的权衡。常用的  $R(\mathbf{x})$  可以设计为总变分,稀疏变换域正则项等,针对不同的  $R(\mathbf{x})$ ,可以选择相应的优化算法进行求解,如交替方向乘子法,近端梯度下降法<sup>[15]</sup>,迭代软阈值算法及快速迭代软阈值算法(fast iterative shrinkage thresholding algorithm,FISTA)等。

## 2 本文方法

### 2.1 迭代优化模型

鉴于医学图像在某些变换域中具有良好的稀疏性特征,本文在重建模型中利用稀疏变换作为正则项,以增强图像的先验约束能力,从而提升在稀疏视图条件下的重建质量。基于此,对于式(2),引入稀疏变换正则化项后,可构建如式(3)所示的重建模型。

$$\mathbf{x} = \underset{\mathbf{x}}{\operatorname{argmin}} \frac{1}{2} \|\mathbf{A}\mathbf{x} - \mathbf{y}\|_2^2 + \delta \|F(\mathbf{x})\|_1 \quad (3)$$

式中: $F(\cdot)$  为稀疏变换算子,可采用傅里叶变换(Fourier

transform, FT)、离散余弦变换(discrete cosine transform, DCT)或离散小波变换(discrete wavelet transform, DWT)等。鉴于 FISTA 在求解  $L_1$  范数正则化问题时计算复杂度小、容易操作的优势, 本文将其作为重建子网络的理论基础, 引导模型迭代更新以逼近全局最优解。其迭代步骤如式(4)~(7)所示。

$$\mathbf{r}^{(k)} = \mathbf{z}^{(k)} - \rho \mathbf{A}^T (\mathbf{A} \mathbf{z}^{(k)} - \mathbf{y}) \quad (4)$$

$$\mathbf{x}^{(k)} = \tau_\theta(\mathbf{r}^{(k)}) =$$

$$\operatorname{argmin}_x \frac{1}{2} \|\mathbf{x} - \mathbf{r}^{(k)}\|_2^2 + \delta \|F(\mathbf{x})\|_1 \quad (5)$$

$$t^{(k+1)} = \frac{1 + \sqrt{1 + 4(t^{(k)})^2}}{2} \quad (6)$$

$$\mathbf{z}^{(k+1)} = \mathbf{x}^{(k)} + \frac{t^{(k)} - 1}{t^{(k+1)}} (\mathbf{x}^{(k)} - \mathbf{x}^{(k-1)}) \quad (7)$$

式中:  $k$  表示 FISTA 中的迭代次数,  $\rho$  为步长参数。  $\tau_\theta(\cdot)$  是与正则项相关的近端映射, 其求解方式是本文算法的关键。当  $F(\cdot)$  表示小波变换, 由于小波变换的正交性,  $\tau_\theta = F^T \operatorname{soft}(F(\mathbf{r}), \theta)$ , 其中  $\operatorname{soft}(F(\mathbf{r}), \theta) = \operatorname{sign}(F(\mathbf{r})) \max\{|F(\mathbf{r})| - \theta, 0\}$ 。然而, 小波变换作为线性变换在表达图像复杂纹理和非局部结构方面存在局限性, 难以满足高质量重建的需求。为提升结构保真度与细节恢复效果, 本文引入表达能力更强的非线性变换。由于此类变换结构更为

复杂, 其对应的近端映射缺乏闭式解, 求解过程更为复杂。为此, 本文采用基于可学习卷积核的方式对该非线性稀疏变换及其近端映射进行建模, 从而实现更有效的图像稀疏表达与优化求解。

此外, FISTA 在每次迭代中引入了前两次估计值  $\mathbf{x}^{(k-1)}$  和  $\mathbf{x}^{(k)}$  的线性组合作为当前输入, 从而实现了动量加速。这种策略不仅在保持计算复杂度基本不变的前提下显著提升了收敛速度和优化效率, 还在一定程度上有助于避免陷入局部极小值。

## 2.2 IADR-Net

基于前文提出的 FISTA 迭代重构框架, 本文进一步将其进行网络化展开, 构建为一个端到端可训练的深度学习网络, 作为整体架构中的稀疏重建网络分支, 从而融合优化模型的可解释性与深度学习的强表征能力, 通过将每一步迭代过程映射为网络层, 实现稀疏变换与重建优化的高效求解。在次基础上, 本文引入细节恢复子网络 (GLONA), 与稀疏重建子网络协同工作, 形成一个双路并行的整体架构。该结构通过融合全局与局部信息, 有效提升图像细节的还原质量, 实现稀疏重建与细节增强的深度结合。此外, 在重建初始阶段, 本文引入初始值增强模块 (IEM), 以提升传统 FBP 初始图像的质量, 为后续网络提供更加可靠的输入基础。整体网络结构如图 1 所示。




图 1 IADR-Net 架构

Fig. 1 IADR-Net structure

### 1) IEM 模块

采用基于 U-Net 架构设计的残差连接模块, 可以增强不同层次网络之间的特征信息交互, 从而达到特征增强的效果, 同时具有良好的抗噪和抗干扰能力, 能有效改善迭代重建过程中的图像质量, 该模块的结构细节如图 2 所示。

### 2) 迭代重建子网络

该子网络由多个迭代阶段级联组成, 每个阶段均包含 3 个关键模块: 梯度下降模块、近端映射模块与动量加速模

块, 分别对应式(4)、(5)与(7)中的各个迭代步骤。通过这种结构化设计, 可实现对 FISTA 优化流程的逐步逼近与高效拟合。图 3 显示了迭代重构子网络的整体结构。

(1) 梯度下降模块  $\mathbf{r}^{(k)}$ : 该模块基于式(4)提供的梯度信息, 对目标函数中光滑可导部分进行更新。具体地, 给定上一层的输出作为输入, 通过梯度下降对重建图像进行迭代更新, 从而获得更接近最优解的估计值。值得注意的是, 式(4)对应的是数据一致性子问题的解析解形式。本文在保持 FISTA 迭代框架结构的前提下, 允许步长参数

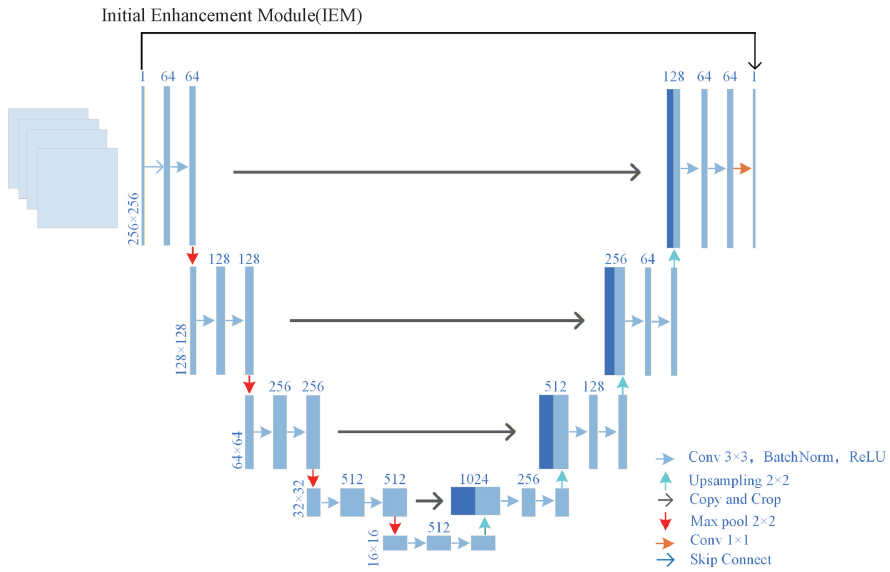


图 2 初始值增强模块增强的结构细节

Fig. 2 Structural details of the initial enhancement module

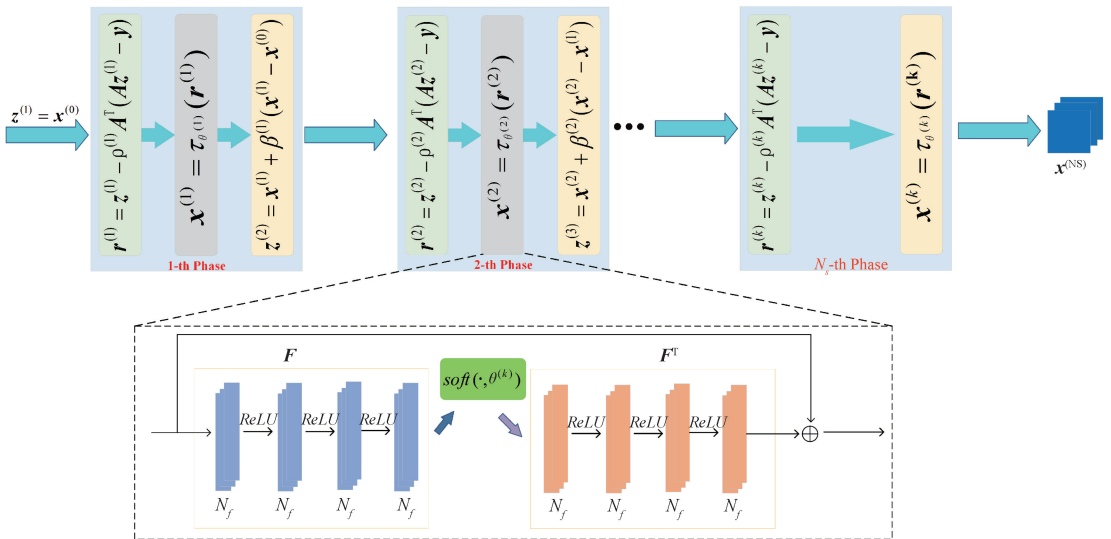


图 3 迭代重建子网络的整体结构

Fig. 3 The overall structure of the iterative reconstruction sub-network

在不同迭代中自适应变化(传统 FISTA 中该参数通常为固定)。因此,输入  $\mathbf{z}^{(k)}$  的模块输出最终定义为:

$$\mathbf{r}^{(k)} = \mathbf{z}^{(k)} - \rho^{(k)} \mathbf{A}^T (\mathbf{A} \mathbf{z}^{(k)} - \mathbf{y}) \quad (8)$$

(2)近端映射模块  $\mathbf{x}^{(k)}$ :该模块是对目标函数中不可微正则项的近端映射算子的展开,用于处理该部分的优化问题,其核心思路是对式(5)中的近端算子进行可学习的表示,并借助可学习神经网络实现高效求解。具体而言,传统模型中稀疏正则化通常依赖固定变换(如小波或 DCT)及软阈值操作进行特征提取与去噪,但此类方法难以充分表达图像中复杂纹理与细节变化。为有效应对非光滑约束所带来的优化挑战,本文提出的模块采用深度网

络替代传统近端映射操作,以更灵活地进行建模和求解。为此,本文借助 CNN 的强表达能力与通用近似性质,设计了一个非线性、可学习的稀疏近似网络,如图 3 中虚线框所示。稀疏变换  $F(\cdot)$  由 4 个线性卷积算子(不含偏置项)组成,并由整流线性单元(ReLU)分隔。第 1 个卷积算子对应于  $N_f$  卷积核(每个卷积核大小为  $5 \times 5$ ),另外 3 个卷积层对应于另一组  $N_f$  卷积核(每个卷积核大小为  $5 \times 5 \times N_f$ ,本文设置  $N_f = 64$ 。考虑到批量归一化(BN)可能引入人工伪影<sup>[16]</sup>,本模块未引入 BN 层。同时,为保证变换的可逆性和稳定性,本文引入了稀疏变换  $F(\cdot)$  的逆运算,并设置正向与逆向变换为对称结构,即均由 4 层卷积构成

(同样无偏置项,包含  $ReLU$  激活)。显然,  $F(\cdot)$  和  $F^T(\cdot)$  都是可学习的,同时引入如下对称性损失来约束  $F^T \cdot F = \mathbf{I}$ 。

$$L_{sym} = \sum_{k=1}^{N_s} \| F^T(F(\mathbf{r}^{(k)})) - \mathbf{r}^{(k)} \|_2^2 \quad (9)$$

为了应对每次迭代中噪声或伪影程度的变化,本文采用以下策略提升网络的适应能力:一方面,  $\tau_\theta(\cdot)$  的参数在不同迭代中是共享的,以确保模型在全局结构上的一致性;另一方面,软阈值参数  $\theta^{(k)}$  则设为可学习的逐阶段变量,允许其在各个迭代中灵活调整,以适应不同阶段中估计图像中噪声与伪影强度的动态变化。此外,为进一步增强网络的特征传播能力,模块内部引入残差连接机制,在输入到输出之间建立跳转连接。因此,模块的输出定义为:

$$\mathbf{x}^{(k)} = \tau_\theta(\mathbf{r}^{(k)}) = \mathbf{x}^{(k-1)} + F^T \text{soft}(F(\mathbf{r}^{(k)}), \theta^{(k)}) \quad (10)$$

(3)动量加速模块:该模块结合了前两次迭代的结果,通过线性组合的方式对当前估计进行更新,从而加速收敛过程。在本网络中,进一步将式(6)中的固定更新参数  $t^{(k)}$  替换为可由训练数据集中自主学习的参数  $\beta^{(k)}$ ,即  $\beta^{(k)} = \frac{t^{(k)} - 1}{t^{(k+1)}}$ 。

### 3)细节恢复子网络

尽管初始重建子网络能够有效提供结构基础信息,但在细节还原方面仍存在一定不足。为进一步提升图像恢复质量,本文设计了细节恢复子网络 GLONA,以实现全局与局部特征的协同增强。在图像恢复任务中,单纯的局部注意力机制或非局部注意力机制都难以完整重建图像的全部信息。若简单地将这两种机制叠加使用,往往难以获得理想的恢复效果。Mou 等<sup>[17]</sup>研究者提出的协作注意力网络(COLA-Net)创新性地局部与非局部注意力机制有机结合,在多项图像恢复任务中取得了显著成效。基于这一研究思路,本研究设计了一个集成注意力模块(如图 1 中 GLONA 所示),该模块首先通过特征提取模块(feature extraction module, FEM)获取浅层特征,随后分别输入到并行的注意力子模块进行处理。特别地,本文采用自适应融合子模块(self-regulating merging module, SMM)动态生成特征权重,实现双分支特征的智能融合。这种融合方式区别于传统的串联或并联结构,通过可学习的自适应机制实现特征的最优组合。

#### (1)特征提取模块

本研究所提出的特征提取模块采用三维特征提取策略,其核心架构如图 1 中 FEM 模块所示。具体而言,输入图像首先经过浅层特征提取块(FEM)进行处理,输出特征图  $\mathbf{F}_{FEM}$ 。为提升特征提取效率与表达能力,FEM 模块基于密集连接网络设计,包含 5 个级联的卷积单元( $Conv + BN + ReLU$ )。该模块通过密集连接机制,实现多层次特征的高效复用与融合,有效增强了模块的特征表达能力。

不仅有助于完整提取三维空间信息,还显著增强了网络的特征表达能力。

#### (2)局部注意力选择模块

为提升图像重建中对局部结构和细节的建模能力,本文首先设计了局部注意力选择模块(local attention selection unit, LASU),其核心结构如图 4 所示。该模块采用深度异构的双分支架构,并结合 CBAM<sup>[18]</sup> 注意力机制,在相同感受野下分别优化通道敏感性与空间局部感知能力。通过并行设计的通道重标定路径和空间区域聚焦路径,LASU 可实现多尺度局部特征的自适应建模。特征融合模块进一步整合两条分支的互补信息,最终输出的特征图  $\mathbf{F}_{LA}$  兼具细粒度的通道表达与局部空间结构,为后续图像重建任务提供更加丰富且高效的特征表示。

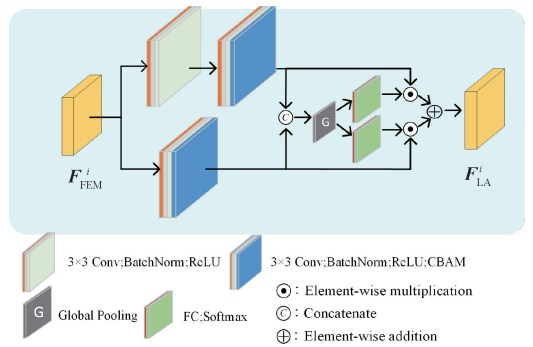


图 4 局部注意力选择模块结构

Fig. 4 Illustration of local attention selection unit

#### (3)全局空间注意力模块

在完成对局部信息的捕捉之后,为进一步增强网络对长距离依赖信息的建模能力,在 GLONA 模块中引入了全局空间注意力机制(global spatial attention unit, GSAU),其结构如图 5 所示。全局注意采用的是片段式非局部操作。给定特征图输入  $\mathbf{F}_{FEM} \in \mathbf{R}^{C \times W \times H}$ , 首先使用 3 个独立的  $1 \times 1$  卷积层作为嵌入函数  $\theta, \phi$  和  $g$ , 生成查询 ( $\mathbf{Q}$ )、键 ( $\mathbf{K}$ ) 和值 ( $\mathbf{V}$ ), 它们不会改变特征图的大小。然后, 每个特征图被分割成  $N$  个大小为  $patch \in \mathbf{R}^{C \times W_p \times H_p}$  的块。从  $\mathbf{Q}$  和  $\mathbf{K}$  扩展出的每个三维补丁都会重塑为一维特征向量, 从而得到  $\tilde{\mathbf{Q}}$  和  $\tilde{\mathbf{K}}$ 。根据  $\tilde{\mathbf{Q}}$  和  $\tilde{\mathbf{K}}$  生成的图像片段距离矩阵的权重, 收集有价值的信息, 更新从  $\mathbf{V}$  扩展的每个三维片段。最后, 将更新的滑动局部块重新组合, 并通过简单的  $1 \times 1$  卷积将增强的特征图调整回原始大小  $C \times W \times H$ , 从而打印出包含全局信息  $\mathbf{F}_{GS}$  的特征图。

$$Attention(\mathbf{Q}, \mathbf{K}, \mathbf{V}) = \text{soft}(\tilde{\mathbf{Q}}^T \tilde{\mathbf{K}}) \mathbf{V} \quad (11)$$

研究表明,与基于像素的计算方法相比,基于三维补丁的相似性关系计算方法更为高效和稳健。考虑到重组操作过程中块与块之间的重叠,本文采用了平均法来处理重叠区域。

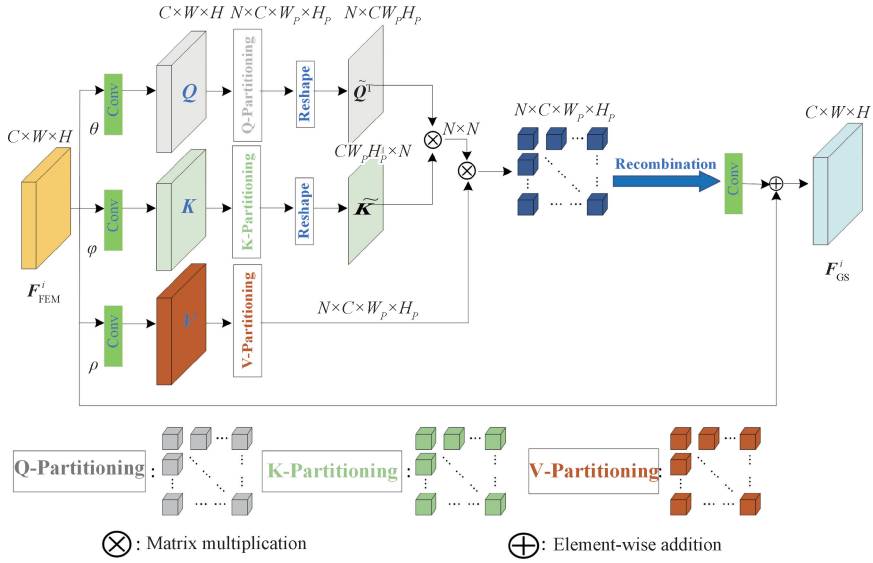


图 5 全局注意力示意图

Fig. 5 Illustration of global spatial attention unit

#### (4) 自适应融合子模块

在图像重建过程中,如何在局部与非局部特征之间实现精确权衡是一项关键挑战。为此,本文设计了一个自适应特征融合机制(如图 1 中 SMM 模块所示)。具体流程如下:首先,将局部注意力选择模块  $F_{LA}$  与全局空间注意力模块  $F_{GS}$  输入融合子模块;其次,经过池化层、全连接层和激活函数的协同处理,动态生成对应的特征权重系数 ( $W_{LA}$  和  $W_{GS}$ );最终,采用加权求和运算输出融合特征  $F_{GLONA}$ 。该自适应融合策略有效克服了人工设定特征权重的局限性,实现了局部细节与非局部上下文信息的最优组合。

$$\begin{cases} v = GP(F_{LA} + F_{GS}) \\ W_{GS}, W_{LA} = \text{soft max}([Q_{Linear1}(v), Q_{Linear2}(v)]) \\ F_{GLONA} = F_{LA} \cdot W_{LA} + F_{GS} + W_{GS} \end{cases} \quad (12)$$

式中:  $GP$  是全局池化层,  $Q_{Linear1}(\cdot)$  和  $Q_{Linear2}(\cdot)$  是两个独立的线性层,  $v \in \mathbf{R}^C$  是全局特征向量。  $W_{GS}$  和  $W_{LA}$  具有内容感知功能,因此注意力分支可根据其特征选择性地重建图像内容。

#### 2.3 损失函数设计

给定训练数据对  $\{y, x^*\}$ , IADR-Net 将  $y$  作为输入,并生成重建结果  $x_{pred}$ 。本文在保持重建准确性的基础上,最小化预测结果与真实图像之间的差异,同时增加结构相似性、对称性约束及感知损失,以进一步增强图像细节和结构还原能力。基于此,本文设计的端到端损失函数如下:

$$L_{total} = L_{mse} + \lambda_1 L_{sym} + \lambda_2 L_{ssim} + \lambda_3 L_{percep} \quad (13)$$

$$L_{mse} = \frac{1}{N_s} \sum_{i=1}^{N_s} \|x_i - x_i^*\|_2^2 \quad (14)$$

$$L_{ssim} = \frac{(2\mu_x \mu_{x^*} + C_1)(2\sigma_{xx} + C_2)}{(\mu_x^2 + \mu_{x^*}^2 + C_1)(\sigma_x^2 + \sigma_{x^*}^2 + C_2)} \quad (15)$$

式中:  $\lambda_1, \lambda_2, \lambda_3$  是平衡参数,  $\mu_x$  和  $\mu_{x^*}$  代表输出结果  $x$  和真实图像  $x^*$  的平均灰度级,  $\sigma_x$  和  $\sigma_{x^*}$  代表输出结果  $x$  和真实图像  $x^*$  的灰色标准偏差,  $L_{percep}$  为感知损失,  $N_s$  为样本总数。

在整体损失中,  $\lambda_1$  保证了重建结果与原图的像素一致性;  $\lambda_2$  强调结构相似性约束,使网络在优化过程中更加关注全局结构与边缘保持,从而有效减少伪影与结构失真;  $\lambda_3$  对应感知损失项,用于引导模型学习高层语义特征,提升重建图像的视觉质量与细节还原能力。根据经验分析,本文将  $\lambda_1, \lambda_2, \lambda_3$  分别设置为 0.01、0.01 和 0.005。过大或过小的权重会导致结构失真或纹理过度强化,因此上述设定可在平滑性与细节保持之间取得平衡。最终,该组合在不同采样角度下均表现出稳定的收敛性能与较高的重建指标,验证了参数设置的合理性。

## 3 实验结果及分析

### 3.1 参数设置

本文对所提出的 IADR-Net 进行了系统的实验评估,并与稀疏角 CT 重建领域中的多种代表性方法进行了对比分析。网络训练过程中采用 Adam 优化器,初始学习率设置为  $1 \times 10^{-4}$ ,并在训练后期逐步衰减至  $1 \times 10^{-6}$ 。所有基于深度学习的模型训练与测试均在 PyTorch 框架下完成,实验运行平台为配备 NVIDIA RTX 4090 24 GB 显卡与 Intel i7-9700K 3.6 GHz 处理器的工作站。

### 3.2 实验数据

为评估所提出的重建性能,本研究采用了在“2016 NIH-AAPM-Mayo Clinic 低剂量 CT 挑战赛”<sup>[19]</sup>中授权的公开数据集。该数据集包含 10 位患者的 5 936 张全剂量 CT 图像,分辨率为  $512 \times 512$ 。为了模拟稀疏采样,本文将原始投影数据降采样为 32、64 和 128 个视图。具体的采样

配置与实验参数如表 1 所示,在数据划分上,本文选取其中五名患者的数据(共计 2 190 张图像)作为训练集,另取 1 名患者的 433 图像用于测试评估。

表 1 数据采集参数

Table 1 Data acquisition parameters

参数	值
X 射线源到探测器的距离	1 068 mm
X 射线源到旋转中心的距离	595 mm
探测器数量	768
探测器像素大小	1 mm
重建尺寸	256×256
像素大小	0.585 9 mm <sup>2</sup>

### 3.3 对比结果

为验证所提出的 IADR-Net 的重建性能,本文将其与多种主流算法进行了对比,包括 FBP、FBPConvNet<sup>[20]</sup>、Framing U-Net<sup>[21]</sup>、REDCNN<sup>[22]</sup>、CAIR<sup>[23]</sup>。其中,FBPConvNet 采用 U-Net 结构作为图像后处理模块,有效抑制重建图像中的噪声与伪影。Framing U-Net 则通过双框架与紧框架等结构优化,在稀疏角 CT 中增强了对高频边缘的恢复能力;REDCNN 采用残差编码-解码结构,有效缓解了低剂量 CT 图像中的噪声与条纹伪影;CAIR 引入了集成注意力机制作为深度先验,并结合迭代优化策略,实现了高质量的稀疏角重建。

为保证对比的公平性,所有深度学习方法均依据原始论文描述的网络结构进行复现,并在相同训练条件下进行优化。具体而言,各模型的输入分辨率统一为 256×256,初始学习率为  $1 \times 10^{-4}$ ,并按指数衰减至  $1 \times 10^{-6}$ 。训练轮

数根据各模型的收敛速度分别设定,以确保在性能稳定后进行对比。其中,FBPConvNet 约在 220 个 epoch 收敛, Framing U-Net 约在 130 个 epoch 收敛, REDCNN 约在 170 个 epoch 收敛,而 CAIR 则在约 100 个 epoch 后达到稳定状态。上述设置确保了不同方法在相同数据与超参数条件下进行公平对比。

本文选择了 4 个指标来评估重建质量,即峰值信噪比 (PSNR)、结构相似性指数 (SSIM)、均方根误差 (RMSE) 以及视觉信息保真度 (VIFs)。

#### 1) 视觉对比

为全面评估各方法在不同数据完整度条件下的重建性能,本文首先在 128 个稀疏角条件下进行对比实验,并在统一测试集上与若干代表算法进行了评估。图 6 给出了各方法在 128 个稀疏角条件下的重建图像及局部感兴趣区域 (ROI) 放大图;其中图 6(a)~(c) 分别对应样本 1、样本 2 和样本 3。每行从左到右依次为:参考真值 (Label)、FBP、FBPConvNet、REDCNN、Framing U-Net、CAIR 以及本文方法 IADR-Net。可以看到,各重建方法的图像质量整体较高,但仍呈现出各自的特点与局限:FBP 算法在 128 个投影角度下仍存在明显的条状伪影,影响图像质量与诊断价值;FBPConvNet 在去除主要伪影方面效果显著,但在边缘区域出现模糊现象,并伴有伪影残留。Framing U-Net 和 CAIR 的重建结果与参考图像相似度较高,但由于过度平滑处理,部分微小血管和精细结构信息未能被完整保留。值得注意的是,在图中箭头所示 ROI 区域,本文提出的 IADR-Net 在边缘锐利度和细微结构保留方面具有显著优势,能够较好的呈现其他方法难以还原的血管纹理细节。

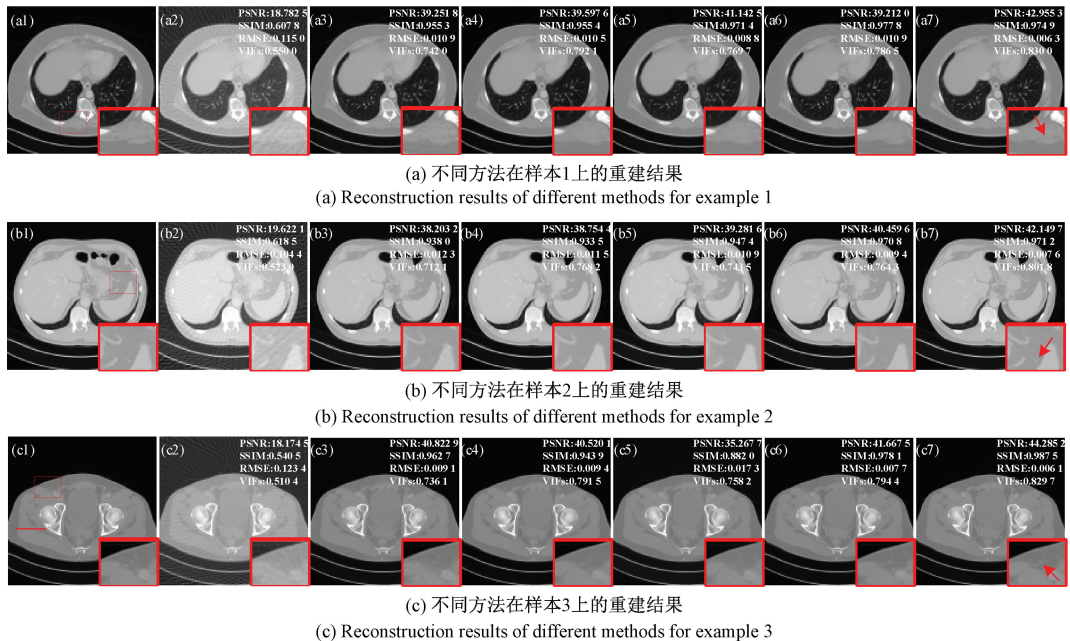


图 6 不同方法在 128 个稀疏角条件下的重建结果对比及 ROI 放大图

Fig. 6 Comparison of reconstruction results and ROI magnified views of different methods under 128 sparse projection angles

为进一步验证 IADR-Net 的重建性能,图 7 给出了图 6(c)中由实线标注位置提取的水平轮廓曲线,以评估不同方法在 128 个投影角度下的像素级拟合效果。结果表明,IADR-Net 和 REDCNN 能更好的拟合参考图

像的相应曲线。但通过观察图 7 中由箭头标注的局部区域可见,IADR-Net 的拟合效果优于 REDCNN 方法,说明 IADR-Net 相比其他方法具有更强的结构保留能力。

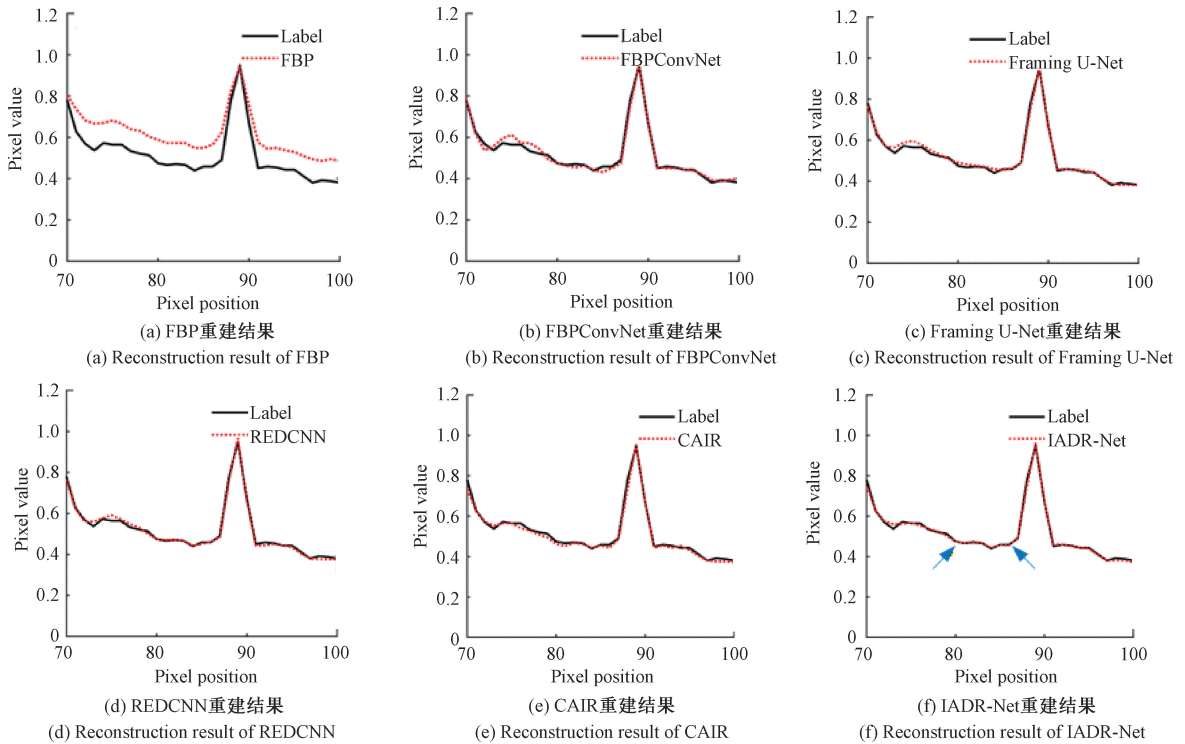


图 7 在 128 个投影角度下,不同对比算法重建结果沿图中实线标注剖面线的强度分布

Fig. 7 Under 128 projection angles, the intensity distributions of reconstruction results from different comparative algorithms along the profile line marked by a solid line in the figure


在 128 个投影角度下,IADR-Net 已展现出优越的重建性能。为进一步验证其在更低数据完整度条件下的稳健性与泛化能力,本文将投影角度减少至 64,并在相同测试集上进行对比实验。图 8 展示了各方法在 64 个稀疏角条件下的重建图像及局部感兴趣区域(ROI)放大图;其中图 8(a)~(c)分别对应样本 1、样本 2 和样本 3,每行从左到右依次为:参考真值(Label)、FBP、FBPCNN、REDCNN、Framing U-Net、CAIR 以及 IADR-Net。在该稀疏视角下,不同方法在重建质量方面表现出明显差异:传统 FBP 方法产生的条状伪影更为明显,伪影干扰加剧,显著降低了图像的可读性与诊断价值。相比之下,深度学习方法整体表现较为优越,但仍存在一定局限。例如,REDCNN 和 Framing U-Net 虽在整体图像质量上有所提升,但在骨骼边缘等高密度区域仍存在伪影残留;CAIR 方法在伪影抑制方面表现突出,尤其在骨骼周边区域,但由于其较强的平滑机制,导致部分细微结构信息被削弱。相比之下,本文提出的 IADR-Net 在图像细节还原与边缘结构保持方面表现更佳,能够更准确地保留临床评估所需的关键图像特征。

为进一步评估结构保真性,图 9 绘制了图 8(a)中由实

线标注位置提取的水平轮廓曲线,覆盖从低密度肌肉到高密度血管的区域。结果表明,虽然 CAIR 整体拟合较好,但在图中由箭头标注的片段,IADR-Net 呈现出更高拟合精度,能更准确还原细节结构。综合来看,IADR-Net 在抑制伪影的同时有效保留了高频信息,实现了细节还原与稳定性的良好平衡,显示出较强的泛化能力与临床应用潜力。


在 64 个投影角度下,IADR-Net 仍展现出良好的细节还原能力与结构保真性。为进一步验证其在更低数据完整度下的适应能力与鲁棒性,本文将投影角度进一步减少至 32,并继续在相同测试集上开展重建实验。图 10 展示了各方法在 32 个高度稀疏角条件下的重建图像及局部感兴趣区域(ROI)放大图;其中图 10(a)~(c)分别对应样本 1、样本 2 和样本 3,每行从左到右依次为:参考真值(Label)、FBP、FBPCNN、REDCNN、Framing U-Net、CAIR 以及 IADR-Net。

当投影数据高度稀疏时,FBP 算法的重建结果中伪影显著增强,图像结构严重扭曲,几乎失去诊断参考价值。FBPCNN 虽能有效抑制大部分伪影,但由于其后处理性质,仅基于 FBP 结果进行端到端修正,缺乏对投影域数据的显式约束,导致部分关键结构发生变形。Framing U-




(a) 不同方法在样本1上的重建结果

(a) Reconstruction results of different methods for example 1



(b) 不同方法在样本2上的重建结果

(b) Reconstruction results of different methods for example 2



(c) 不同方法在样本3上的重建结果

(c) Reconstruction results of different methods for example 3

图 8 不同方法在 64 个稀疏角条件下的重建结果对比及 ROI 放大图

Fig. 8 Comparison of reconstruction results and ROI magnified views of different methods under 64 sparse projection angles

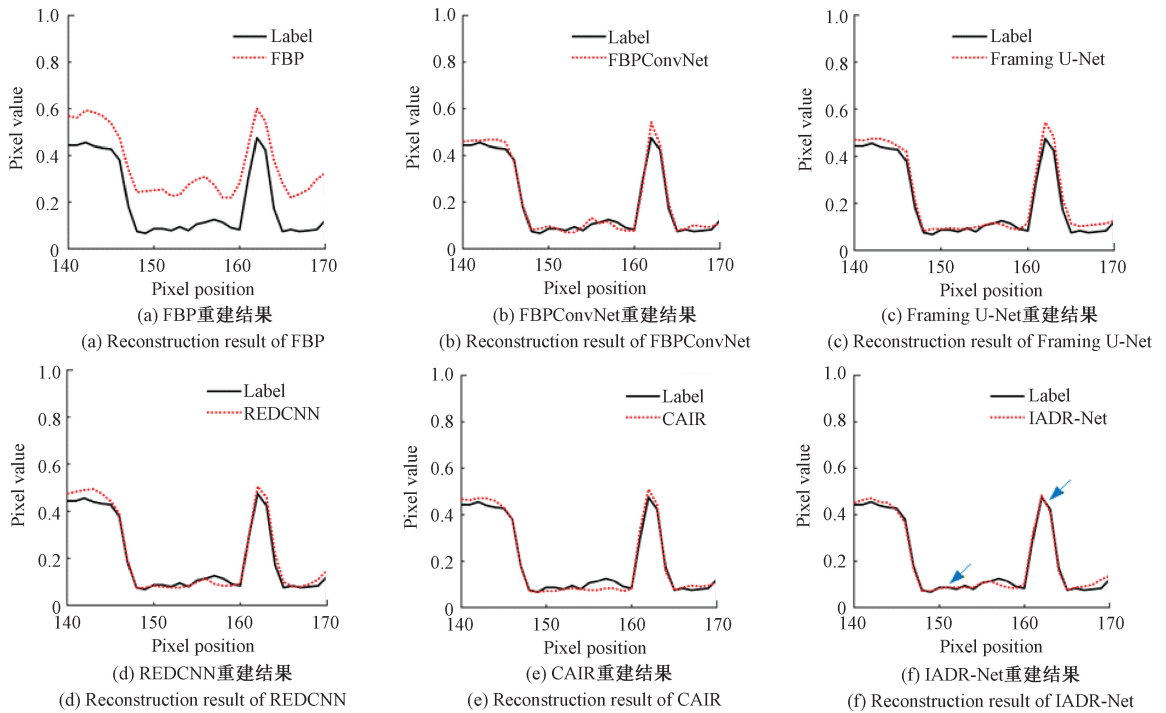


图 9 在 64 个投影角度下,不同对比算法重建结果沿图中实线标注剖面线的强度分布

Fig. 9 Under 64 projection angles, the intensity distributions of reconstruction results from different comparative algorithms along the profile line marked by a solid line in the figure

Net 在伪影抑制方面表现更为出色,但容易引发图像细节的过度平滑。REDCNN 通过残差结构增强了边缘表达能力,在一定程度上改善了结构保留,但在复杂纹理区域仍

存在一定程度的失真。CAIR 引入注意力机制,有效提升了伪影抑制效果,但在高对比度区域的细节保留方面仍存在不足。相比之下,本文提出的 IADR-Ne 在抑制伪影的

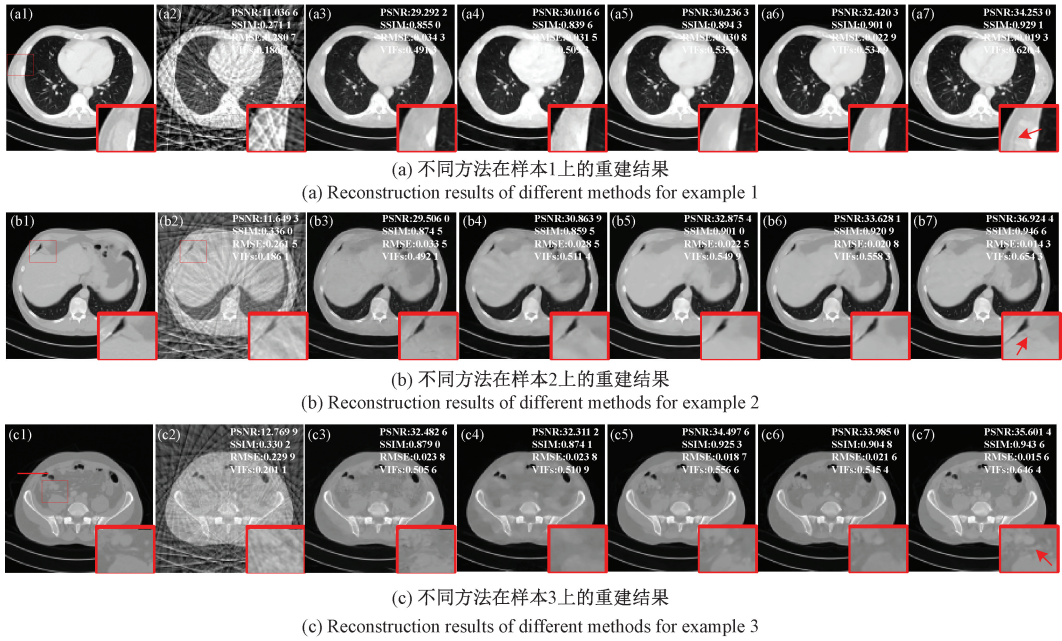


图 10 不同方法在 32 个稀疏角条件下的重建结果对比及 ROI 放大图

Fig. 10 Comparison of reconstruction results and ROI magnified views of different methods under 32 sparse projection angles

同时能够更好地保留图像细节,重建结果在结构一致性与纹理还原方面均更接近于参考图像,展现出更强的重建保真性与视觉一致性。

为进一步验证 IADR-Net 在结构信息保真方面的性

能,本文在图 11 中给出了从图 10(c)中由实线标注位置提取的水平轮廓曲线,以评估不同方法在 32 个投影角度条件下的像素级拟合效果。可以很容易地观察到,IADR-Net 与参考图像的拟合最为接近。

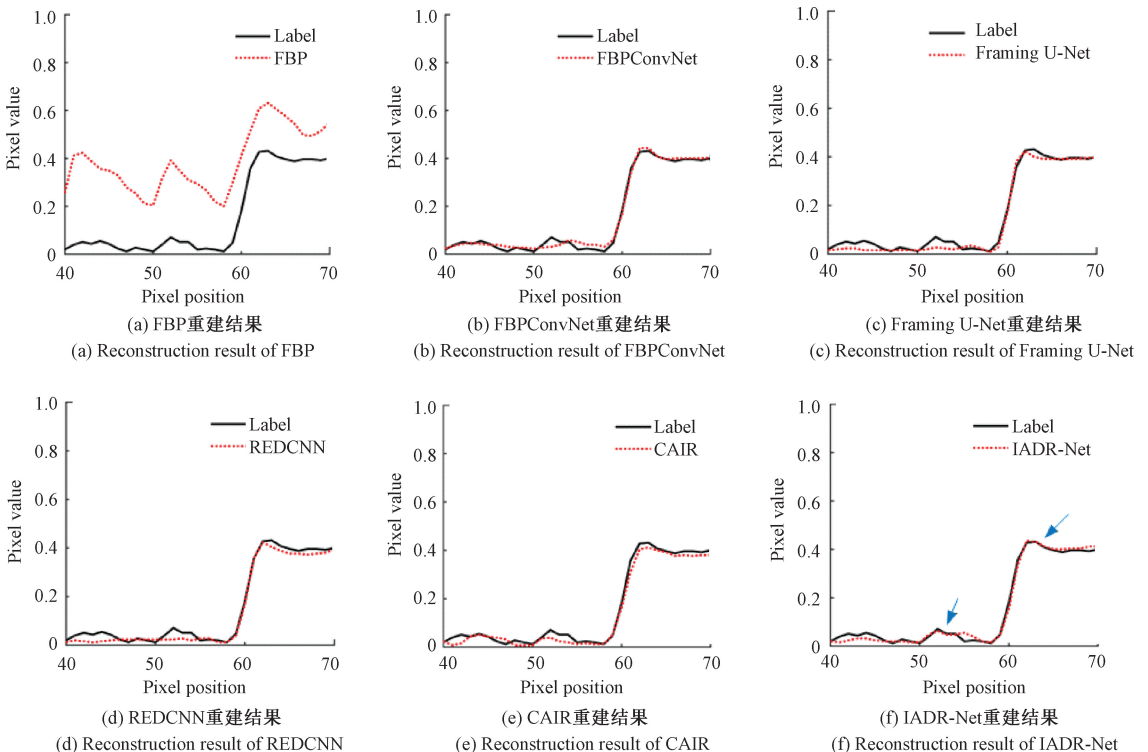


图 11 在 32 个投影角度下,不同对比算法重建结果沿图中实线标注剖面线的强度分布

Fig. 11 Under 32 projection angles, the intensity distributions of reconstruction results from different comparative algorithms along the profile line marked by a solid line in the figure

2) 定量评估

在 32、64 和 128 个投影角度条件下, 本文对比了各方法在测试集上的重建性能, 评价指标包括 RMSE、PSNR、SSIM 和 VIFs, 并绘制了 PSNR、SSIM 和 VIFs 的箱形图(图 12)以展示性能分布特征。通常而言, RMSE 越低, PSNR、SSIM 和 VIFs 越高, 表示重建图像越接近参考图

像。实验结果表明, 所提出的 IADR-Net 在所有采样条件下均取得了最佳性能, 且在 PSNR 与 SSIM 两个指标上表现出更高的中位数和更紧凑的分布。同时, 其 VIFs 指标也优于其他方法, 进一步印证了其良好的鲁棒性与稳定性, 整体重建质量优于其他方法, 并与前文的视觉对比结果保持一致。

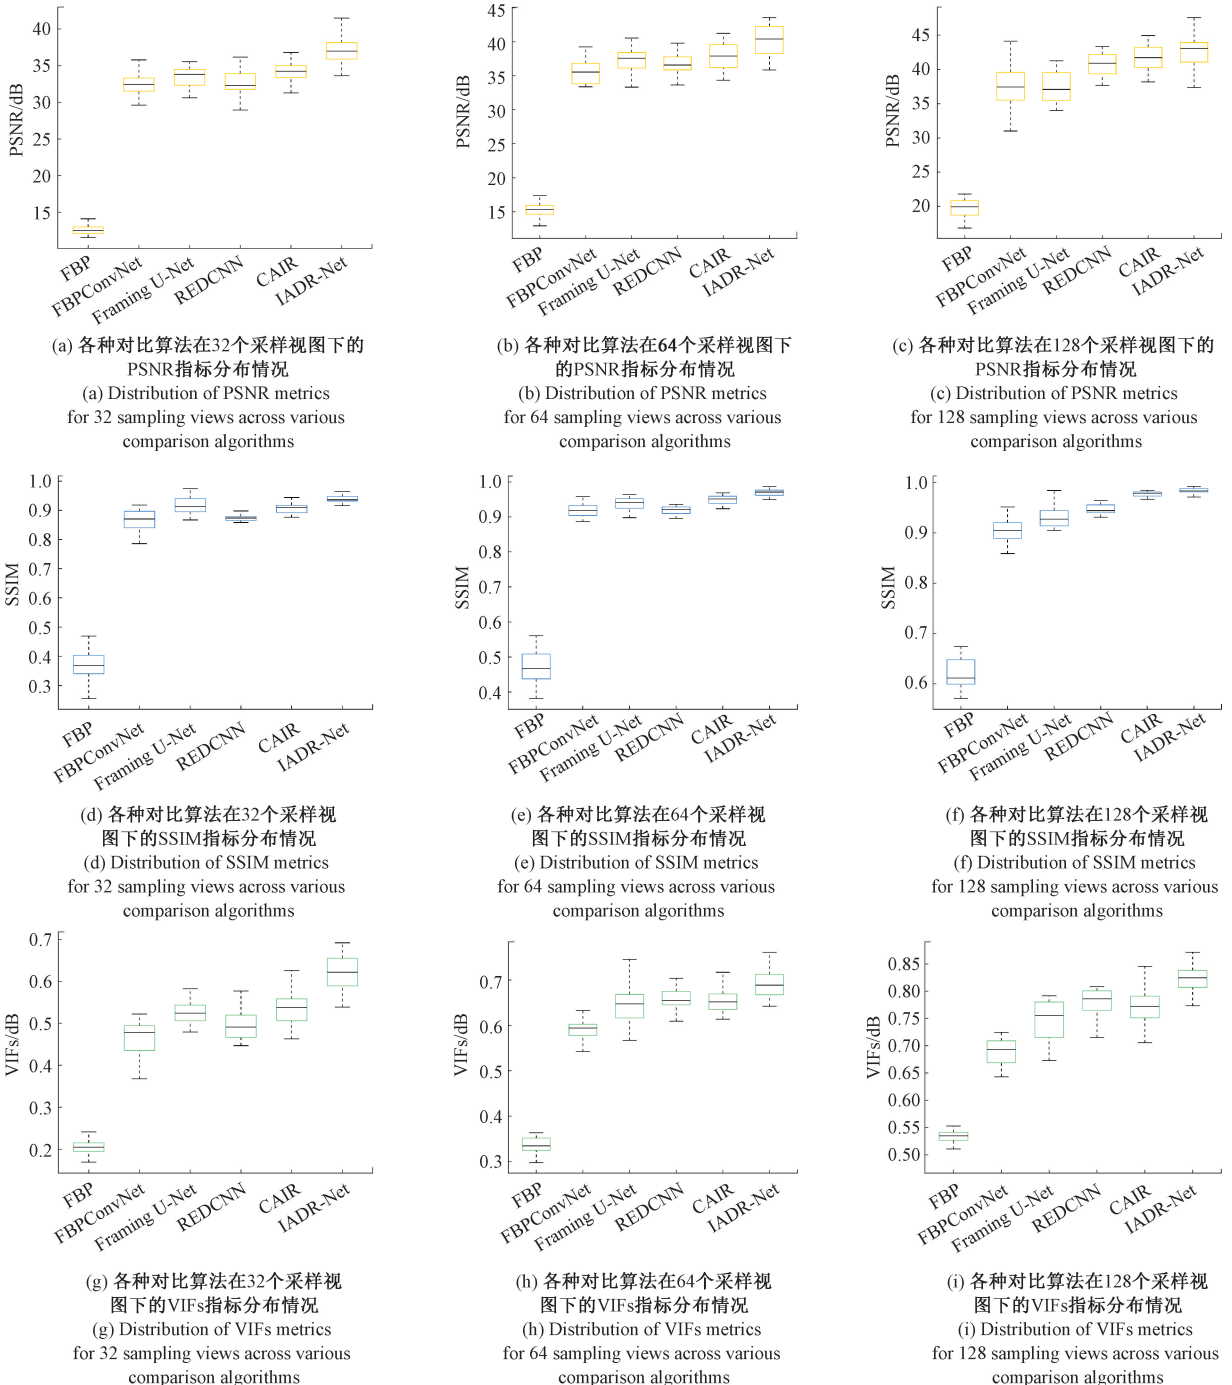


图 12 对比方法评价指标分布

Fig. 12 Distribution of evaluation metrics for comparative methods

### 3.4 消融实验

为了进一步验证本文中初始化增强模块(IEM)和注意力模块(GLONA)的有效性,本文设计了如表2~4所示的消融实验。其中,A-Net表示去除初始值增强模块后的模型,B-Net表示去除混合注意力模块后的模型。实验分别采用32、64和128个视角的投影数据作为输入,以评估模型在不同稀疏角度条件下的PSNR、SSIM和RMSE指标性能表现。从结果可见,IADR-Net在所有评价指标上均优于其他两种变体,说明初始化增强模块与注意力机制在提升重建性能方面均发挥了积极作用,二者的协同设计能够有效提升图像的整体质量与结构还原能力。

表2 32角度消融实验评价结果

Table 2 Evaluation results of the ablation study for 32 views

模型	RMSE	PSNR	SSIM
A-Net	0.015 4	36.241 1	0.931 7
B-Net	0.016 6	35.583 9	0.922 4
IADR-Net	0.014 7	37.223 0	0.944 0

表3 64角度消融实验评价结果

Table 3 Evaluation results of the ablation study for 64 views

模型	RMSE	PSNR	SSIM
A-Net	0.012 4	38.131 3	0.955 6
B-Net	0.012 8	37.891 5	0.934 0
IADR-Net	0.009 9	40.102 3	0.969 9

表4 128角度消融实验评价结果

Table 4 Evaluation results of the ablation study for 128 views

模型	RMSE	PSNR	SSIM
A-Net	0.009 0	40.903 2	0.967 0
B-Net	0.009 7	40.301 5	0.958 2
IADR-Net	0.006 5	43.803 2	0.981 9

## 4 结 论

本文提出了一种面向稀疏角CT重建任务的新型深度学习框架——IADR-Net。该网络由初始化增强模块、迭代重建子网络与细节恢复子网络组成。其中,初始化增强模块基于U-Net架构,并引入残差连接机制,以在低质量初始图像上提取更有效的先验特征,为后续重建提供更稳健的输入基础。迭代重建子网络则基于可学习的FISTA迭代结构,实现对非线性稀疏变换的端到端优化;细节恢复子网络采用全局-局部双分支架构,其中全局路径增强上下文感知能力,局部路径聚焦于细节保留,最终通过自适应

融合模块有效整合两类特征信息。

在AAPM公开数据集上的实验结果表明,IADR-Net在32、64和128个投影角度条件下的PSNR分别较当前对比算法中最好的CAIR网络提升了2.392 6、2.175 5和1.255,且在视觉效果方面实现了更显著的伪影抑制和结构细节增强,验证了其在不同稀疏条件下的广泛适应性和优越性能。

尽管本研究取得了良好效果,但IADR-Net在实际应用中仍存在一定局限。目前受限于计算资源,模型仅适用于 $256 \times 256$ 分辨率图像的重建,难以满足临床对高分辨率图像的需求。未来可通过模型优化与资源调度,结合渐进式重建策略,实现对更高分辨率图像的适配。此外,由于稀疏视图采集造成的严重信息缺失,FBP初始重建图像中存在显著伪影,影响了细节恢复子网络的重建性能。为缓解该问题,后续可探索引入结构相似的相关数据(如同一器官或病灶类型)以实现跨样本的知识迁移,从而增强模型对缺失信息的重建能力。

另一方面,虽然深度学习重建模型(DLRecon)在视觉质量上明显优于传统迭代重建方法,但其生成图像中仍可能存在潜在的信息丢失,从而对临床诊断的准确性造成影响<sup>[24]</sup>。目前常用的图像质量评价指标(ImagQMs),如SSIM和PSNR,主要衡量视觉层面的相似性,却难以全面反映放射科医师的主观感知及临床诊断需求。未来工作可考虑引入诊断导向的人工智能技术(如深度学习检测模型DLDetect),在传统视觉质量指标基础上建立面向诊断任务的综合评估体系(DiagQM),以更准确地衡量DLRecon模型的临床诊断有效性<sup>[25]</sup>。此外,将该评估体系与临床专家经验相融合,有望构建更符合医学实际需求的重建质量评价框架,为深度学习重建技术在医学影像领域的推广提供有力支撑。

## 参考文献

- [1] 董建,张海宁.基于压缩感知的稀疏扫描型CT图像快速重建算法[J].国外电子测量技术,2024,43(10):64-71.  
DONG J, ZHANG H N. Fast reconstruction algorithm of sparse scanning CT images based on compressed sensing[J]. Foreign Electronic Measurement Technology, 2024, 43(10): 64-71.
- [2] CHEN H, ZHANG Y, CHEN Y J, et al. LEARN: Learned experts' assessment-based reconstruction network for sparse-data CT[J]. IEEE Transactions on Medical Imaging, 2018, 37(6): 1333-1347.
- [3] XIA W J, LU Z X, HUANG Y Q, et al. MAGIC: Manifold and graph integrative convolutional network for low-dose CT reconstruction[J]. IEEE Transactions on Medical Imaging, 2021, 40(12): 3459-3472.
- [4] XIA W J, YANG Z Y, LU Z X, et al. RegFormer: A

- local-nonlocal regularization-based model for sparse-view CT reconstruction [J]. *IEEE Transactions on Radiation and Plasma Medical Sciences*, 2024, 8(2): 184-194.
- [5] 周先春, 吕梦楠, 芮旸, 等. 基于注意力机制的双卷积图像去噪网络[J]. *电子测量与仪器学报*, 2025, 39(2): 60-71.  
ZHOU X CH, LYU M N, RUI Y, et al. Image denoising using dual convolutional neural network with attention mechanism[J]. *Journal of Electronic Measurement and Instrumentation*, 2025, 39(2): 60-71.
- [6] ZHANG Y, CHEN H, XIA W J, et al. LEARN++: Recurrent dual-domain reconstruction network for compressed sensing CT [J]. *IEEE Transactions on Radiation and Plasma Medical Sciences*, 2023, 7(2): 132-142.
- [7] WANG J X, ZENG L, WANG CH X, et al. ADMM-based deep reconstruction for limited-angle CT [J]. *Physics in Medicine & Biology*, 2019, 64(11): 115011.
- [8] HUANG Y X, PREUHS A, MANHART M, et al. Data extrapolation from learned prior images for truncation correction in computed tomography [J]. *IEEE Transactions on Medical Imaging*, 2021, 40(11): 3042-3053.
- [9] 柴世杰, 黄魁东, 杨富强, 等. 基于多尺度生成对抗网络的锥束 CT 图像耦合伪影校正方法[J]. *仪器仪表学报*, 2024, 45(9): 44-54.  
CHAI SH J, HUANG K D, YANG F Q, et al. Cone-beam CT image coupled artifact correction method based on multi-scale generative adversarial network [J]. *Chinese Journal of Scientific Instrument*, 2024, 45(9): 44-54.
- [10] ZHANG H M, DONG B, LIU B D. JSR-Net: A deep network for joint spatial-radon domain CT reconstruction from incomplete data [C]. *IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*. Brighton: IEEE, 2019: 3657-3661.
- [11] CHUN I Y, HUANG ZH Y, LIM H, et al. Momentum-net: Fast and convergent iterative neural network for inverse problems [J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2023, 45(4): 4915-4931.
- [12] XIANG J X, DONG Y G, YANG Y J. FISTA-net: Learning a fast iterative shrinkage thresholding network for inverse problems in imaging [J]. *IEEE Transactions on Medical Imaging*, 2021, 40(5): 1329-1339.
- [13] ZHANG H M, LIU B D, YU H Y, et al. MetaInv-net: Meta inversion network for sparse view CT image reconstruction [J]. *IEEE Transactions on Medical Imaging*, 2021, 40(2): 621-634.
- [14] 李响, 艾尔肯·亥木都拉, 王路路. DBTNet: 一种用于运动想象脑电解码的融合网络 [J/OL]. *电子测量技术*, 1-12 [2025-12-15]. <https://link.cnki.net/urlid/11.2175.tn.20251128.1622.006>.  
LI X, AIERKEN H, WANG L L. DBTNet: A fusion network for decoding motor imagery EEG [J]. *Electronic Measurement Technology*, 1-12 [2025-12-15]. <https://link.cnki.net/urlid/11.2175.tn.20251128.1622.006>.
- [15] NITANDA A. Stochastic proximal gradient descent with acceleration techniques [C]. *28th International Conference on Neural Information Processing Systems*. Montreal: MIT Press, 2014: 1574-1582.
- [16] RONNEBERGER O, FISCHER P, BROX T. U-Net: Convolutional networks for biomedical image segmentation [C]. *Medical Image Computing and Computer-Assisted Intervention*. Cham: Springer International Publishing, 2015: 234-241.
- [17] MOU CH, ZHANG J, FAN X P, et al. COLA-Net: Collaborative attention network for image restoration [J]. *IEEE Transactions on Multimedia*, 2022, 24: 1366-1377.
- [18] WOO S, PARK J, LEE J Y, et al. CBAM: Convolutional block attention module [C]. *Computer Vision-ECCV 2018*. Cham: Springer, 2018: 3-19.
- [19] MCCOLLOUGH C H, BARTLEY A C, CARTER R E, et al. Low-dose CT for the detection and classification of metastatic liver lesions: Results of the 2016 low dose CT grand challenge [J]. *Medical Physics*, 2017, 44(10): 339-352.
- [20] JIN K H, MCCANN M T, FROUSTEY E, et al. Deep convolutional neural network for inverse problems in imaging [J]. *IEEE Transactions on Image Processing*, 2017, 26(9): 4509-4522.
- [21] HAN Y, YE J C. Framing U-Net via deep convolutional framelets: Application to sparse-view CT [J]. *IEEE Transactions on Medical Imaging*, 2018, 37(6): 1418-1429.
- [22] CHEN H, ZHANG Y, KALRA M K, et al. Low-dose CT with a residual encoder-decoder convolutional neural network [J]. *IEEE Transactions on Medical Imaging*, 2017, 36(12): 2524-2535.
- [23] CHENG W T, HE J CH, LIU Y, et al. CAIR: Combining integrated attention with iterative

optimization learning for sparse-view CT reconstruction[J]. Computers in Biology and Medicine, 2023, 163: 107161.

- [24] KLONTZAS M E, PONSIGLIONE A, CUOCOLO R. Evaluation of AI-assisted medical image reconstruction: More than meets the eye? [J]. European Radiology, 2024, 34(11): 7362-7363.
- [25] LOHUIZEN Q V, ROEST C, SIMONIS F F J, et al. Assessing deep learning reconstruction for faster prostate MRI: Visual vs. diagnostic performance metrics [J]. European Radiology, 2024, 34(11): 7364-7372.

## 作者简介

杨林鹏, 硕士, 主要研究方向为深度学习、图像重建、图像处理。

E-mail: 15603478691@163.com

刘祎(通信作者), 博士, 教授, 主要研究方向为医学图像处理、医学图像重建。

E-mail: liuyi@nuc.edu.cn

梁旭东, 硕士, 主要研究方向为深度学习、图像处理。

E-mail: 17831946915@163.com

桂志国, 博士, 教授, 主要研究方向为三维CT、医学图像处理与重建、模式识别。

E-mail: gzgtg@163.com