

基于深度学习的稀疏或有限角度 CT 重建方法研究综述

邸江磊^{1*}, 林俊成¹, 钟丽云¹, 钱克矛^{2**}, 秦玉文^{1***}¹广东工业大学信息工程学院先进光子技术研究院广东省信息光子技术重点实验室, 广东 广州 510006;²新加坡南洋理工大学计算机科学与工程学院, 新加坡 639798

摘要 由于计算机断层扫描(CT)成像技术对物体内部结构具有出色的可视化能力,其在临床医学诊断中获得广泛应用。但是 X 射线辐射会对人体造成伤害,通常采用降低扫描强度或者减少扫描角度数量的方式降低患者受到的 X 射线辐射剂量,然而在欠采样投影数据条件下重建的低剂量 CT 图像会有严重的条状伪影和噪声。近年来,深度学习技术快速发展,同时卷积神经网络在图像表示与特征提取等方面展现出巨大优势,应用在稀疏或者有限角度下的 CT 重建任务中可以实现快速和高质量的重建。因此面向稀疏或者有限角度条件下的 CT 重建技术,综述了深度学习技术在图像域后处理、正弦域预处理、双域数据联合处理、迭代重建算法和端到端映射重建 5 个方面的国内外最新研究进展,对当前基于深度学习的稀疏或者有限角度 CT 重建方法的技术特点及其局限性进行分析,并展望了未来可能的研究方向。

关键词 CT 重建; 深度学习; 稀疏角度; 有限角度; 神经网络

中图分类号 O439

文献标志码 A

DOI: 10.3788/LOP230488

Review of Sparse-View or Limited-Angle CT Reconstruction Based on Deep Learning

Di Jianglei^{1*}, Lin Juncheng¹, Zhong Liyun¹, Qian Kemao^{2**}, Qin Yuwen^{1***}¹Guangdong Key Laboratory of Information Photonics Technology, Institute of Advanced Photonics Technology, School of Information Engineering, Guangdong University of Technology, Guangzhou 510006, Guangdong, China;²School of Computer Science and Engineering, Nanyang Technological University, Singapore 639798

Abstract Computed tomography (CT) technology is widely used in clinical medical diagnosis thanks to the excellent visualization of the CT imaging technology for the internal cross-sectional structure of objects. Because X-ray radiation will be harmful to the human body, it is demanded to reduce the dose of X-ray radiation to patients by reducing the X-ray intensity of the scan or number of the view of the scan. However, low-dose CT images reconstructed from sub-sampling projection data will produce severe stripe artifacts and noise. In recent years, deep learning techniques have developed rapidly, and convolutional neural networks have shown great advantages in image representation and feature extraction, helping to achieve high speed and quality CT reconstruction from sparse-view or limited-angle projection data. This paper mainly focuses on the sparse-view or limited-angle CT reconstruction techniques, and reviews the latest research progresses of deep learning techniques in CT reconstruction in five directions, including image post-processing, sinogram domain pre-processing, joint processing of dual domain data, iterative reconstruction algorithms, and end-to-end mapping reconstruction. In the end, we analyze the technical characteristics, advantages, and limitations of existing sparse-view or limited-angle CT reconstruction methods based on deep learning, and discuss possible future research directions to address these challenges.

Key words CT reconstruction; deep learning; sparse-view; limited-angle; neural network

1 引言

计算机断层扫描(CT)是一种使用 X 射线、 γ 射线

等对人体进行断层扫描的成像方式,可无创伤地直接获取人体内部组织结构的三维影像信息,具有扫描快、图像分辨率高等优点,是当前临床医学诊断的重要辅

收稿日期: 2023-01-10; 修回日期: 2023-02-24; 录用日期: 2023-03-06; 网络首发日期: 2023-03-10

基金项目: 国家自然科学基金(62075183, 62175041)、广东省“珠江人才计划”引进创新创业团队(2021ZT09X044, 2019ZT08X340)

通信作者: *jiangleidi@gdut.edu.cn; **MKMQian@ntu.edu.sg; ***qinyw@gdut.edu.cn

助手段^[1-2]。使用重复或者高剂量 X 射线对患者进行扫描可以获得高质量 CT 图像,有助于医生对患者病情的准确诊断,但如果患者长时间暴露在高剂量的 X 射线辐射中可能会导致身体出现代谢异常,甚至诱发癌症等问题^[3]。因此,对患者进行 CT 检查时通常希望降低扫描系统 X 射线的辐射剂量。而在目前的 CT 临床检测中,降低系统 X 射线对人体扫描时的辐射剂量主要包括 3 种方式:降低系统 X 射线管的管电压或者管电流,从而减小 X 射线源的辐射强度,并进行低剂量 CT 重建;减少 CT 设备中成像的环绕扫描角度数量,增加 CT 扫描的角度间隔进行稀疏角度 CT 重建,如在平行射线投影重建所需的 180° 满角度条件下,每间隔 3 个角度对患者进行扫描获得 60 个角度的投影数据,称为稀疏角度投影扫描;限制 CT 设备中扫描角度的范围,在有限角度范围下进行有限角度 CT 重建,如同样在平行射线投影重建所需的 180° 满角度条件下,只在 $[0, 60^\circ]$ 范围内对患者进行扫描,获得 60 个角度的投影数据,称为有限角度投影扫描。第一种方式虽然降低了单次扫描的辐射剂量,但会导致探测器采集的投影数据有量子噪声,最终在重建 CT 图像中引入噪声,且噪声水平随射线源辐射强度降低变得越严重。后两种方式直接减少投影角度的采集数量因而可加快扫描速度,同时也显著减少了完整扫描过程的辐射剂量,因此后两种方式应用更为广泛。然而,扫描角度的缺失导致 CT 重建计算过程所需的投影角度不满足奈奎斯特采样定律,此时利用不完整投影角度数据对物体截面进行 CT 重建的过程变成了不适定的逆问题^[4],重建得到的稀疏或者有限角度 CT 图像存在视觉退化现象,在边缘和细节结构上会产生模糊现象,且随着扫描角度限制范围的增大或扫描角度数量的减少,重建的 CT 图像会有愈加严重的条状伪影并伴随更低的峰值信噪比。在这种情况下获得的 CT 重建图像清晰度较差,会影响医生对患者病情诊断的准确性。

滤波反投影 (FBP) 算法^[5]是一种典型的基于 Radon 变换的物理解析 CT 重建算法,具有空间分辨率高、重建速度快等优势。但在稀疏或者有限角度条件下,FBP 算法重建得到的 CT 图像信噪比低并存在严重的条状伪影。为解决稀疏或有限角度下的 CT 重建问题,图像域后处理^[6-8]、正弦域预处理^[9-11]和迭代重建^[12-16]等算法相继被提出。图像域后处理主要利用滤波手段抑制图像的伪影和噪声,仅能在一定程度上改善图像效果;因为稀疏或有限角度下的投影数据有限,正弦域预处理方法会在插值计算过程中引入误差,使重建的 CT 图像有一定的虚假结构信息;相比之下,迭代重建算法能够很好地减少图像的条状伪影并恢复其细节结构,但迭代过程中需多次建立前向和逆向投影,计算成本较高且重建时间较长,在实际应用中受到一定限制。

近年来,深度学习技术快速发展,由于其对图像特

征的强大提取能力、出色的非线性拟合能力等,在自动驾驶、自然语言处理、目标识别等领域取得巨大的成功,同时也在医学图像处理等领域展现出诱人的应用前景^[17]。本文对当前深度学习技术在稀疏或有限角度 CT 重建领域中的最新应用进展进行综述,主要包括基于深度学习的图像域后处理、正弦域预处理、双域数据联合处理、迭代重建和端到端映射重建方法。首先概述稀疏角度或有限角度条件下传统重建方法的局限性,然后介绍深度学习中卷积神经网络的主要应用和基本结构模型,随后讨论 5 类方法的应用及它们对比传统重建算法的优势,最后对深度学习在稀疏或者有限角度 CT 重建中的发展方向进行总结和展望。

2 CT 重建原理及挑战

2.1 CT 重建中的投影和反投影原理

在 CT 扫描设备中,探测器测量得到的 X 射线光源强度遵循 Lambert-Beer 衰减定理,即一束 X 射线穿过物体后,在物体内部会产生电子对效应、康普顿效应等,由于 X 射线能量被物体所吸收,其在穿透物体时自身的强度发生衰减。如图 1 所示,入射强度为 I_0 的 X 射线穿透物体后,最终探测器所检测到的强度 I 与物体密度、厚度及初始强度等相关,可以表示为

$$I = I_0 e^{-(\mu_0 l_0 + \mu_1 l_1 + \dots + \mu_N l_N)}, \quad (1)$$

式中: μ_i 为物质本身第 i 处的衰减系数; l_i 为射线穿透物质第 i 处时的路径长度。对于实际二维 (x, y) 平面上各点密度分布不均匀的物体,不同密度点处衰减系数 $f(x, y)$ 的线性叠加通常表示为

$$g = \int_L f(x, y) dl = \ln \frac{I_0}{I}, \quad (2)$$

式中: g 也称为投影数据。




图 1 X 射线穿透物体的衰减过程^[18]

Fig. 1 Attenuation process of X-ray penetrating an object^[18]

以图 2(a) 所示的平行 X 射线穿透物体为例,进一步结合 Radon 积分变换,式(2)可以写为

$$g(\rho, \theta) = \int_{-\infty}^{+\infty} \int_{-\infty}^{+\infty} f(x, y) \delta(x \cos \theta + y \sin \theta - \rho) dx dy, \quad (3)$$

式中: $g(\rho, \theta)$ 表示物体密度分布 $f(x, y)$ 的 Radon 变换,是平行射线的投影数据; ρ 为坐标原点到平行射线

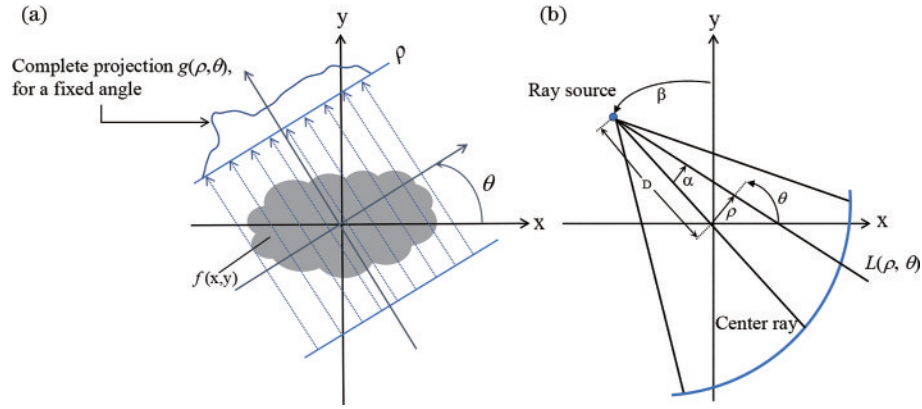


图 2 投影示意图^[19]。(a)基于 Radon 变换的平行光束投影过程;(b)扇形光束投影过程
Fig. 2 Schematic of beam projection^[19]. (a) Radon transform-based parallel beam projection process;
(b) sectoral beam projection process

的垂线长度; θ 是平行射线沿几何物体中心旋转的角度; $\delta(\cdot)$ 为冲击函数,表示投影数据是对沿着物体对应旋转角度 θ 的平行射线 $x \cos \theta + y \sin \theta = \rho$ 进行积分计算得到的^[5]。而反投影重建只需要将对应角度的原始平行射线的投影值加权复制到原图像即可,由于平行射线投影积分具有对称性,最终对所有角度的投影从 0 到 π 进行求和积分即可得到原始图像,表达式为

$$f(x, y) = \int_0^\pi g(x \cos \theta + y \sin \theta, \theta) d\theta. \quad (4)$$

而 FBP 算法则是在上述反投影方法基础上结合傅里叶中心切片定理^[20]实现的。傅里叶中心切片定理将二维物体横截面密度 $f(x, y)$ 和各个方向旋转角度的一维投影在频谱域上建立数学关系,即该物体的单个角度投影数据的傅里叶变换是二维物体傅里叶变换的一个中心切片,二维物体在旋转角度 θ 下的投影数据的傅里叶变换在数学上可表示为

$$G(\omega, \theta) = \int_{-\infty}^{\infty} g(\rho, \theta) e^{-j2\pi\omega\rho} d\rho = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} f(x, y) e^{-j2\pi\omega(x \cos \theta + y \sin \theta)} dx dy, \quad (5)$$

式中: ω 表示频谱域中的频率变化。图像的反投影则通过对其进行傅里叶逆变换得到,公式为

$$f(x, y) = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} [G(\omega, \theta) e^{j2\pi(\omega x \cos \theta + \omega y \sin \theta)}] du dv \quad u = \omega \cos \theta; v = \omega \sin \theta = \int_0^\pi \int_{-b}^b G(\omega, \theta) e^{j2\pi\omega(x \cos \theta + y \sin \theta)} |\omega| d\omega d\theta. \quad (6)$$

通过对积分值 (ω, θ) 变换坐标系后,利用雅可比行列式变换其积分形式即可得到在频谱域滤波的效果。 $|\omega|$ 可视为频谱域中的斜坡滤波函数,其中 b 为投影带宽,投影的傅里叶变换在频域间隔 $(-b, b)$ 以外

的能量为 0。对于扇形 X 射线束 CT 重建,如图 2(b) 所示,探测器排列为一个圆弧,其中 α 表示 X 射线对应的探测器相对于中心射线的偏移角度, β 表示射线源相对于 y 轴的偏移角度, $L(\rho, \theta)$ 为射线束, D 表示射线源到坐标原点之间的距离。令 $s(\rho)$ 表示 $|w|$ 的傅里叶逆变换形式,将式(6)平行 X 射线的卷积反投影形式拓展至扇形光束,可表示为

$$f(x, y) = \frac{1}{2} \int_0^{2\pi} \int_{-T}^T g(\rho, \theta) s(x \cos \theta + y \sin \theta - \rho) d\rho d\theta, \quad (7)$$

式中: $\theta = \beta + \alpha, \rho = D \sin \alpha; T$ 表示以坐标系原点为中心包围物体的圆形区域的半径。进一步将旋转角度 (α, β) 转换为极坐标 (r, φ) 积分形式,最终扇形 X 射线束投影重建过程为

$$f(r, \varphi) = \frac{1}{2} \int_0^{2\pi} \int_{-a_m}^{a_m} g(D \sin \alpha, \beta + \alpha) \times s[r \cos(\beta + \alpha - \varphi) - D \sin \alpha] D \cos \alpha d\alpha d\beta, \quad (8)$$

式中: $x \cos \theta + y \sin \theta = r \cos(\theta - \varphi); a_m$ 与 $-a_m$ 分别为式(7)的积分变量 ρ 转换为 α 后的积分上下限值 $\arcsin(T/D)$ 与 $\arcsin(-T/D)$ 。CT 重建流程如图 3 所示。

2.2 稀疏或有限角度下的传统 CT 重建算法

在稀疏或有限角度条件下,投影域中角度数据缺失导致 FBP 算法重建的 CT 图像会有严重的条状伪影并且细节结构模糊。图 4(a)~(d)分别为满剂量的 CT 图像、模拟的在平行投影模型基础上使用 FBP 算法获得的 180° 满视角条件下重建的 CT 图像、 $1/6$ 稀疏角度采样条件下重建的 CT 图像、 $[0, 120^\circ]$ 有限角度条件下重建的 CT 图像。从图像对比结果可见,相比满角度重建图像,在稀疏或者有限角度条件下重建的图像会有较大的噪声且细节结构存在大面积模糊。因此,在稀疏或有限角度条件下重建高质量 CT 图像一直是医学层析成像研究中的巨大挑战。



图 3 CT 重建流程示意图^[21]Fig. 3 Schematic of the CT reconstruction process^[21]

图 4 CT 重建图像质量退化的视觉效果。(a) 满剂量的 CT 图像；(b) 满角度 180° 条件下重建的 CT 图像；(c) 1/6 采样稀疏角度条件下重建的 CT 图像；(d) $[0, 120^\circ]$ 有限角度条件下重建的 CT 图像

Fig. 4 Visual of reconstructed CT degradation. (a) Full dose reference CT image; (b) full-view (180°) reconstructed CT image; (c) 1/6 sampling sparse-view reconstructed CT image; (d) reconstructed CT image under limited-angle of $[0, 120^\circ]$

针对稀疏或有限角度条件下的 CT 重建问题,近年来人们提出了许多不同的技术方案,主要分为图像域后处理、正弦域预处理和迭代重建 3 种方法。

图像域后处理方法使用滤波方法对稀疏或有限角度正弦图数据重建得到的 CT 图像进行滤波,以去除图像中噪声和条状伪影。典型滤波方法包括自适应方向性滤波^[6]、自适应非局部均值滤波^[7]和基于最大后验估计的统计滤波^[8]等。正弦域预处理方法在进行反投影重建之前对稀疏或有限角度下的正弦图进行插值,以修复正弦图中缺失的投影数据,通常使用线性或者方向插值方法^[9]。当正弦图扫描角度缺失越多时,利用简单线性插值方法修复缺失数据的误差也会越

大,导致重建后 CT 图像产生虚假结构信息并存在边缘模糊现象。正弦图归一化插值法^[10]与基于位移函数的正弦图插值法^[11]等改进的插值方法相继被提出,以提高插值数据的保真效果。

与上述两种方法不同,迭代重建方法通过建立多次前向投影和反向投影过程,在两个域中进行反复迭代,去除噪声和伪影,并恢复 CT 图像,直至迭代到设定的步数,或者数据保真项误差小于设定的阈值。典型代数迭代算法包括代数重建技术 (ART) 算法^[12]、同时代数重建技术 (SART) 算法^[13]等。代数迭代重建算法能够从不完整的投影角度数据中重建出较好质量的 CT 图像,克服传统解析重建算法存在的缺点,但是仍存在结构模糊和部分伪影问题。因此总差分变异 (TV)^[13]与非局部均值 (NLM)^[14]等提取图像先验信息的方法进一步被引入,提出了如 TV-POCS 算法^[15]与 ART-NLM 算法^[16]等迭代优化 CT 重建算法。改进的迭代重建算法通常对稀疏或有限角度 CT 成像系统建立物理模型,将图像的先验信息作为算法约束项构建目标方程,在正则项约束条件下不断建立前向投影与反投影过程;然后通过迭代,对比前向投影计算的模拟投影数据与真实测量的投影数据之间的误差;最后将计算得到的投影数据误差值反投影至图像域中,结合图像先验信息对 CT 图像进行更新,从而逐渐减少重建 CT 图像的伪影,提高数据保真效果。所以该算法在稀疏或有限角度 CT 重建任务中表现出色,能够较好地复原图像信息并消除条状伪影。

2.3 稀疏或有限角度 CT 重建中面临的问题

上述算法在一定程度上可抑制稀疏或者有限角度 CT 图像中的条状伪影,但仍存在以下问题。

1) 传统的 CT 图像域后处理方法利用人工设计固定的滤波卷积核或映射函数实现 CT 图像伪影去除,但是实际重建图像的条状伪影往往具有非均匀分布的特性,难以用单一滤波方式完全去除,同时简单的滤波卷积核也会导致图像产生模糊现象。

2) 传统的正弦域预处理方法利用人工设计插值方法从现有采样投影数据中估计对应邻域内缺失的投影数值,从而恢复得到满角度的正弦图。但随扫描角度数量的减少,先验信息进一步减少,会导致插值算法

得到的投影数值误差增大,从而无法在极端欠采样条件下恢复出近似真实的满角度投影数据。

3) 传统的CT迭代重建算法通过引入先验信息建立优化迭代模型,在梯度下降算法迭代更新过程中,正反投影矩阵的计算复杂度与CT图像分辨率和探测器的窗口数量成正相关,存在计算量大、复杂度高的问题,同时正则项的选择受重建系统和环境影响大,需要进行大量的人工实验选择,导致其泛化能力进一步降低。

3 深度学习技术概述

随着深度学习技术和大数据的发展,基于数据驱动的深度学习模型因强大的特征提取和非线性映射能力在计算机视觉、自然语言处理等领域取得了许多突破性的成功应用,尤其是卷积神经网络(CNN)被广泛

应用于图像分类、图像去噪、目标识别等计算机视觉领域中^[22-24]。同时在医学图像处理领域,CNN等模型也逐渐用于组织器官和病灶识别、分割等研究^[17],数据驱动型的深度学习模型解决了传统的稀疏或者有限角度CT重建方法中的问题。

3.1 卷积神经网络

1998年,LeCun等^[25]结合神经网络和基于随机梯度下降的算法,提出了LeNet-5网络,从而正式确立了现代CNN的基本结构,如图5所示,其包含卷积层、池化层、全连接层。随着GPU硬件计算能力的提升,网络的结构与深度不断得到拓展,相继出现AlexNet^[26]、VGGNet^[27]、GoogLeNet^[28]等基础分类网络,随后残差网络、密集连接网络、注意力机制等“即插即用”的CNN嵌入结构模块相继被提出,进一步加快了网络收敛速度和提高了网络性能^[29-32]。

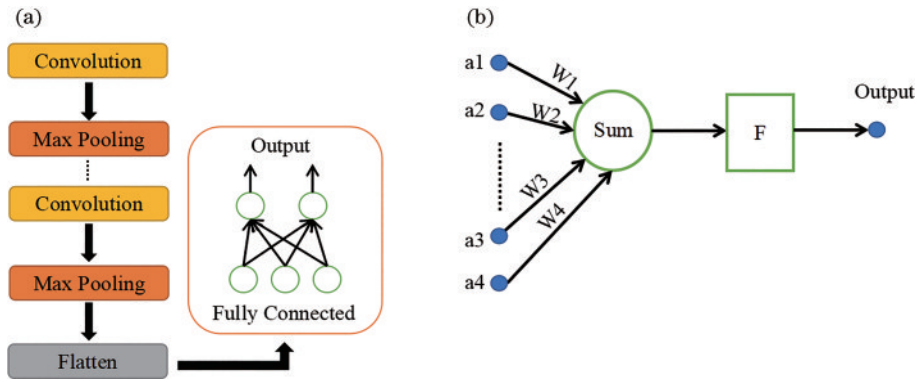


图5 CNN^[25]。(a)CNN的基本结构;(b)神经网络的神经元基本结构
Fig. 5 CNN^[25]. (a) Basic structure of CNN; (b) basic structure of neurons of a neural network

残差网络^[29]的提出解决了网络训练时深度增加导致的梯度消失与爆炸的问题,如图6(a)所示,它通过使用跳跃连接对前一层的输入特征与经过卷积后的输出特征进行相加,增强了梯度反向传播能力。密集连接网络模块^[30]如图6(b)所示,通过在通道维度上融合

不同层次的输出特征加强了特征层之间的信息传递,但层数增加会导致模型运算参数量增大。CNN中常用的注意力模块分别如图6(c)与图6(d)所示,包括通道注意力机制^[31]和空间注意力机制^[32]。注意力机制通过自适应池化层对输入特征向量的通道或者空间信息

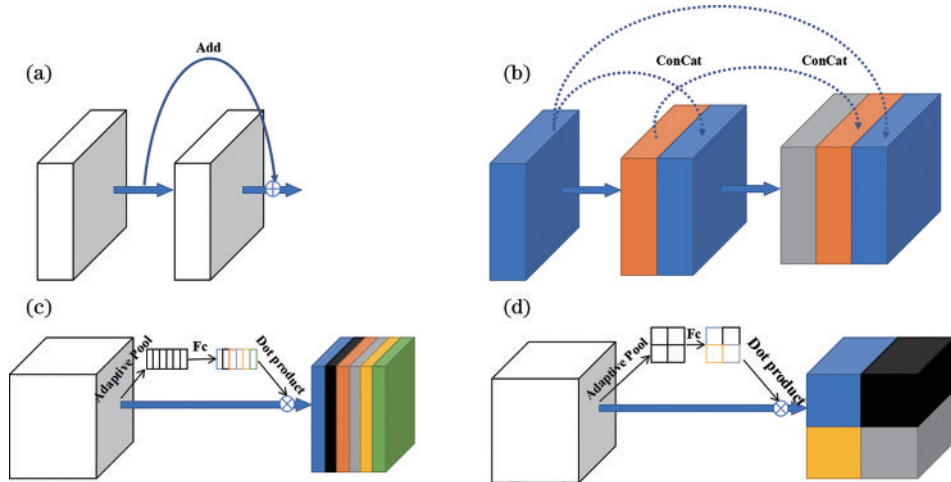


图6 CNN中的嵌入模块。(a)残差网络模块^[29];(b)密集连接模块^[30];(c)通道注意力模块^[31];(d)空间注意力模块^[32]
Fig. 6 Embedding modules in CNN. (a) Residual network module^[29]; (b) dense connection module^[30]; (c) channel attention module^[31]; (d) spatial attention module^[32]

进行降维后使用全连接层对其权重进行调整,再利用点乘运算方式将学习的权重加权回原始输入的特征向量中,使得网络可以关注更重要的特征空间或者通道信息。

3.2 神经网络主体结构

全卷积网络(FCN)^[33]是最先提出的一种用于解决端到端图像语义分割任务的网络结构,核心是运用反卷积将下采样后的特征图尺寸还原为输入像素尺寸,实现等尺寸的像素级语义分割效果,FCN的出现取代了传统的语义分割方法。受 FCN 启发, Ronneberger 等^[34]提出具有对称性的收缩下采样编码路径和扩展上采样解码路径的 U-net 模型,通过跳跃连接对编解码路径的特征进行融合,从而增强了网络对图像结构的恢复能力。

生成对抗网络(GAN)^[35]包括两个 CNN 模型主体结构,分别为生成网络 G 和判别网络 D。G 用于学习目标数据集中的分布概率,D 则对生成网络的输出和真实标签进行打分,利用对抗博弈的思想对 GAN 进行训练,最终 G 能够将一个随机噪声变量 z 转换成有规律的分布数据。GAN 也常用于医学图像修复或者医学数据增强等,以解决医学数据集中数据量不足的问题^[36]。

Visual Transformer(ViT)^[37]是基于自然语言处理(NLP)的 Transformer 框架改进而来的用于处理图像块的编解码注意力框架,是一种处理视觉任务的新型网络结构。区别于对局部像素区域进行平移卷积运算的 CNN,ViT 完全通过自注意力机制实现对输入特征的全局关联,从而建模特征之间的远距离像素关系与上下文内容长距离依赖关系,在特征提取方面展现出了巨大优势。

去噪扩散概率模型(DDPM)^[38]是无监督生成模型中的新结构。区别于 GAN 模型,DDPM 包括噪声扩散和逆扩散两个数据变化过程。首先其在扩散过程中

利用马尔可夫链条件概率扩散准则缓慢地将随机高斯噪声添加至数据中,直至趋向于先验分布,然后在逆扩散过程中利用网络学习扩散过程的噪声均值和方差,以从噪声中逐步采样,恢复原始数据的分布形式,因此其对生成图像的控制稳定性更高。

4 基于深度学习的稀疏或有限角度 CT 图像域后处理

在稀疏或有限角度条件下,由于正弦域中投影角度的采样不足甚至当扫描的角度低于奈奎斯特采样频率时,使用传统的 FBP 算法进行重建时会产生严重的条形状伪影和噪声,并且不同 CT 系统也存在噪声不一致与波束硬化等问题,使迭代重建中的先验知识往往难以获取,导致迭代重建方法不能在不同 CT 系统中同时获得稳定可靠的高质量结果,所以对于正弦域投影数据欠采样重建的 CT 图像,需要一种快速并且可靠的去伪影通用算法。由于重建 CT 图像中噪声分布具有非均匀性特点,传统图像滤波方法无法很好地去除不同系统条件下产生的条状伪影。Frikel 等^[39]证明 FBP 算法重建的有限角度 CT 图像伪影可以用网络表征,同时 CNN 在端到端图像去噪和滤波方面通用性较好,因此可利用 CNN 对 CT 图像中伪影和结构进行表征学习,以达到去除伪影的目的。通常深度学习应用于 CT 重建图像域后处理时,先使用传统 FBP 或者迭代重建方法重建得到稀疏或有限角度 CT 图像,然后再通过 CNN 等模型对图像进行优化,该方法的核心在于网络结构和损失函数设计上。基于不同网络的主体结构,图像域后处理方法分为 4 类:基于 U-net 的去伪影模型、基于 GAN 或无监督 DDPM 的去伪影模型、基于其他模块改进的 FCN 的去伪影模型、基于 Transformer 的去伪影模型。通常基于 CNN 的稀疏角度 CT 图像域后处理流程如图 7 所示。

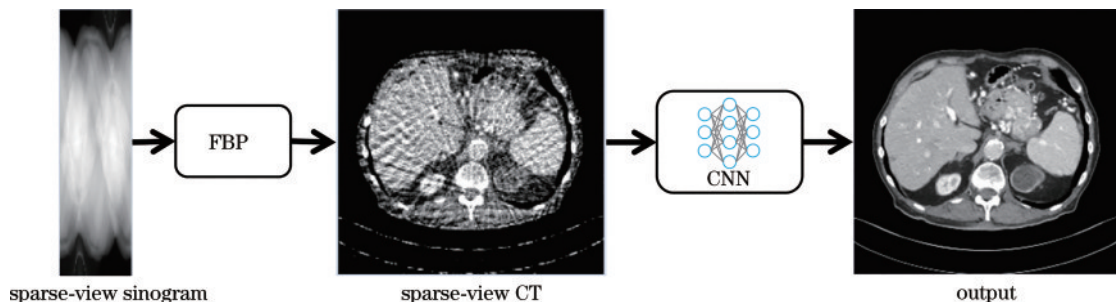


图 7 CT 图像域后处理流程

Fig. 7 CT image domain post-processing process

4.1 基于 U-net 的去伪影模型

Jin 等^[40]将 U-net 和残差学习机制结合,提出了残差 U-net,以 FBP 重建的稀疏角度 CT 图像作为网络输入,学习 CT 图像中的伪影分布,在输出端将稀疏角度 CT 图像减去得到的伪影图,从而恢复高质量 CT 图像。实验结果表明,残差学习的伪影去除效果要优于直接映射

无伪影 CT 图像的方式,但原始的 U-net 仅采用简单的卷积对原始数据提取特征,忽略了 CT 图像不同频段的伪影分布特性,导致在高频细节结构恢复上不佳。Gu 等^[41]针对上述问题,在文献[40]基础上结合小波变换进行改进,以离散小波变换后的不同频段图像作为网络输入,分别学习小波域中高低频的条状伪影的不同方向性

特征。为了进一步解决 U-net 的单路编解码器结构过于强调恢复图像低频特征的问题, Han 等^[42]结合卷积小波变换提出了一种双帧框架 U-net, 对稀疏角度 CT 图像中的伪影分布进行估计, 带小波变换的紧框架 U-net 通过一条额外的路径来处理小波分解后的子带信息, 使得网络能够更好地表征不同频率中的伪影信息。同样

地, Lee 等^[43]利用离散小波卷积取代原始 U-net 中的下采样池化层, 解决了原始池化层导致 CNN 平移不变性丢失的问题, 同时扩大了特征图感受野, 从而保留更多特征信息。其网络结构以及重建的 CT 对比结果如图 8 所示, 相比于传统算法和原始 U-net, 其在结构保真度和条状伪影去除的表现上都要更好。

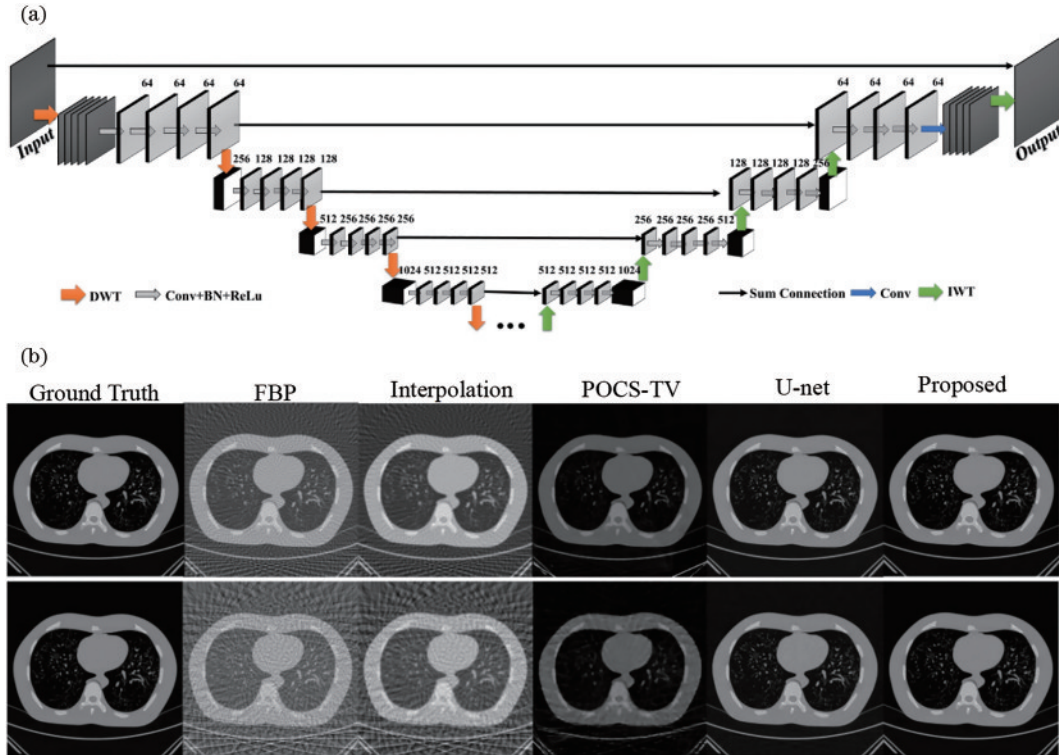


图 8 网络结构与重建结果对比^[43]。(a)多级小波变换的 U-net; (b)CT 重建结果对比

Fig. 8 Network structure and comparison of reconstruction results^[43]. (a) U-net based on multi-level wavelet transform; (b) comparison of CT reconstruction results

随着计算机硬件算力的提升, 对卷积层数堆叠更深与通道数量扩展更大的 U-net 模型进行训练变得更容易实现。Mustafa 等^[44]提出一种多通道输入输出的 U-net 模型, 该模型通过使用权重共享卷积同时处理多通道输入的稀疏角度 CT 图像, 从而快速重建多通道高质量 CT 图像。张艳娇等^[45]提出了一种多残差 U-net 模型, 该模型在每一层的基础卷积模块都引入多残差连接, 从而加深了网络深度, 提高了网络的表达能力, 提高了对伪影的抑制能力并保留了更多图像纹理和细节。同样, 也有将 SART 迭代算法或 TV 正则化迭代算法与残差 U-net 相结合对有限或者稀疏角度 CT 图像进行去伪影的方法^[46-47]。图 9 为文献[47]中的方法的重建流程, 该方法将迭代重建与深度学习相结合, 有效地抑制了伪影并保留了图像结构。相比基于 FBP 重建的 U-net 去伪影模型, 这类算法能够实现更好的重建性能, 但迭代处理增加了模型计算量, 一定程度上限制了处理速度。

4.2 基于 GAN 或无监督 DDPM 的去伪影模型

不同于仅利用数据保真项损失进行约束训练的 U-net 去伪影模型, GAN 模型则进一步在数据保真项损失基础上结合对抗训练损失以恢复更加丰富的图像细节信息, 通过最大化对数似然损失函数增加模型拟合全角度 CT 图像数据分布特性的概率, 同时能够减少数据保真损失项中均方差损失函数带来的结构模糊问题。Liao 等^[48]将 U-net 和 GAN 模型相结合, 处理稀疏角度 CT 图像, 生成网络使用的是 U-net, 而判别网络则是基于多尺度结构特征金字塔的 CNN。黄锦威等^[49]在此基础上利用多残差结构改进生成器网络, 以提高模型的表征学习能力。针对原始 GAN 中简单的对抗损失导致模型训练不稳定的问题, 杜聪聪等^[50]引入了 Patch GAN 判别器^[51], 不同于原始 GAN 判别器中的单神经元输出结构, 其为全卷积网络结构, 最终判别器输出数据为图像特征 Patch 块, 保留了更多图像特征信息以提高鉴别器性能, 同时进一步改用了平均绝对误差作为对抗损失, 也提高了鉴别器训练的稳定性。同样, Hegazy 等^[52]提出一种基于 WGAN 和 U-net

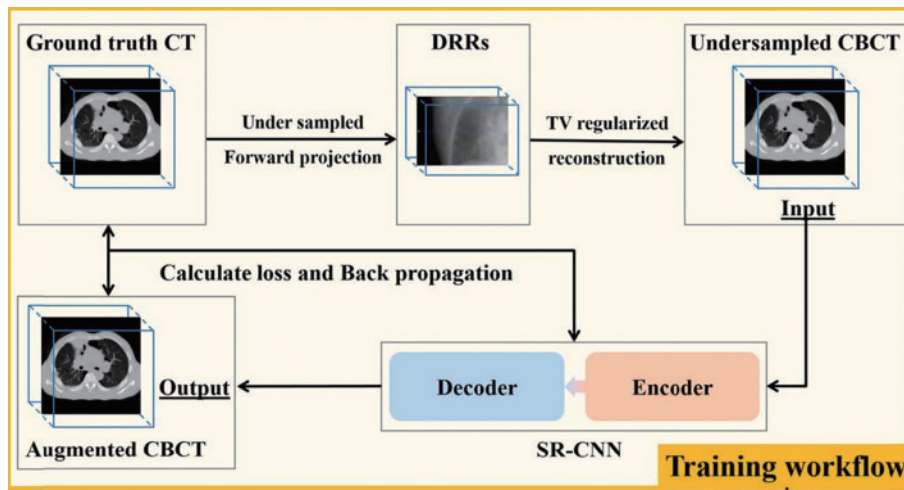


图 9 结合 TV 正则化迭代与 U-net 的去伪影模型^[47]

Fig. 9 Artifact removal model combining TV regularization iteration reconstruction with U-net^[47]

的改进网络,引入 WGAN 中的 Wasserstein 距离代替原始鉴别器中的交叉熵损失,以度量真假 CT 图像数据之间分布距离的方式约束生成器的输出,利用 Wasserstein 距离平滑特性有效解决了原始 GAN 中训练过程梯度消失与训练不稳定的问题。Xie 等^[53]则进一步引入密集连接模块,构建了深度编解码对抗重建网络(DEAR-3D),如图 10(a)所示,在生成器中引入稠

密连接模型后,网络能够融合不同层次感受野的结构特征信息,增强了模型消除稀疏角度 CT 图像伪影的能力。相比基于单一均方差训练损失的有监督的残差 U-net 的去伪影网络,加入对抗训练损失的网络可在一定程度上减少均方差损失带来的模糊现象,恢复的 CT 图像在视觉感官上表现得更好,其重建对比结果如图 11(a)所示。

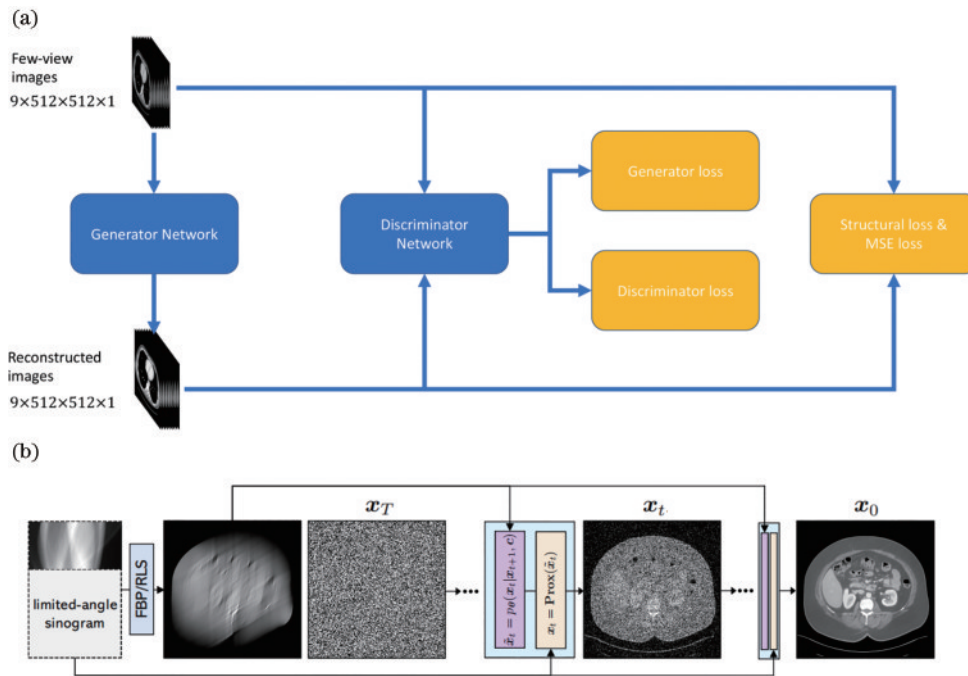


图 10 基于 GAN 或 DDPM 的去伪影模型。(a)U-WGAN 模型^[53]; (b)DDPM^[55]

Fig. 10 Artifact removal models based on GAN or DDPM. (a) U-WGAN model^[53]; (b) DDPM^[55]

此外,DDPM 是生成模型领域中的无监督方向新应用。DDPM 生成模型是基于马尔可夫链概率扩散的图像去噪过程实现的,无须同时对两个网络进行对抗训练,相比 GAN,对生成图像过程具有更强的指导性,对数据样本的概率分布具有更强的学习能力,已成

功应用在图像翻译、生成及修复等领域,同时在图像生成任务中展现了比 GAN 更加优越的性能^[54]。最近,针对有限角度 CT 重建任务,Liu 等^[55]利用如图 10(b)所示的改进 DDPM 构建去伪影模型,将有限角度伪影 CT 图像作为概率逆扩散过程的网络输入条件,从而

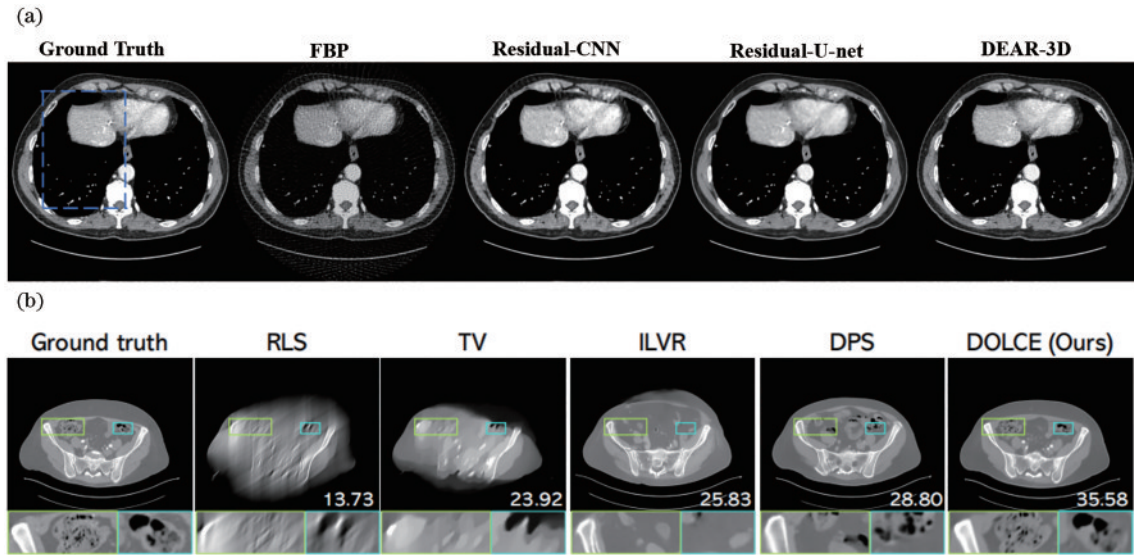


图 11 基于 GAN 或 DDPM 的去伪影模型重建结果。(a) 文献 [53] 的 CT 重建结果; (b) 文献 [55] 的 CT 重建结果

Fig. 11 Reconstruction results of the artifact removal models based on GAN or DDPM. (a) CT reconstruction results in Ref. [53]; (b) CT reconstruction results in Ref. [55]

使得 DDPM 能够稳定生成目标无伪影 CT 图像。相比 GAN 在 CT 重建中的应用, DDPM 不需要通过增加有监督的数据保真项损失指导网络对图像的生成过程, 在无监督训练方式下仍然能够从极端有限角度中重建出高质量 CT 图像, 其稀疏角度重建结果如图 11(b) 所示。Song 等 [56] 将 CT 成像模型嵌入到最新的分数生成扩散模型中, 实现了从稀疏角度伪影 CT 图像中采样生成高质量 CT 图像的目标, 且该模型可扩展至核磁共振成像过程。DDPM 优势在于能够比 GAN 生成更加逼真的图像并且不需要标签图像数据指导网络的生成过程。然而, 现在基于 DDPM 的逆扩散 CT 重建过程仍然存在采样次数多导致运行速度慢、最大似然差和数据泛化能力弱等问题, 需要进一步优化。

4.3 基于其他模块改进的 FCN 去伪影模型

除上述模型外, 基于密集连接模块、注意力机制模块等结构改进的 FCN 也应用于 CT 图像域后处理中, 以提高 CT 重建精度和速度。Zhang 等 [57] 提出了一种基于密集连接模块与反卷积的浅层网络 DDNet, 同时引入图像结构相似性作为模型训练损失的正则项, 在保证重建精度的前提下提高模型重建速度。Xie 等 [58] 提出一种基于 GoogLeNet 的网络模型, 堆叠了多个 GoogLeNet 与残差结构, 学习伪影特征的分布特性。Shen 等 [59] 提出一种递归网络 R2-Net, 网络模型如图 12(a) 所示, 该网络具有特征映射的编码器网络、特征空间中的递归变换网络和伪影估计解码器网络, 通过结合循环机制和通道注意力更好地表征了条状伪影的重复性特征。Zhou 等 [60] 提出一种多尺度的扩张卷积神经网络 (MSD-CNN), 该网络利用多尺度空洞卷积增大特征图的感受野, 并通过多尺度池化层保留更多特征信息。Shen 等 [61] 提出了一种伪影消除网络

ARCliqueNet, 其通过 Clique Block [62] 从稀疏角度 CT 图像中提取一组特征图, 然后将特征映射输入到多尺度空洞卷积块并进行细化, 通过不断循环两个模块以进一步提高重建质量。Qian 等 [63] 提出一种基于残差网络的去伪影模型, 通过改进残差块减少模型计算量。Fu 等 [64] 提出了一个多层残差密集连接网络 (MS-RDN), 网络结构如图 12(b) 所示, 通过对稀疏角度 CT 图像进行区域强制学习, 融合高分辨率特征与低分辨率特征增强图像恢复效果。Xie 等 [65] 提出一种特征融合残差网络 (FFRN), 该网络在浅层引入残差密集块 (RSDB), 通过跳跃连接实现局部特征融合, 提升模型的特征提取能力。Zhang 等 [66] 利用去噪自编码先验的鲁棒性增强机制提出 REDAEP 去伪影模型, 将网络分为增强学习和鲁棒重建阶段, 细化重建网络的结构以进一步增强 CT 恢复性能。针对锥束稀疏角度 CT 重建问题, Jiang 等 [67] 提出一种合并编码器卷积神经网络 (MeCNN), 该网络从学习到的先验图像和欠采样图像中提取图像特征, 并利用深度卷积在多尺度层次上采样合并特征, 最后输出高质量锥束 CT 图像。

4.4 基于 Transformer 的去伪影模型

Transformer 框架利用多头自注意力机制对特征的长距离关系进行建模, 从而捕获全局先验知识, 在目标检测、图像分割等领域都展现出了比 CNN 更强大的特征提取优势 [68]。针对有限角度双能锥束 CT 重建问题, Zhang 等 [69] 结合 CNN 和 Transformer 编码器分别从双能 CT 图像和双能 CT 融合后的先验图像提取特征, 利用特征融合模块捕获图像的局部和全局先验知识, 重建图像局部细节结构信息, 表征全局伪影信息, 进而通过差分 CNN 解码器恢复高质量双能 CT 图像, 模型结构如图 13 所示。虽然 Transformer

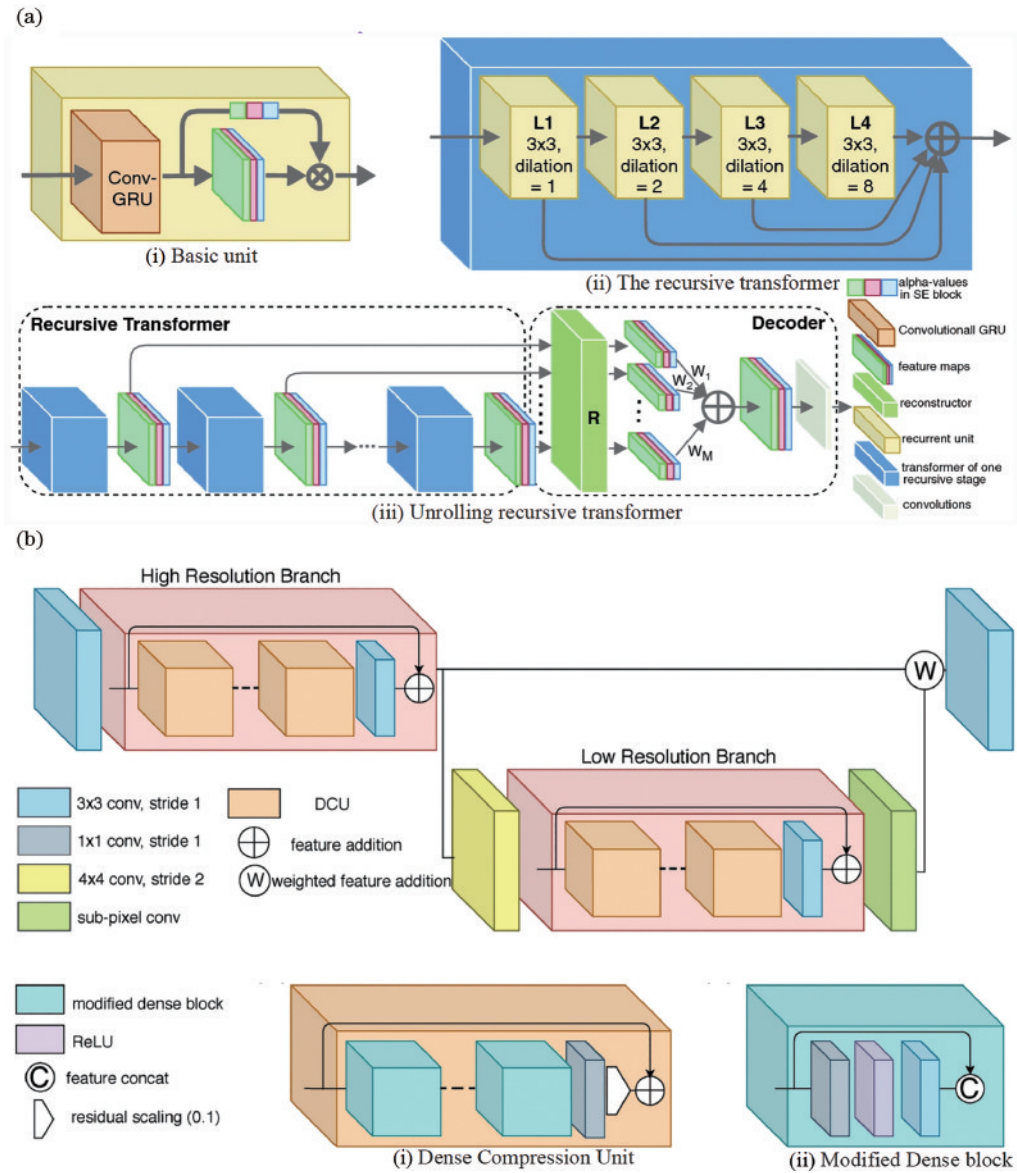


图 12 基于不同网络结构设计的 FCN 去伪影模型。(a)R2-Net 模型^[59]; (b)MS-RDN 模型^[64]

Fig. 12 FCN artifact removal models based on different network structures. (a) R2-Net model^[59]; (b) MS-RDN model^[64]

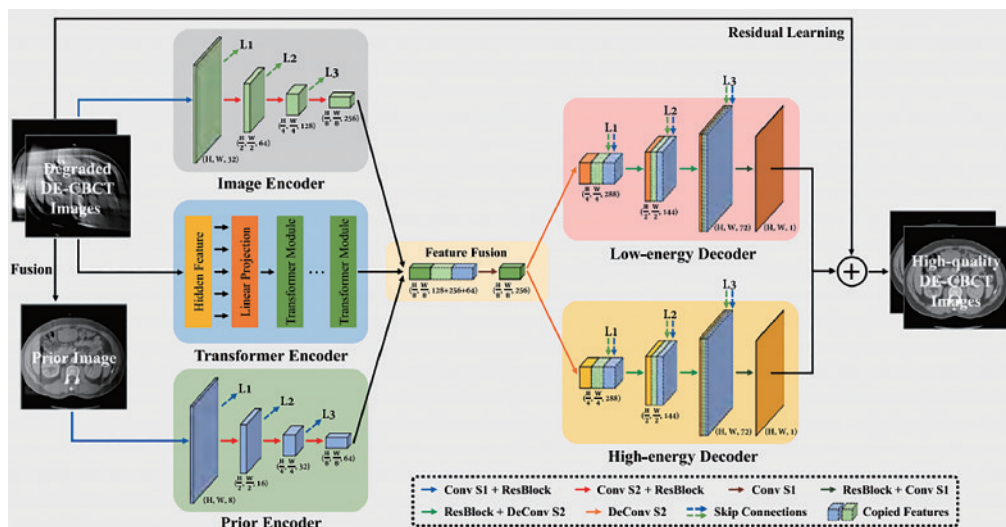


图 13 基于 Transformer 的去伪影模型^[69]

Fig. 13 Artifact removal model based on Transformer^[69]

提高了 CT 图像恢复能力,但在图像处理过程中的全局矩阵自注意力的计算增加了模型本身的计算量与时间成本。

4.5 图像域后处理方法总结

基于 CNN 的 CT 图像域后处理方法不仅在实验设计方面比传统人工设计的 CT 图像滤波算法要简单,并且神经网络能够通过数据驱动的方式学习图像中伪影的分布规律,在去除伪影效果与保留结构方面表现更佳,同时具备更强大的泛化能力。基于简单 U-net 模型的图像域后处理方法能够有效去除缺失角度较少的 CT 图像中的伪影信息,但由于其结构与损失函数设计比较简单,恢复的 CT 图像容易有结构模糊现象。为更好地处理角度缺失较多的 CT 图像,可进一步融合小波域分解方法以有效去除条状伪影。基于 GAN 的图像域后处理方法则通过对抗损失训练生成器,从而恢复生成更多缺失的结构信息,提高图像细节的多样性与丰富性,对于 GAN 模型,需要进一步改进鉴别器结构或者损失函数才能更好地控制数据生成的准确性。与 GAN 相比,DDPM 生成模型完全不需要

标签数据指导其对图像的生成过程,在缺失角度较多时也能恢复较完整的 CT 结构,但存在迭代采样恢复过程,重建一张图像比 GAN 要消耗更多时间。而基于不同结构模块改进的 FCN 是利用 CT 图像数据不同伪影特性对网络结构进行设计得到的,在一定程度上能够增强模型对数据的表征能力,提高图像数据恢复的保真度和速度。基于 Transformer 的去伪影模型通过引入 NLP 自注意力机制对全局特征依赖关系建模,相比 CNN,能够更好地表征全局伪影特征分布特性,但其多头自注意力机制也给模型带来更大的参数量和计算量。

基于深度学习的图像域后处理方式仅约束 CT 图像数据保真度,缺少对采集投影数据保真度的约束,存在一定程度的虚假结构生成问题。同时,由于神经网络的构建缺乏理论性指导,如何引入投影数据保真度的约束以及从物理角度上针对图像数据特征设计网络的结构、深度与损失函数是深度学习技术应用于 CT 图像域后处理的难点。表 1~3 对基于 U-net、GAN、DDPM、其他模块改进的 FCN 的 CT 去伪影模型的相

表 1 基于 U-net 的去伪影模型总结

Table 1 Summary of artifact removal model based on U-net

Reference	Network detail	Loss function	Dataset	Feature
[40]	Residual learning, skip connection	MSE	Biomedical, Ellipsoidal, Human Knee	
[41-42]	Residual learning, skip connection, wavelet transform	MSE	AAPM Low Dose CT	Advantages: artifact removal in different frequency bands and simple implementation
[43]	Residual learning, skip connection, wavelet transform		Chest and Catphan phantom	
[44]	Skip connection	MAE	3D Spectral Slices	Limitations: the network structure and loss function are single
[45-46]	Residual learning, skip connection		TCIA	
[47]	Residual learning, skip connection	SSIM loss	AAPM Low Dose CT	

表 2 基于 GAN 或 DDPM 的去伪影模型总结

Table 2 Summary of artifact removal model based on GAN or DDPM

Reference	Network detail	Loss function	Dataset	Feature
[48]	Residual learning	GAN loss, perceptual loss	Human Knee	Advantages: the resulting CT images are rich in detail and DDPM is more controllable; DDPM models do not require labels
[49]	Skip connection	GAN loss, MSE	TCGA-CESC	
[50]	Residual learning, skip connection	MAE, MSE	TCIA	
[52]	Skip connection	Wasserstein loss, MSE	Dental CT	
[53]	Dense block, skip connection	Wasserstein loss, MSE, SSIM loss	AAPM Low Dose CT	Limitations: GANs are difficult to train and have poor convergence; the sampling speed of DDPM is slow
[54]	DDPM	MSE, KL divergence	Checked-in Luggage, C4KC-KiTS	
[55]	DDPM	MSE, KL divergence	LIDC, LDCT	

表 3 基于其他 FCN 的去伪影模型总结

Table 3 Summary of artifact removal model based on other FCN

Reference	Network detail	Loss function	Dataset	Feature
[57]	Dense block, skip connection	MSE, MS-SSIM loss	NBIA	
[58]	Residual learning, GoogLeNet	MSE	Clinical Routine CT	
[59]	Residual learning, channel attention, recursive transformer	MSE	AAPM Low Dose CT	
[60]	Multi-scale dilated convolution, multi-scale pooling		LiTS	Advantages: design different network structures according to task requirements and data characteristics and the reconstruction algorithm is fast
[61]	Multi-scale dilated convolution, Clique Block ^[62]	MSE	AAPM Low Dose CT	
[63]	Residual learning	MAE	LIDC-IDRI	
[64]	Dense block, residual learning	MAE	Breast CT	Limitations: the loss function is single
[65]	Dense block, residual learning	MAE	Head CT	
[66]	Residual learning, skip connection	MSE	AAPM Low Dose CT	
[67]	Skip connection	MSE	4D-Lung, DIR-LAB	

关文献中所使用的网络细节结构、损失函数、数据集及算法优点和局限性进行了总结。

5 基于深度学习的稀疏或有限角度 CT 正弦域预处理

对于稀疏或者有限角度 CT 重建,所面临的最直观问题是在正弦域中缺少部分连续投影数据。虽然双线性插值或者改进的插值技术能够在一定程度上补充缺失数据,但当正弦域缺失的数据超过满角度投影数据的一半或者更多时,传统插值方法将无法获得较好的恢复效果,同时物理解析重建算法对其重建后并不能恢复出完整的 CT 图像结构,因此研究者们借助

CNN 的强大映射能力来修复缺失数据。深度学习应用于正弦域投影数据预处理的主要思路为:直接使用 CNN 对稀疏或者有限角度正弦图进行插值,再使用传统重建方法对 CNN 恢复的正弦图进行 CT 重建;或者先使用传统插值方法对稀疏或者有限角度正弦图进行插值,随后使用 CNN 对插值后的满角度正弦图进行优化,减小插值产生的误差并恢复出更准确的数据信息,最后使用传统重建方法对 CNN 恢复的正弦图进行 CT 重建。根据主体网络结构的不同,插值方法可分为两种:基于 U-net 与 FCN 的正弦图插值方法;基于 GAN 的正弦图插值方法。基于 CNN 的稀疏角度正弦域数据预处理流程如图 14 所示。




图 14 正弦域预处理流程

Fig. 14 Sinogram domain preprocessing process

5.1 基于 U-net 与 FCN 的正弦图插值模型

Lee 等^[70]首先提出了一个仅含 20 个卷积层的正弦图插值模型,该模型直接通过网络对稀疏角度正弦图缺失的数据进行插值,实验结果表明基于 CNN 的弦图插值效果优于线性插值方法,但该模型缺少深层特征提取过程,不能表征正弦图的多层次分布特性。针对此问题, Lee 等^[71]利用残差 U-net 模型对缺少的数据进

行插值,同时以卷积层替换池化层,提高模型对特征信息的保留与表征能力。Cao 等^[72]则结合传统线性插值算法与 CNN 对稀疏角度弦图进行插值,其网络框架如图 15(a) 所示,通过 U-net 修正线性插值引入的误差。为了提高模型对正弦图特征的表达,温静等^[73]在原始 U-net 基础上融合了递减感受野特征信息的密集连接模块,将最近邻插值和双三次插值方法相

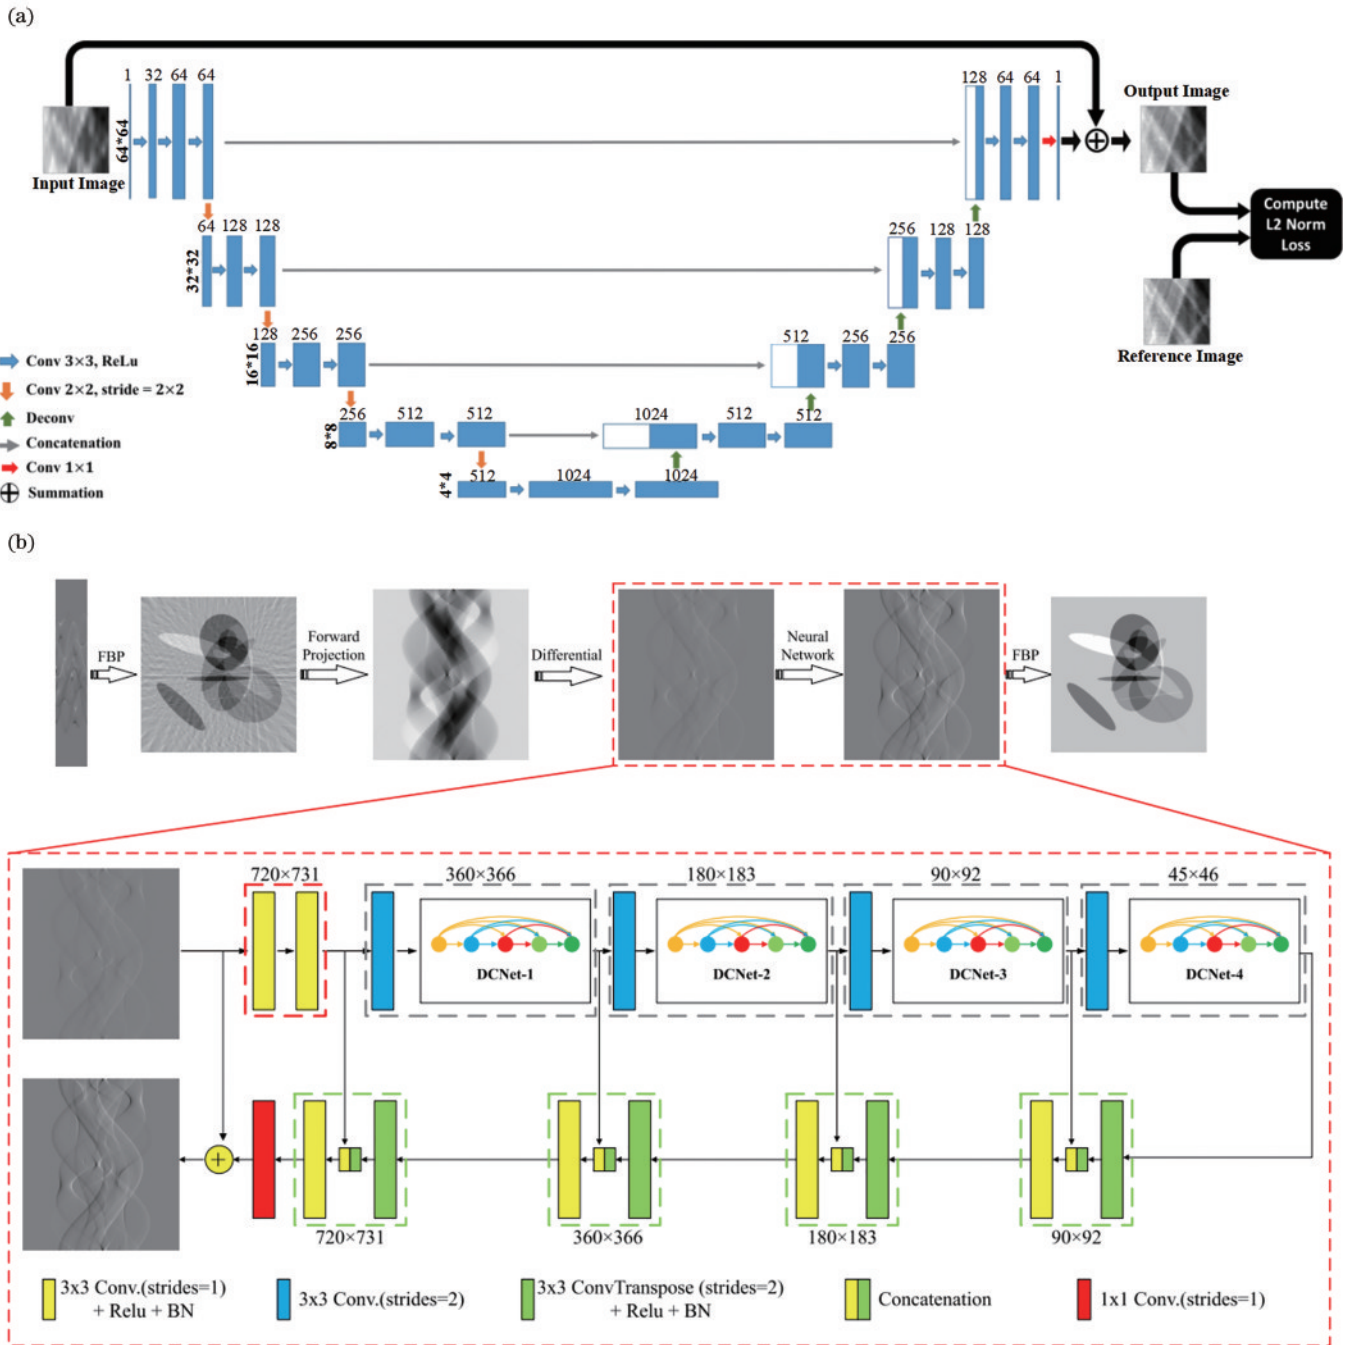


图 15 基于 U-net 的正弦图插值模型。(a) 结合线性插值与 U-net 的模型^[72]; (b) DPC-CT 模型^[75]

Fig. 15 Sinogram interpolation models based on U-net. (a) Model combining linear interpolation with U-net^[72]; (b) DPC-CT model^[75]

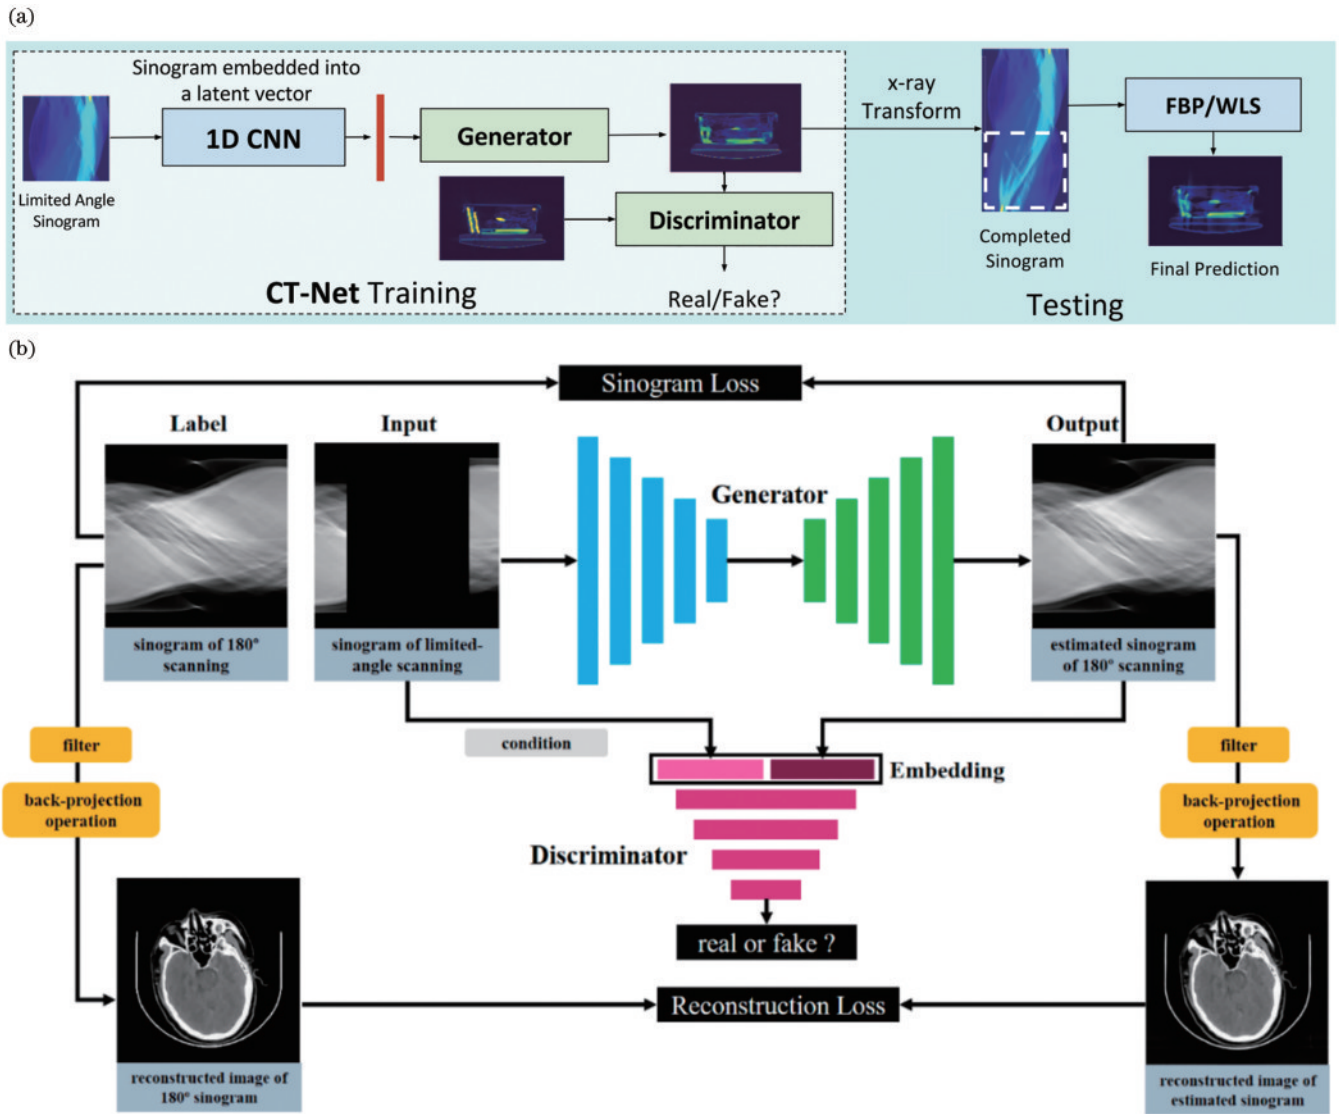
结合,对稀疏角度弦图进行数据预插值,该网络模型利用多尺度卷积结构改进基础卷积模块,并运用三通道并行卷积的方式减少网络计算参数量。

不同于上述弦图插值模型框架,Dong等^[74]将FBP算法嵌入到弦图恢复网络模型中,提出了一种基于U-net和FBP解析重建耦合的稀疏角度弦图修复框架,利用FBP算法对稀疏正弦图进行初始重建后利用前向投影模型模拟全角度的投影数据,进而应用U-net模型对其进行修正,但由于原始U-net基础卷积结构块比较简单,该模型不能较好表征正弦图特征。在此基础上,Fu等^[75]对上述框架进行改进,采用密集连接

模块进一步改进U-net,以融合不同感受野的多尺度特征并对正弦图数据进行修复,提出的DPC-CT插值重建框架如图15(b)所示。

5.2 基于GAN的正弦图插值模型

由于GAN模型中生成器能够学习目标数据中的概率分布的特性并最终能够从噪声中生成所需图像数据,因此可以利用GAN模型修复投影数据中缺失的角度数据信息。例如,Anirudh等^[76]提出了一种由一维和二维CNN组成的CT-Net,如图16(a)所示,首先利用一维CNN对有限角度正弦图嵌入潜在向量,再使用二维卷积模块构建的GAN对正弦图嵌入的向量误差

图 16 基于 GAN 的正弦图插值模型。(a)CT-Net 模型^[76];(b)SI-GAN 模型^[80]Fig. 16 Sinogram interpolation models based on GAN. (a) CT-Net model^[76]; (b) SI-GAN model^[80]

进行修复,最后通过 Radon 变换将修复结果投影至满角度弦图空间,该方法可将构建的模型扩展到不同角度数量缺失的正弦图修复任务中。CT-Net 重建结果如图 17(a)所示,即使在 FBP 无法恢复 CT 图像结构的极端有限角度情况下,GAN 仍然可以生成缺失的投影数据,从而重建出大部分物体结构信息。针对单一均方差损失重建高频细节时存在缺陷和图像模糊的问题,Bai 等^[77]提出了一种基于联合损失函数的对抗式自编码器,将联合对抗损失作为对重建损失的补偿以改善正弦图修复的效果。在文献^[77]框架基础上,Dai 等^[78]针对锥束 CT 重建问题,将三维锥束 CT 投影切割为多个二维片段,利用上述模型修复缺失的正弦图数据,最终在输出端堆叠修复的二维切片以获得满角度的三维锥束 CT 投影。


此外,Li 等^[79]结合 U-net 与 GAN 模型,提出一种有限角度弦图修复方法,采用 U-net 作为生成器学习弦图数据分布,以实现弦图数据的修复,减少了投

影数据缺失造成的 CT 图像模糊的现象,但原始 GAN 模型缺乏确定的指导信息,存在过度生成虚假结构的问题。而 Li 等^[80]基于条件生成对抗网络(CGAN)^[81],提出了如图 16(b)所示的 SI-GAN 模型。CGAN 中判别器的输入数据增加了标签条件指导信息,从而改善了图像数据生成不确定性高的问题,使得修复的正弦图中投影数据更加接近原始标签像素值;同时联合正弦域平均绝对误差损失和图像域重建均方根误差损失以增加重建 CT 图像的保真度,利用双域数据保真度更精准地修复弦图数据,重建结果如图 17(b)所示。SI-GAN 同样能在极度有限角度情况下重建出更加精确的 CT 结构,同时相比原始 GAN,其重建图像的模糊度要更低。Liu 等^[82]将文献^[79]中的模型进一步应用在改进的 FORBILD 腹部幻影数据集中,实验表明该模型在不同稀疏角度条件下训练都能够得到较好的 CT 图像恢复结果,表现出较强的泛化能力。Ghani 等^[83]基于上述模型,进一

步修改判别器中的 Patch GAN, 通过将端到端同尺度的特征图输出方式取代 Patch GAN 中的图像 Patch 块输出方式, 该网络的输出特征图能够更好地表征

完整角度正弦图中的非局部结构特性, 增强鉴别器对图像区域细节特征的判别能力, 最终提高生成器的性能。

(a)



(b)




图 17 基于 GAN 的正弦图插值模型重建结果。(a)文献[76]的 CT 重建结果;(b)文献[80]的 CT 重建结果

Fig. 17 Reconstruction results of the sinogram interpolation models based on GAN. (a) CT reconstruction results in Ref. [76];

(b) CT reconstruction results in Ref. [80]

5.3 正弦域预处理方法总结

与传统人工设计的正弦域投影数据插值方法相比, CNN 提供了一种更快速、可靠的稀疏或有限角度正弦图修复方法, 结构设计更为简单, 通过构建简单的 FCN 即可获得不错的插值结果, 有效去除后续重建时产生的伪影, 并在一定程度上抑制插值误差引入的错误。该方法整体思路与基于深度学习的图像域后处理方法类似, 都为单域处理方法。绝大多数正弦图插值模型仅有投影数据的保真损失项, 缺少对图像域数据保真效果的关注, 所以当 CT 投影域缺失角度数据过多时, 仅仅依赖简单的 FCN、U-net 模型与

投影数据均方差保真项就会在数据修复过程中引入部分误差数据, 而基于 GAN 的正弦图插值模型可以充分利用生成器从噪声中生成新数据, 以修复扫描角度数量更少的正弦图。但当缺失数据过多时, GAN 模型中生成数据不稳定的问题逐渐加重, 因此在基础卷积模块融入插值技术对其进行指导修复, 或者改进 GAN 模型的鉴别器结构与对抗损失函数提高模型的稳定性尤为重要, 可进一步提高 GAN 生成数据的保真度。表 4 与表 5 对基于 U-net 与 FCN、GAN 的正弦图插值模型的相关文献中所使用的网络细节结构、损失函数、数据集及算法的优点和局限性进行了总结。

表 4 基于 U-net 与 FCN 的正弦图插值模型总结

Table 4 Summary of sinogram interpolation model based on U-net and FCN

Reference	Network detail	Loss function	Dataset	Feature
[70]	Residual learning		XCAT	Advantages: the network structure design is simple and the network operation efficiency is high
[71]	Residual learning, skip connection	MSE	Lung CT	
[72]	Residual learning, skip connection	MSE	micro-CT	
[73]	Residual learning, skip connection			Limitations: the loss function is single
[74]	Skip connection	MSE	Phantoms	
[75]	Skip connection, dense block, residual learning	MSE, MS-SSIM loss	Phantoms	

表 5 基于 GAN 的正弦图插值模型总结

Table 5 Summary of sinogram interpolation model based on GAN

Reference	Network detail	Loss function	Dataset	Feature
[76]	1D convolution	MSE, GAN loss	Checked in luggage CT	Advantages: generate complete projection data at extreme sparse views and have high feature similarity
[77]	Skip connection	MSE, GAN loss	Siemens Somatom CT	
[78]	Residual learning, skip connection	MSE, GAN loss	Oral CT	
[79]	Skip connection	MAE, GAN loss	Cranial cavity CT	Limitations: GANs are difficult to train and have poor convergence
[80]	Skip connection	MAE, GAN loss	Cranial cavity CT, Head PhantomCT	
[82]	Skip connection, residual learning	MAE, GAN loss	Modified FORBILD abdomen phantom CT	
[83]	Skip connection	MSE, GAN loss	AAPM Low Dose CT	

6 基于深度学习的稀疏或有限角度 CT 双域数据联合处理

第 4 节和第 5 节中的两种方法均利用 CNN 在正弦域或者重建后 CT 图像域进行单一领域的图像插值、滤波去伪影处理。为进一步减少模型在正弦域中生成投影数据误差和重建后图像去伪影时产生模糊的现象,一种在不同域数据变换过程嵌入物理解析重建算法的综合域神经网络处理模型被提出,同步联合 CNN 对正弦域稀疏或有限角度投影数据进行插值滤波和对重建 CT 图像进行去伪影,可以实现端到端的弦图到 CT 图像的训练和重建测试。按照网络主体模型的不同,可将基于深度学习的正弦域与图像域联合处理方法分为 3 种:基于 U-net 与 FCN 的双域重建网络;基于 GAN 的双域重建网络;基于 Transformer 的双域重建网络。基于 CNN 的稀疏角度 CT 重建的正弦域与图像域联合处理流程如图 18 所示。

6.1 基于 U-net 与 FCN 的双域重建网络

Yuan 等^[84]构建了如图 19(a)所示的基于残差 U-net 的双域重建网络框架 (SPID),该框架能同时实现在稀疏角度正弦域插值和 CT 图像域去伪影的功能,重建结果如图 20(a)所示,在结构重建精确度与数据保真度上相比单域网络处理方法有一定程度的提升。为增强模型对不同域数据的表征能力, Lee 等^[85]用多尺度二维离散小波变换取代 U-net 下采样中的池

化层,先对稀疏角度正弦图进行线性插值,再使用 CNN 对插值误差数据进行优化,通过小波变换将特征数据分为不同频段的数据,利用网络结构分别表征高低频的插值误差,同时也进一步减少了正弦图与 CT 图像因池化层下采样而导致空间分辨率损失的问题。如图 19(b)所示, Liang 等^[86]在上述综合域网络基础上,利用正弦图分布特性改进了正弦域修复网络,根据 CT 扫描几何投影结构将缺失的角度数据按邻域关系分为不同子集,分别利用多通道的网络修复不同部分的弦图缺失数据,最后在空间维度拼接后,利用一个优化网络生成满角度投影,进而增强投影数据的保真度,并进一步用 U-net 对重建后的 CT 图像进行优化,重建结果如图 20(b)所示。Zhou 等^[87]同样基于数据保真层的设计,提出一种端到端递归循环的综合域神经网络框架 (DuDoDR-Net),如图 19(c)所示,该框架主要由图像数据一致层 (iDCL) 和正弦图数据一致层 (sDCL) 构成。在 U-net 的基础卷积模块中,该框架融合了通道注意力机制和密集连接模块,进一步通过结合金属伪影和真实稀疏角度的正弦图的掩模图,在图像域和正弦域通过交错迭代方式减少了 CT 中出现的金属伪影现象,重建结果如图 20(c)所示。此外还有对反投影模块进行固定权重设计的方法,如通过将一个固定权重的 FBP 模块嵌入到 FCN 或 U-net 中,同样实现由弦图域到图像域端到端直接重建的过程^[88-89]。

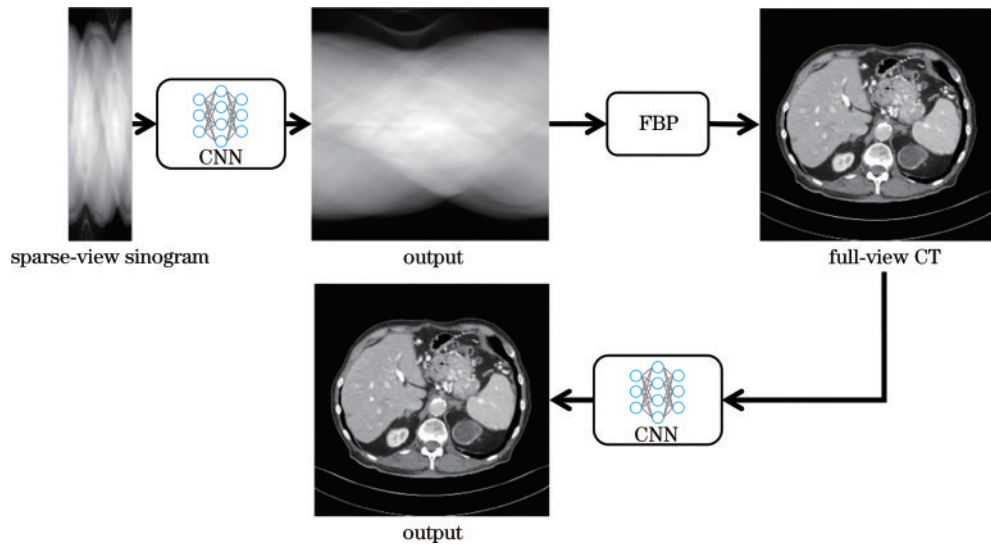


图 18 双域网络联合处理流程

Fig. 18 Dual-domain network joint processing process

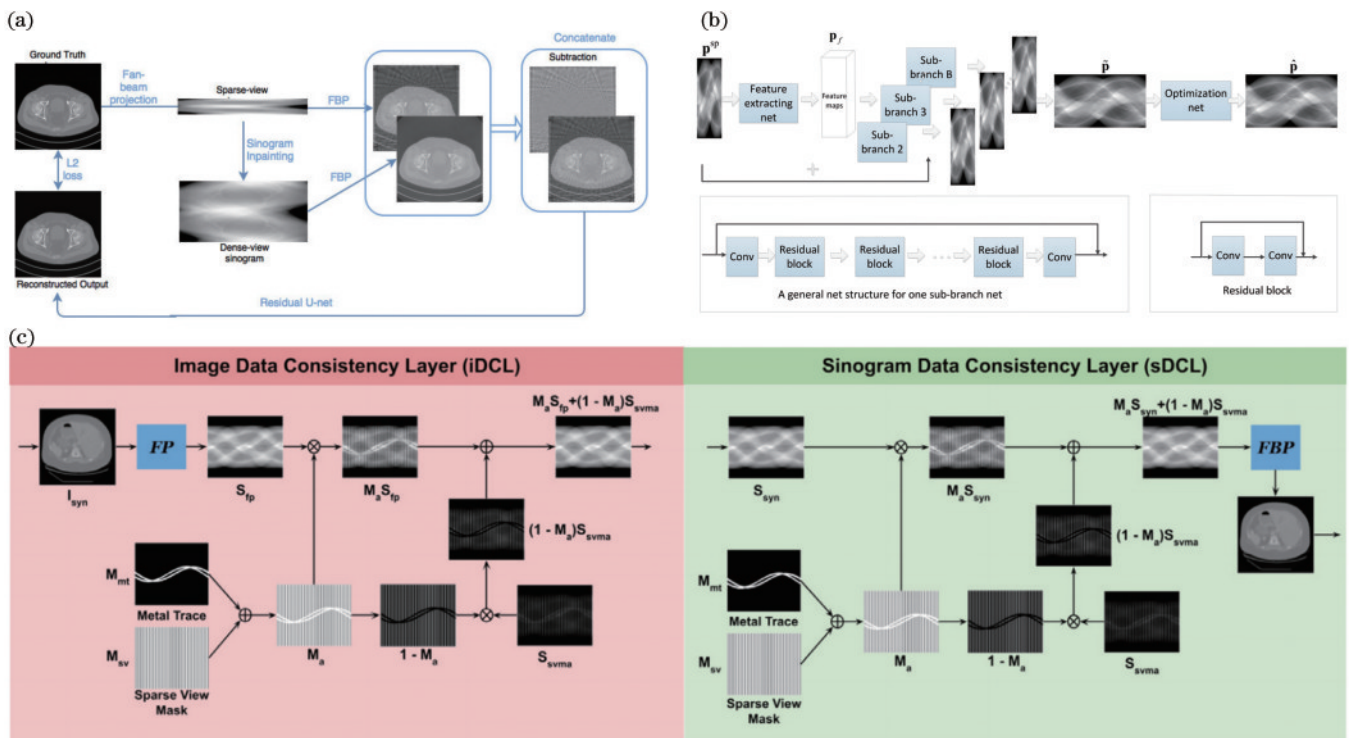


图 19 基于 U-net 与 FCN 的双域重建网络。(a) SPID 模型^[84]; (b) 多通道修正正弦图模型^[86]; (c) DuDoDR-Net 模型^[87]

Fig. 19 Dual-domain reconstruction network based on U-net and FCN. (a) SPID model^[84]; (b) multi-channel sinogram restoration model^[86]; (c) DuDoDR-Net model^[87]

针对双能量谱稀疏角度 CT 重建问题, Zhang 等^[90]基于双能 CT 扫描的能量域冗余特性和空间域一致性, 设计了一个具有双通道 U-net 的光谱互补综合域网络 (CD-Net), CD-Net 分别处理高、低能量谱中的正弦图和 CT 图像数据, 解决了双能 CT 系统存在的能量域信息冗余问题, 并且在损失函数中加入不同能量谱差异平均绝对误差损失函数, 确保了双能谱分解的准确性。Amirrahedi 等^[91]在稀疏角度正电子发射层析图像重建研究中, 同样引入 U-net 并采

用卷积下采样和插值卷积方式取代了池化层和反卷积操作, 减少了 PET 图像空间特征信息丢失的同时避免了反卷积运算导致上采样后的图像产生棋盘效应的问题。

而对于三维稀疏和有限角度 CT 图像重建问题, 相比单域网络的处理方式, 综合双域网络模型的复杂度与计算量会变得更高, 如何减少模型计算量与降低计算复杂度是该问题关键的解决思路。Hu 等^[92]直接使用三维 U-net^[93]对三维稀疏正弦图和 CT 图像分别

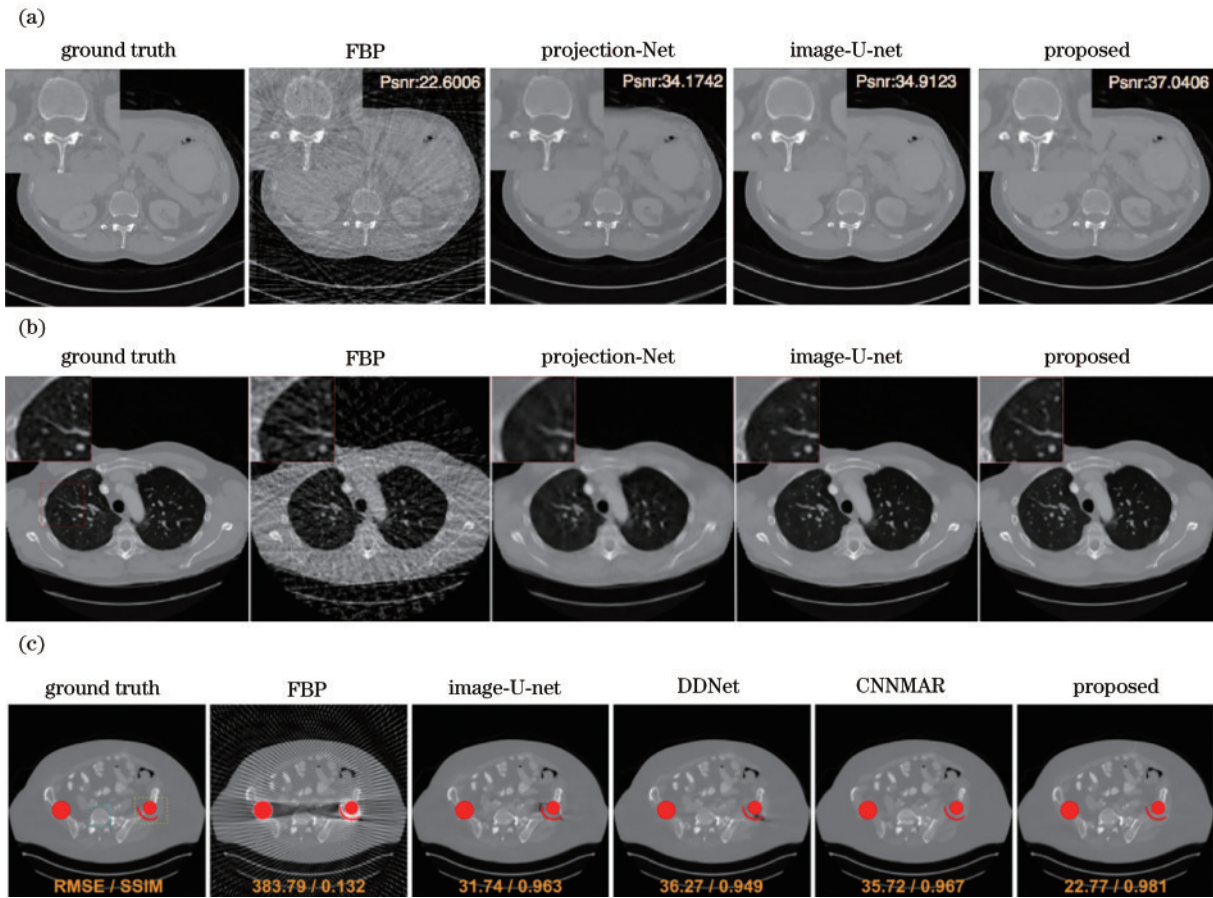


图 20 基于 U-net 与 FCN 的双域重建网络的重建结果。(a)文献[84]的 CT 重建结果;(b)文献[86]的 CT 重建结果;(c)文献[87]的 CT 重建结果;

Fig. 20 Reconstruction results of dual-domain reconstruction networks based on U-net and FCN. (a) CT reconstruction results in Ref. [84]; (b) CT reconstruction results in Ref. [86]; (c) CT reconstruction results in Ref. [87]

进行优化处理,并且利用卷积层取代下采样池化层,较好地避免了细节结构的丢失。Han 等^[94]更进一步将二维 U-net 应用在极端稀疏角度三维 CT 重建中,模型通过对三维正弦图进行切片处理,只需对二维稀疏角度正弦图和 CT 图像进行插值与去伪影,从而简化三维 CT 重建在网络设计上的计算与空间复杂度。Zheng 等^[95]在文献[92]的基础上结合了原始稀疏角度的投影数据特性,提出一种具有数据保真度的端到端正弦域和图像域双域处理的 CNN 结构,以重建稀疏螺旋三维 CT 图像。

6.2 基于 GAN 的双域重建网络

GAN 模型也同样被用于综合双域网络的优化训练中。Zhao 等^[96]提出了一种基于 CNN 和 GAN 的双域重建网络结构,首先在弦图域中使用残差 CNN 模型对稀疏角度正弦图进行插值,恢复为满角度的正弦图,在图像域中则结合感知损失函数和重建损失函数约束 GAN 并对重建的 CT 图像进行优化,有效解决了重建后 CT 图像过于平滑并且高频边缘结构缺失的问题。Ketola 等^[97]基于 Pix2Pix-GAN^[81],提出一种综合域神经网络(DGAN),如图 21 所示,DGAN 利用输入标签

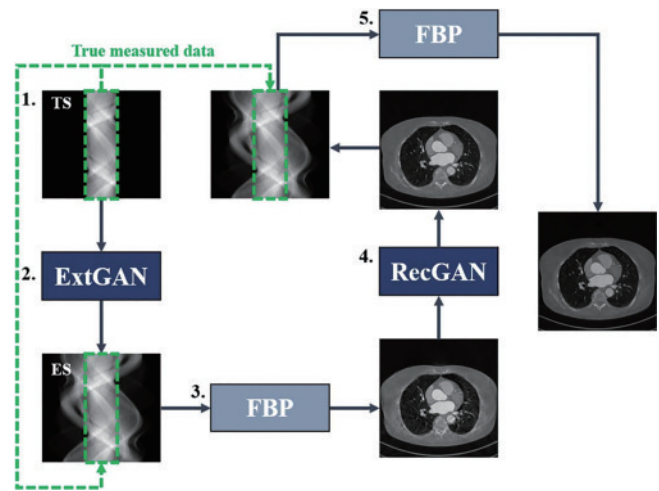


图 21 DGAN 模型^[97]

Fig. 21 DGAN model^[97]

条件指导的方式训练鉴别器,最终能够使生成器正确恢复在内部 CT 扫描系统中被截断的正弦图投影数据,并且进一步修复了 FBP 重建的 CT 图像,同时在 ExtGAN 生成的投影数据和 RecGAN 生成 CT 图像的正向投影数据中,融入了真实的截断弦图数据,以抑制

虚假结构的生成和加强图像恢复的细节结构。Xie 等^[98]则通过在投影域中结合余弦相似性度量和 Softmax 自注意力分数计算过程对缺失的弦图数据进行修复,利用自监督掩模弦图损失约束 GAN 的优化过程,在图像域中则利用循环 GAN 损失实现对 CT 图像修复的无监督训练过程,从而改善网络训练时对标签数据依赖度高的问题。

6.3 基于 Transformer 的双域重建网络

将 Transformer 与可微分的 FBP 算法相结合,可以构建具有双域数据长距离关联的稀疏或者有限角度 CT 双域重建网络。Wang 等^[99]提出了一种双域 Transformer 网络,利用 Swin-Transformer 编码器长距离依赖关系建模能力从稀疏角度弦图中提取全局先验信息,以匹配满角度弦图全局特征,同时通过在图像域中结合原始和增强的正弦图重建结果来共同恢复高质

量 CT 图像。Shi 等^[100]将稀疏角度弦图直接视作长句子向量,输入到原始 NLP 的 Transformer 解码器中,以辅助增强图像域网络中 Transformer 编码器提取的全局特征,最终通过卷积块重建得到 CT 图像。Li 等^[101]针对 Transformer 处理二维插值弦图或者 CT 图像时的不匹配性问题,通过在自注意力机制中的多层感知机(MLP)映射模块中增加卷积块以减少图像降维时特征信息的损失。Pan 等^[102]为了减轻双域 Transformer 带来的计算成本开销,将 Transformer 只用在了最后的 CT 图像微调模块中,而初始的稀疏角度弦图和 CT 图像的恢复过程则通过 CNN 完成,其网络结构与重建结果如图 22 所示。增加了 Transformer 结构的双域网络能够实现比基于 CNN 的迭代重建算法(FISTA 以及 LEARN)更高的重建性能,同时重建所需的时间更短。

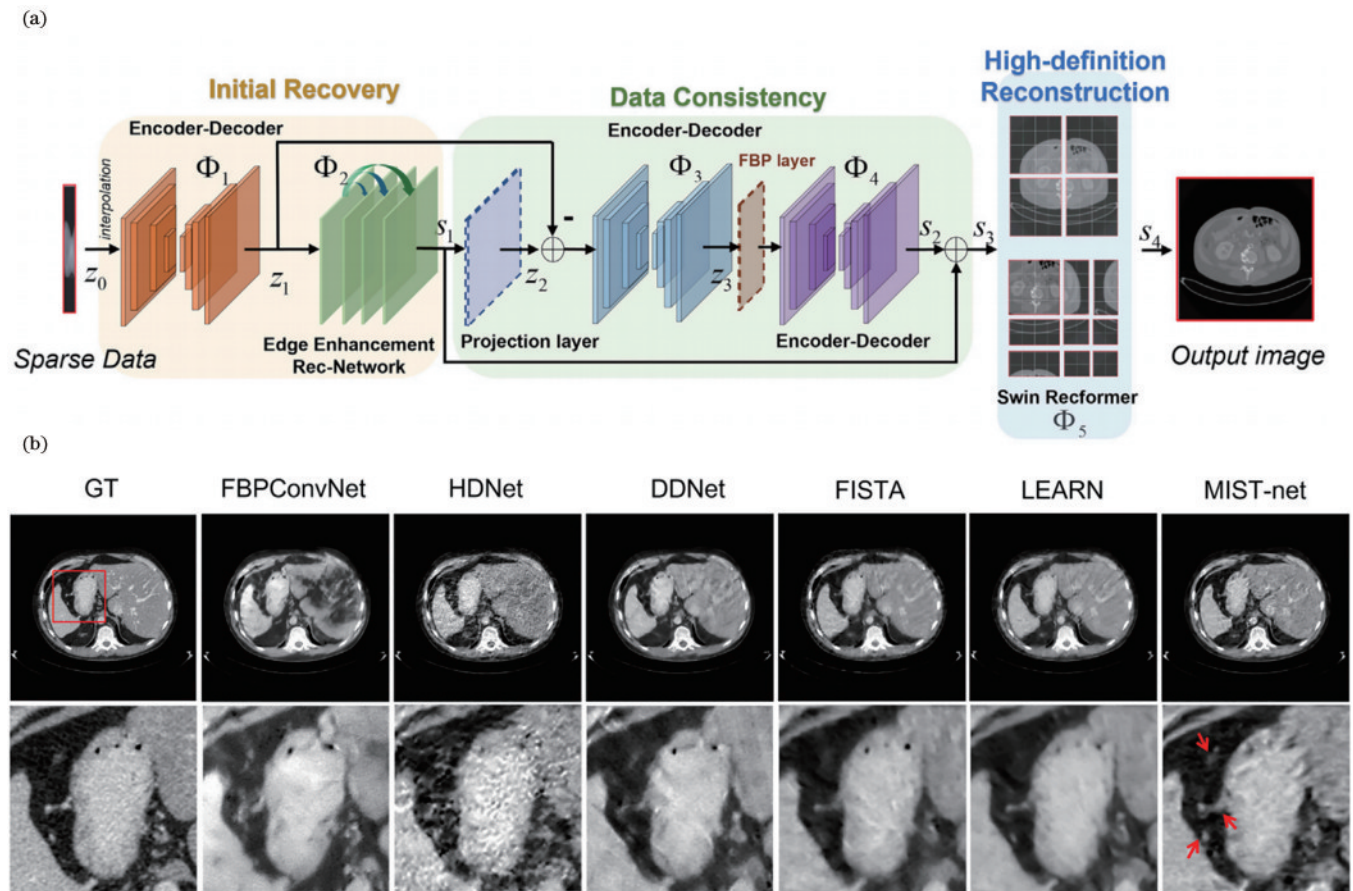


图 22 网络结构与重建结果^[102]。(a)基于 Transformer 的双域重建网络;(b)CT 重建结果对比

Fig. 22 Network structure and reconstruction results^[102]. (a) Dual-domain reconstruction network based on Transformer;

(b) comparison of CT reconstruction results

6.4 双域数据联合处理方法总结

相比在图像域或者正弦域的单一域数据处理方法,双域神经网络处理方法能够更加充分地关联正弦域和图像域的图像特征信息,具有双域数据的保真约束效果,在微小结构的恢复与伪影抑制上都表现出更加优秀的性能。同时,双域重建网络在正弦域数据转换过程嵌入了可微分的 FBP 算法,能够直接将稀疏或

有限角度投影数据单步重建为高质量 CT 图像而无需对不同域数据进行分离处理。Transformer 结构的引入进一步增强了双域网络对弦图与 CT 图像长距离依赖关系的建模能力,可实现更好的图像细节信息恢复性能。在正弦域网络基础上,增加图像域后处理的网络能够有效校正正弦域网络修复插值弦图数据时所引入的误差投影数据,抑制重建中的虚假结构和优化

CT重建的细节结构。不过综合双域重建网络在模型设计复杂度、计算速度等方面都要略低于单一域数据处理方法。表 6 和表 7 对基于 CNN 和 GAN、

Transformer 的双域重建网络相关文献中所使用的网络细节结构、损失函数、数据集及算法的优点和局限性进行了总结。

表 6 基于 CNN 和 GAN 的双域重建网络方法总结

Table 6 Summary of dual-domain reconstruction network based on CNN and GAN

Reference	Network detail	Loss function	Dataset	Feature
[84]	Residual learning, skip connection	MSE, TV loss	AAPM Low Dose CT	
[85]	Residual learning, skip connection, wavelet transform	MAE	TCIA	
[86]	Residual learning, skip connection	MSE	thoracic CT	
[87]	Dense block, channel attention, residual learning, skip connection	MAE	DeepLesion	Advantages: the network has dual domain data fidelity; end-to-end reconstruction of projection data
[88]	Residual learning	MAE, MSE	AAPM Low Dose CT	
[89]	Skip connection	MSE	AAPM Low Dose CT	
[90]	Residual learning, skip connection, dual channel fusion	MAE, SSIM loss, DIFF loss	AAPM Low Dose CT	
[91]	Residual learning, skip connection		Small animal Xtrim PET	
[92]	Skip connection	MSE	AAPM Low Dose CT	
[93]	Skip connection	Cross-entropy loss	Xenopus kidney embryos	
[94]	Skip connection	MSE	real 9-view CT EDS	
[95]	Residual learning, skip connection	MSE	AAPM Low Dose CT	
[96]	Residual learning	MSE, GAN loss, Perceptual loss	Data Science Bowl 2017	Limitations: dual CNN structure is simple; dual GANs further increase the cost of training and the difficulty of convergence
[97]	Skip connection	MAE, GAN loss	Heart craniocaudally CT	
[98]	Skip connection, cosine similarity, Softmax attention	Hole_L1 loss, perceptual loss, Cycle GAN loss	DeepLesion, LDCT and Projection data	

表 7 基于 Transformer 的双域重建网络方法总结

Table 7 Summary of dual-domain reconstruction network based on Transformer

Reference	Network detail	Loss function	Dataset	Feature
[99]	Swin-Transformer	MSE	AAPM Low Dose CT	Advantages: long-range dependency modeling capability; extracting global feature information
[100]	Transformer	MSE	LIDC-IDRI	
[101]	Swin-Transformer	MSE, Charbonnier loss	LDCT and Projection data	Limitations: large number of parameters of the self-attention mechanism
[102]	Swin-Transformer, Sobel operator	MSE	AAPM Low Dose CT	

7 基于深度学习的稀疏或有限角度 CT 迭代重建

随着压缩感知理论和稀疏表示等在 CT 重建中的应用,在迭代重建框架上结合 CT 图像的先验信息建立的模型在稀疏或者有限角度 CT 图像去伪影方面表现出色。通常 CT 图像迭代重建算法在数学上可以表示为

$$\hat{\mathbf{x}} = \arg \min_{\mathbf{x}} E(\mathbf{x}) = \arg \min_{\mathbf{x}} \left[\frac{\lambda}{2} \|\mathbf{A}\mathbf{x} - \mathbf{y}\|_2^2 + R(\mathbf{x}) \right], \quad (9)$$

式中: \mathbf{A} 表示正向投影矩阵; \mathbf{x} 表示待重建的 CT 图像; \mathbf{y} 表示 CT 系统中投影弦图数据;目标优化方程中左侧的最小二乘项作为迭代重建中的数据保真项; $R(\mathbf{x})$ 表示 CT 图像中的先验信息,作为迭代重建中的正则约

束项; λ 为平衡数据保真项和正则项的系数。传统的迭代问题需要利用梯度下降法多次重复计算正向投影数据和反投影 CT 图像数据, 以更新优化目标函数中的投影矩阵 \mathbf{A} 与 λ 等参数, 求导后结合梯度下降法, 迭代优化过程可以表示为

$$\mathbf{x}^{i+1} = \mathbf{x}^i - \left\{ \left[\lambda \mathbf{A}^T (\mathbf{A} \mathbf{x}^i - \mathbf{y}) \right] + R'(\mathbf{x}^i) \right\}, \quad (10)$$

式中: \mathbf{A}^T 表示反投影矩阵。通过反投影矩阵, 迭代重建算法计算初始估计的 CT 图像的稀疏或者有限角度投影数据, 然后与真实投影数据进行对比, 得到投影误差后再进一步反投影至图像域中, 结合正则项更新 CT 图像, 所以迭代重建算法需要消耗较长的计算时间, 同时含有正则项的梯度求导优化过程也进一步加重了算法的计算负担。对于传统迭代算法, 目前存在

两方面的问题: 1) 针对 CT 系统和不同 CT 图像重建任务, 都需要重新选择合适的约束条件正则项, 对于不同重建任务很难找到一个通用的正则项用于迭代重建, 并且算法中的平衡参数 λ 同样需要通过大量人工实验来进行选择, 同时由于不同 CT 成像系统中噪声与波束硬化等不一致的问题, 图像的先验信息也不易获取, 使用传统迭代重建算法重建稀疏角度和有限角度 CT 图像时并不能快速且可靠地得到高质量 CT 图像; 2) 迭代算法进一步结合凸优化算法对目标方程进行迭代求解时, 存在计算复杂度高与非凸子问题优化求解难的问题。在迭代重建算法中引入深度学习可在一定程度上缓解上述问题, 提高 CT 图像重建速度和质量。基于 CNN 正则项的稀疏角度 CT 迭代重建流程如图 23 所示。

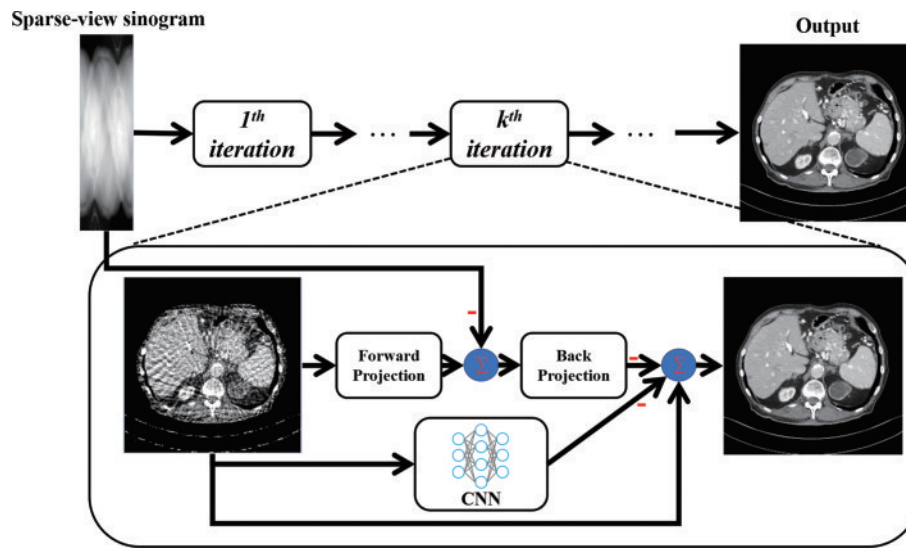


图 23 基于 CNN 正则项的迭代重建流程^[103]

Fig. 23 CNN regular term based iterative reconstruction process^[103]

7.1 基于 CNN 的正则项与平衡参数的优化模型

为解决正则项在迭代更新过程中求导计算的复杂度高及需要人为选择设计等问题, Chen 等^[103]将“专家领域(FoE)”广义正则项引入稀疏角度迭代重建模型中作为约束项, 该正则项由一个势函数表示, 进而利用势函数的特性设计 CNN 模块来学习更新正则项中的参数, 简化了正则项的选择设计, 同时更有效地利用了图像中的先验知识。在文献^[103]基础上, Zhang 等^[104]提出一种由两个并行交互的子网络构成的双域 CNN 正则项迭代模型, 在图像域与正弦域中同时进行 CT 图像和投影数据的修复, 充分利用投影数据和重建图像之间潜在的投影关系, 加强了重建 CT 图像与投影数据的保真度。Hammernik 等^[105]受到变分图像恢复中分线性滤波方法的启示, 提出一种基于卷积算子正则项的有限角度 CT 迭代重建算法, 利用 CNN 代替卷积算子正则项迭代更新参数, 同时通过网络反向传播对正则项平衡参数进行优化更新, 从而降低迭代模型的计算复杂度。更进一步地, Cheng 等^[106]利用充分的稀疏采样

条件生成全采样系统矩阵, 在迭代重建中, 通过全采样矩阵重建目标图像和拟合对应正弦域满角度的投影数据, 并将它们作为约束的正则项, 将 CNN 融入数据保真项和正则项迭代更新中, 直接学习投影数据和 CT 图像之间的相互关系, 从而不需要根据图像噪声分布建模数据保真项和基于图像先验信息对正则项进行更新。Wang 等^[107]提出一种基于交替方向乘子法(ADMM)的有限角 CT 深度重建算法(ADMMBDR), 先使用 ADMM 拆分正则化重建模型, 然后使用 U-net 代替 ADMM 正则项部分子问题迭代步骤, 以迭代减少 CT 图像的伪影同时避免正则项及其参数选择。

此外, 也有工作将 Transformer 与 CNN 结合至 CT 迭代重建算法中, 通过多头自注意力机制以进一步提取图像的先验信息。Xia 等^[108]利用 CNN 学习图像局部正则化同时利用 Transformer 中的自注意力编解码结构将学习到的非局部先验信息进一步映射至迭代模型中, 提高了迭代模型提取深层特征的能力, 其整体迭代结构与重建结果如图 24 所示, 相比 CNN 迭代重建

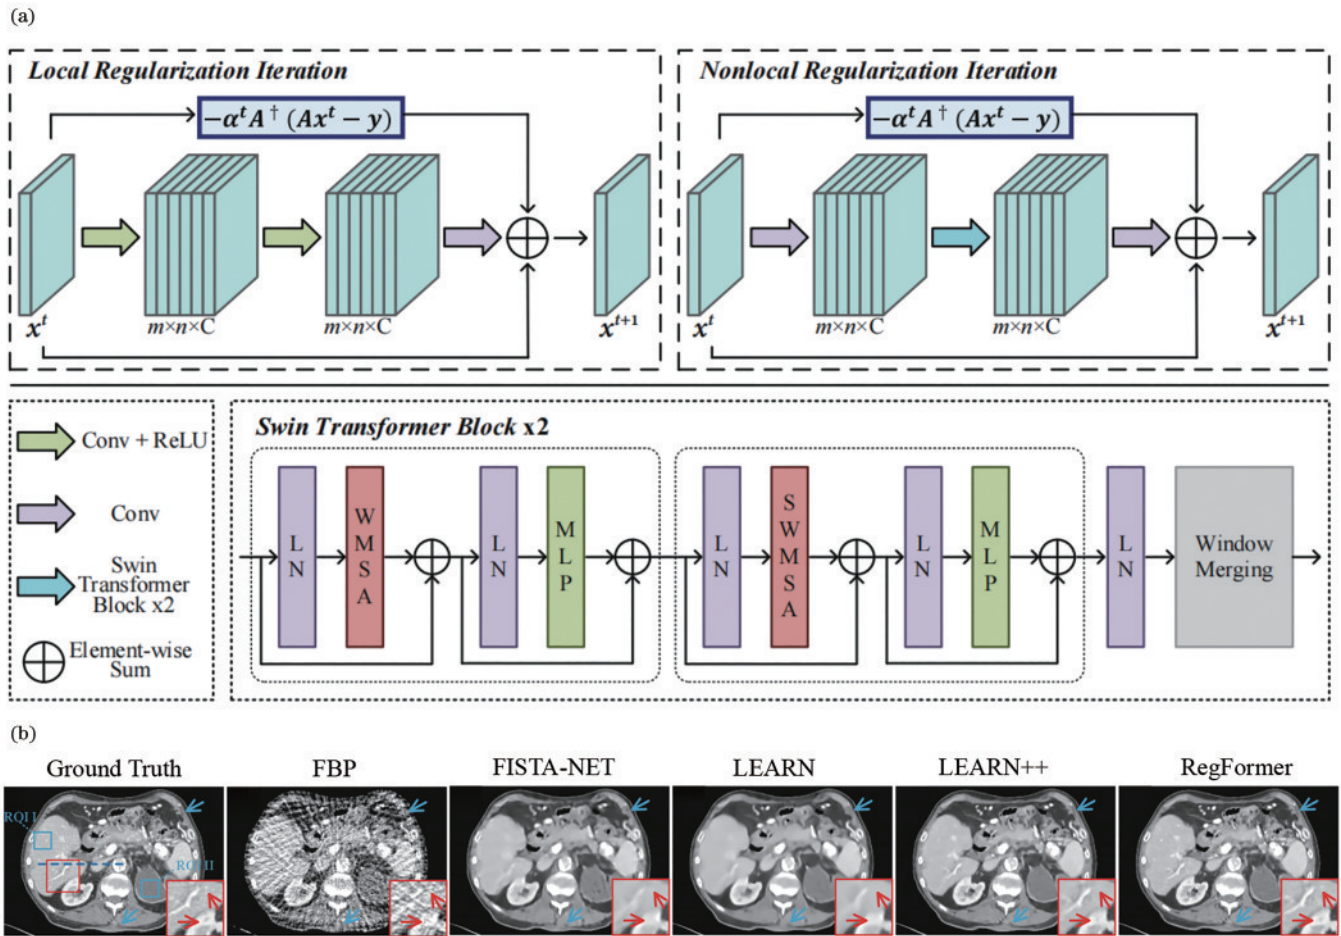


图 24 基于 CNN 的正则项与平衡参数的优化模型及重建结果^[108]。(a)RegFormer 模型；(b)CT 重建结果对比

Fig. 24 Optimization model of regular terms and balance parameters based on CNN and reconstruction results^[108]. (a) RegFormer model; (b) comparison of CT reconstruction results

算法,实现了更高质量的重建结果,但同时也增加了计算参数量。

7.2 基于 CNN 的子问题迭代展开优化模型

为降低模型迭代计算复杂度,稳定获取图像先验信息,CNN 被用于不同迭代模型的子问题优化求解过程中。Huang 等^[109]提出一种基于数据一致性伪影消除的迭代重建算法,首先使用 U-net 在有限角度 CT 图像中学习伪影信息得到先验图像,在一定程度上提供了缺失角度的投影域信息,随后利用迭代算法进一步优化缺失的投影数据,并通过约束项保证有限角度的测量值一致性,从而恢复得到完整角度的投影数据。Zhang 等^[110]基于迭代的联合空间-Radon 域重建(JSR)模型和 CNN,提出了一种 CNN 迭代重建算法(JSR-Net),采用多尺度结构相似性、均方差和语义损失的混合损失函数提高网络重建 CT 细节与边缘结构的性能,通过 CNN 对子问题进行迭代,JSR-Net 恢复和重建更多的重要细节结构。Chun 等^[111]将回归神经网络与模型迭代图像重建方法相结合,提出快速收敛的逆神经网络(Momentum-Net),Momentum-Net 由图像细化、基于动量更新项的图像迭代推断、图像重建三个核心模块组成,其中构建的动量更新项加快了图像迭代

推断部分的收敛速度。Xiang 等^[112]结合基于模型的快速迭代收缩阈值算法(FISTA)与 CNN,提出了如图 25(a)所示的基于模型迭代的神经网络,使用阈值算子代替梯度下降算法同时通过结合动量项加快图像迭代的收敛速度,并且算法中设计了一个 CNN 模型来解决稀疏约束近端映射求解问题,将 CNN 中学习到的参数通过不同阈值算子加权后在整个迭代中共享,以处理不同重建问题迭代中的不同噪声,重建结果如图 26(a)所示。同时,Bubba 等^[113]提出了一种基于剪切波变换与稀疏正则化的深度学习混合迭代重建算法,整体算法结构如图 25(b)所示,利用剪切波变换在 CT 图像空间将其像分解为可见与不可见波前集,在迭代更新部分 CNN 仅用于推断不可见剪切波系数,只学习基于原始模型中迭代不可处理部分的子问题参数,提高模型的稳定性与迭代速度,重建结果如图 26(b)所示。

Genzel 等^[114]基于 U-net 设计一个具有离散扇形正弦域数据反投影转换步骤的端到端神经网络迭代重建模型,将反投影模块过程融合到基于梯度下降的参数优化更新项中,其中 U-net 作为一个后处理模块,嵌入到模型的每一层中对输出的稀疏角度 CT 图像细节结

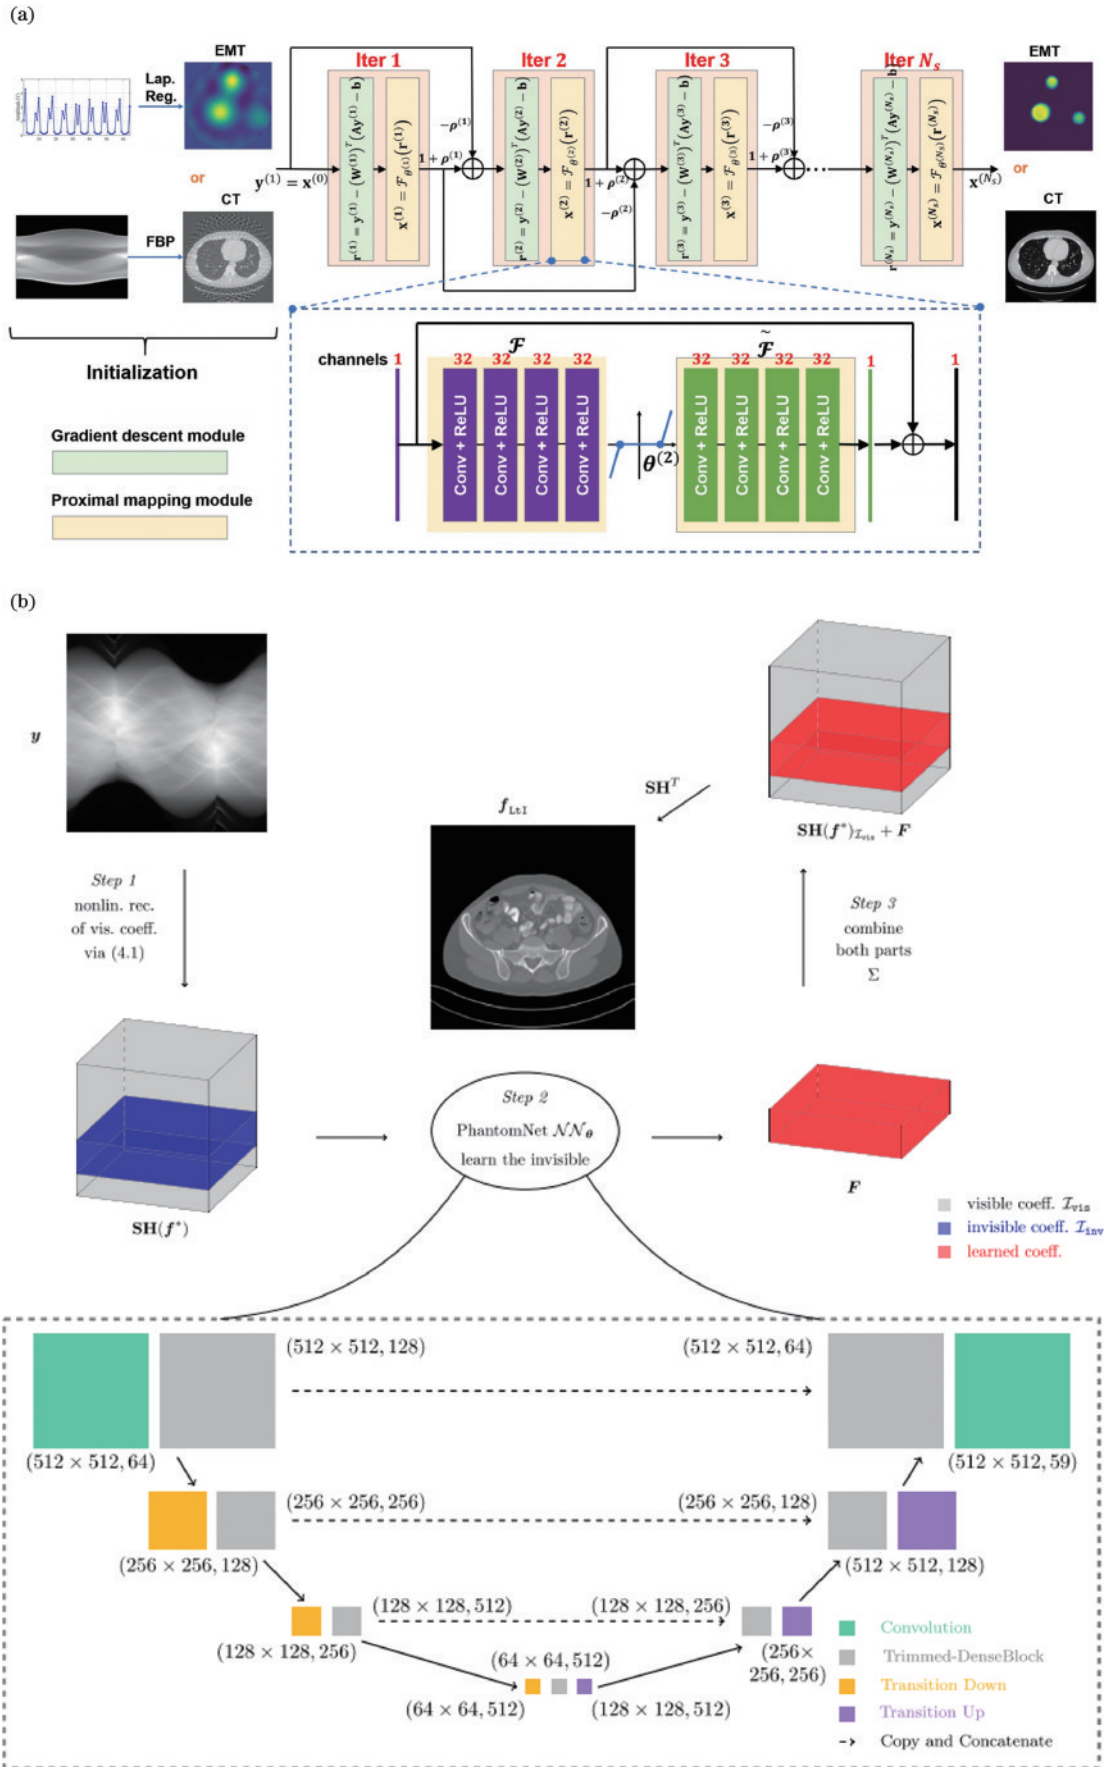


图 25 基于 CNN 的子问题迭代展开优化模型。(a) 基于 FISTA 的迭代重建模型^[112]; (b) 基于剪切波的迭代重建模型^[113]
 Fig. 25 Sub-problem iterative expansion optimization models based on CNN. (a) FISTA-based iterative reconstruction model^[112]; (b) shear wave based iterative reconstruction model^[113]

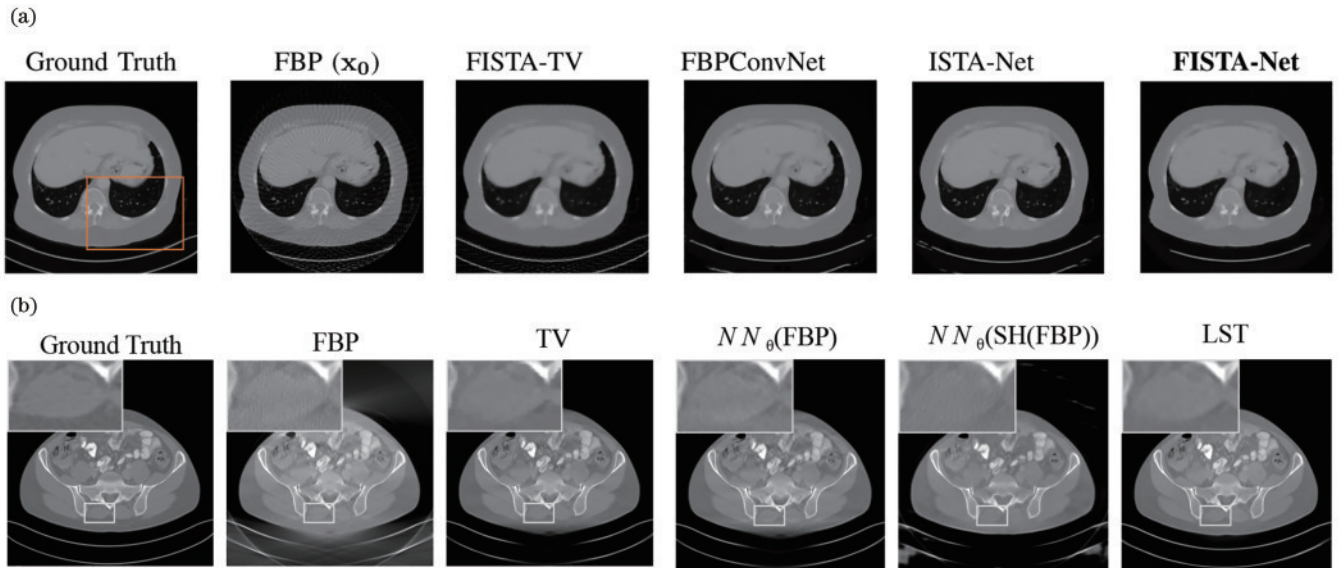


图 26 基于 CNN 的子问题迭代展开优化模型重建结果。(a)文献[112]的 CT 重建结果;(b)文献[113]的 CT 重建结果

Fig. 26 Reconstruction results of sub-problem iterative expansion optimization model based on CNN. (a) CT reconstruction results in Ref. [112]; (b) CT reconstruction results in Ref. [113]

构进行修复,而正则项则使用测量的稀疏角度弦图作为约束条件。Zhang 等^[115]将半二次分裂-共轭梯度算法作为骨干网络,U-net 仅用于预测算法中每一层迭代的初始化图像信息,减少了整个模型所需训练的参数数量和模型不稳定因素,实验结果表明该算法在各种测试设置条件下都能以更高质量重建 CT 图像。

7.3 其他 CNN 迭代展开和无监督迭代重建模型

Wu 等^[116]使用残差 U-net 和 GAN,分别在正弦域和图像域进行投影数据插值和 CT 图像细化处理,同时还结合了压缩感知模块对重建的先验 CT 图像进行进一步展开迭代优化,提高重建图像的保真度。Zhou 等^[117]融合通道和空间注意力机制和密集连接网络,提出了一种具有数据保真层改进的模型迭代算法,该算法在每一层迭代块中都输入真实的有限角度投影数据作为约束项,并且利用注意力机制减少细节结构丢失,更有效地去除了图像迭代过程中的噪声。陈高宇等^[118]在融合解析迭代重建网络基础上分别在每层迭代之间增加残差结构,与先前迭代层重建的图像相加,并且每层同样使用具有密集连接和残差连接的 CNN,增强 CT 图像特征在后层的传输能力,从而减少迭代总次数与增加模型重建的精度。

医学图像数据集在实际中并不容易获取到且通常缺少对应的 CT 弦图数据,而基于无监督的学习方式可以减少模型对 CT 图像标签的依赖性,另一种思路则是将无监督方式融合到迭代重建算法中以提高模型的泛化能力。Wu 等^[119]将 K 值-稀疏自编码器与 CNN 相结合,采用无监督训练方式对稀疏角度 CT 进行迭代重建,每次迭代时计算 K 个最大值元素作为图像稀疏掩模图,利用全连接层来训练图像进行更新迭代,最终通过贪婪算法对迭代过程求得最优解。Zhang 等^[120]

利用基于去噪自编码器多通道先验信息的无监督算法,提出了一种融合 CNN 的迭代重建算法 (REDAEP),如图 27(a)所示,将去噪自编码器获得的先验信息作为 ART 迭代模型的正则项以约束 CT 图像的优化过程,并且将 CT 图像中 RGB 通道信息固有的高维结构融入 CT 图像重建过程,增强了网络的表达能力,重建结果如图 27(b)所示,基于无监督迭代的算法的结果要优于传统的 TV 正则化迭代算法和基于监督的 CNN 后处理算法。Chun 等^[121]结合无监督算法利用卷积分析算子 (CAOL) 训练自编码神经网络,同时利用块近端梯度法 (BPG-M) 优化模型框架和动量项,对图像进行展开迭代更新,解决非凸问题优化,从而加快重建速度。

7.4 神经网络迭代重建方法总结

与传统 CT 迭代重建算法相比,基于迭代模型与 CNN 结合的重建方法通过利用神经网络取代迭代模型中的正则项与平衡参数的更新过程,降低了迭代运算过程的计算复杂度,同时减少了人工选择参数与正则项的实验成本。在另一方面,利用 CNN 对目标优化方程中的子问题进行求解,可以有效解决非凸问题,优化部分的映射解关系,进一步降低计算复杂度。相比普通 CNN 单域或者双域网络方法,基于迭代模型与 CNN 结合的重建方法重建的 CT 图像效果要更好。与双域网络的方法类似,迭代算法同样能够实现端到端重建过程,但是基于迭代重建的算法仍然不可避免地需要建立多个投影与反投影过程,模型迭代过程依旧具有较大的计算与内存开销。相比神经网络迭代算法,双域网络则是一种平衡精度与速度的方法。表 8~10 对基于 CNN 的正则项与平衡参数的优化模型、基于 CNN 的子问题迭代展开优化模型、其他 CNN 迭代

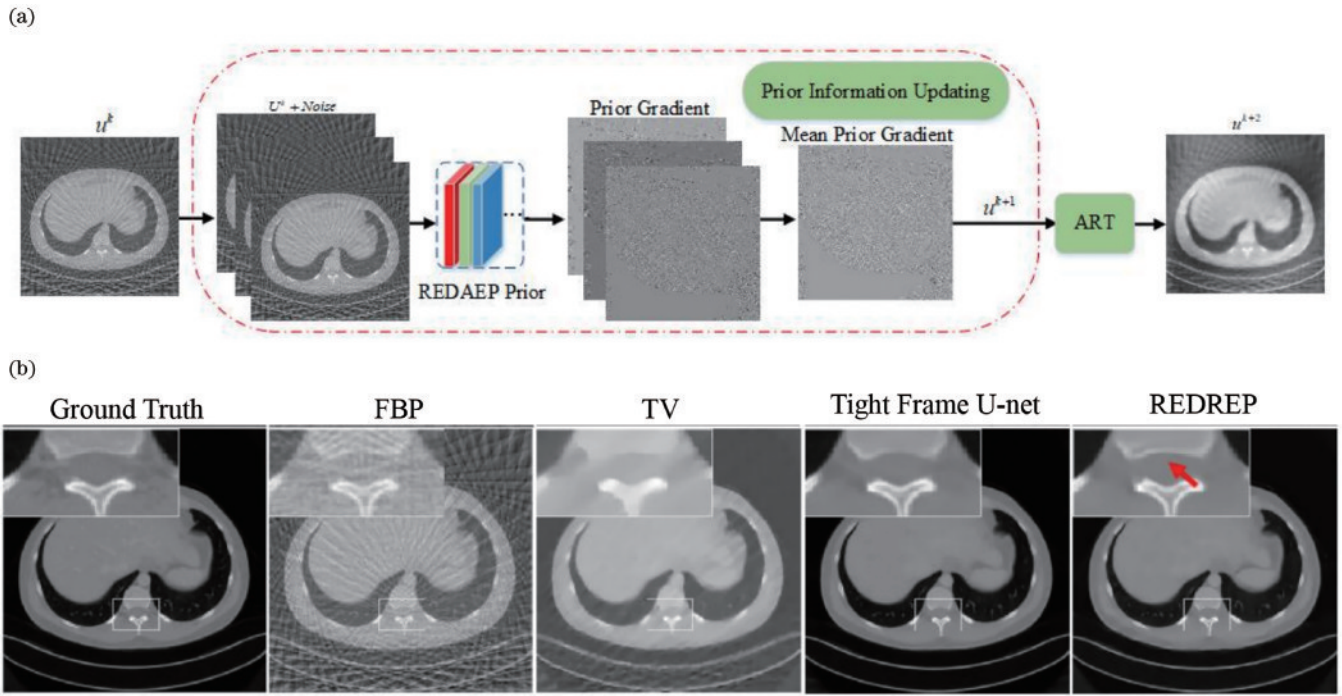


图 27 无监督迭代模型及重建结果^[120]。(a) REDAEP 迭代重建模型; (b) CT 重建结果对比

Fig. 27 Unsupervised iterative model and reconstruction results^[120]. (a) REDAEP iterative reconstruction model; (b) comparison of CT reconstruction results

表 8 基于 CNN 的正则项与平衡参数的优化模型总结

Table 8 Summary of optimization model of regular terms and balance parameters based on CNN

Reference	Network detail	Loss function	Dataset	Feature
[103]	Residual learning	MSE	AAPM Low Dose CT	Advantages: avoid the selection of regular terms and balance parameters; reduce the cost of manual experiments and computational complexity
[104]	Residual learning	MSE, perceptual loss	AAPM Low Dose CT	
[105]	1D convolution	MSE		
[106]	Residual learning	MSE	Ellipses, head phantom	
[107]	Residual learning, skip connection	MSE	TCIA	
[108]	Transformer	MSE	AAPM Low Dose CT	Limitations: high number of reconstruction iterations

表 9 基于 CNN 的子问题迭代展开优化模型总结

Table 9 Summary of the sub-problem iterative expansion optimization model based on CNN

Reference	Network detail	Loss function	Dataset	Feature
[109]	Convolution-based	MSE	AAPM Low Dose CT, Clinical Head	Advantages: mapping solutions to non-convex problem; accelerated reconstruction rate using CNN
[110]	Convolution-based	MSE, SSIM loss, semantic loss	AAPM Low Dose CT	
[111]	Convolution-based	MSE	AAPM Low Dose CT	
[112]	Residual learning	MSE	Simulated EMT	
[113]	Skip connection	MSE	Ellipses, AAPM Low Dose CT	Limitations: few parameters for network training; high number of reconstruction iterations
[114]	Skip connection	MSE	AAPM Low Dose CT	
[115]	Residual learning, skip connection	MSE, SSIM loss	AAPM Low Dose CT	

表 10 其他 CNN 迭代展开和无监督迭代重建模型总结

Table 10 Summary of other CNN iterative expansion and unsupervised iterative reconstruction models

Reference	Network detail	Loss function	Dataset	Feature
[116]	Residual learning, skip connection	Wasserstein loss, MSE	NBIA	Advantages: attention mechanism increases reconstruction accuracy; unsupervised training reduces dependence on labeled data and provides greater generalization
[117]	Dense block, residual learning, channel and spatial attention	MSE	AAPM Low Dose CT, DeepLesion	
[118]	Residual learning	MSE	Chest and abdomen CT	Limitations: attention mechanism increases network calculation parameters and reduces reconstruction speed; unsupervised network optimization is difficult
[119]	Fully connected	MSE, TV loss	AAPM Low Dose CT	
[120]	Residual learning	MSE	Ellipses, Chest CT	
[121]	Convolutional analysis operator learning	MSE	XCAT	

展开和无监督迭代重建算法的相关文献中所使用的网络细节结构、损失函数、数据集及算法的优点和局限性进行了总结。

8 基于深度学习的稀疏或有限角度 CT 端到端映射重建

CT 重建过程在数学上可以表示为

$$\mathbf{y} = \mathbf{A}\mathbf{x} + \mathbf{u}, \quad (11)$$

式中: \mathbf{y} 为正弦域离散投影数据; \mathbf{x} 为重建的 CT 图像向量; $\mathbf{A} \in \mathbb{R}^{(u \times v) \times (h \times w)}$ 是系统投影矩阵, 其中 $(u \times v)$ 为投影矩阵 \mathbf{A} 的总行数, 其等于 CT 系统中检测器数目与投影角度的乘积, $(h \times w)$ 为投影矩阵 \mathbf{A} 的总列数, 其等于重建图像高度与宽度的乘积; \mathbf{u} 是系统中存在的噪声。CT 重建过程则是对式(11)矩阵方程进行逆求解, 但是由于系统投影矩阵过大并且在稀疏或有限角度投影下重建的投影矩阵并非满秩, 所以该 CT 重建问题本质上是一个不适定和“病态”的逆问题, 并不能简单将投影矩阵直接转置来重建原图像 \mathbf{x} 。当前基于深度学习以解决逆问题的映射关系已经取得许多成果, 在解决投影矩阵求解的不适定和“病态”问题方面同样也有一定进展。基于深度学习的端到端稀疏或有限角度 CT 映射重建方法主要包括 3 种: 利用神经网络代替正向投影矩阵 \mathbf{A} , 直接从投影数据重建 CT 图像; 通过构建可学习的解析算法代替 FBP 算法, 嵌入到网络中实现端到端重建, 利用 CNN 学习反投影部分的重建映射关系; 利用傅里叶特征空间坐标映射、CNN 等从不同向量中自监督映射重建 CT 图像。基于 CNN 的端到端映射重建流程如图 28 所示。

8.1 基于神经网络的全学习重建模型

基于神经网络的全学习重建模型通过数据驱动的方式构建神经网络模型, 并以黑盒的形式直接学习物理解析重建过程, 将稀疏或有限角度正弦图数据直接映射为 CT 图像数据, 实现对“病态”逆问题的求解。Zhu 等^[122]首先提出一个统一的广义图像重建框架, 即 AUTOMAP 模型, 利用 CNN 实现了从传感器域数据




图 28 端到端映射重建流程

Fig. 28 End-to-end mapping reconstruction process

到图像域数据的自动映射重建, 不需要图像重建的相关“专业知识”, 直接使用全连接层代替域数据变换的编解码函数, 建立了流形映射的反投影关系, 随后在全连接层后增加卷积层, 在卷积特征空间中实现图像稀疏表示, 以重建图像细节结构, 同时实验结果表明该流形学习策略可以拓展至不同传感器数据的低维空间稀疏表示。Zhang 等^[123]基于 AUTOMAP 重建框架, 实验分析了全连接层在正弦域到图像域之间的转换作用。Yim 等^[124-125]替换了 AUTOMAP 全连接层中的激活函数, 并将全连接层维度降低到与图像展开的维度相等, 网络框架如图 29(a) 所示, 降低了网络训练参数量以重建更高维度的稀疏角度和有限角度 CT 图像, 其重建结果如图 30(a) 所示, 图像重建质量和速度都优于传统 FBP 与 SART 算法。Ma 等^[126]基于 AUTOMAP 框架与稀疏约束的非负矩阵分解(NMF)理论, 提出一种全自动重建网络(FARNet), 利用投影矩阵数值的非负特性, 使用 NMF 将投影矩阵近似分解为一系列低维矩阵, 从而降低全连接网络中隐藏层的维度, 同时在全连接层后附加了一个多尺度特征融合的 U-net, 进一步抑制稀疏角度重建下产生的噪声和伪影。

为解决 AUTOMAP 全连接层带来的开销与计算时间的消耗, Kalare 等^[127]提出一种基于级联 U-net 的深度重建网络, 直接使用全卷积网络对弦图进行重建以降低模型计算量。Mizusawa 等^[128]提出了一种基于

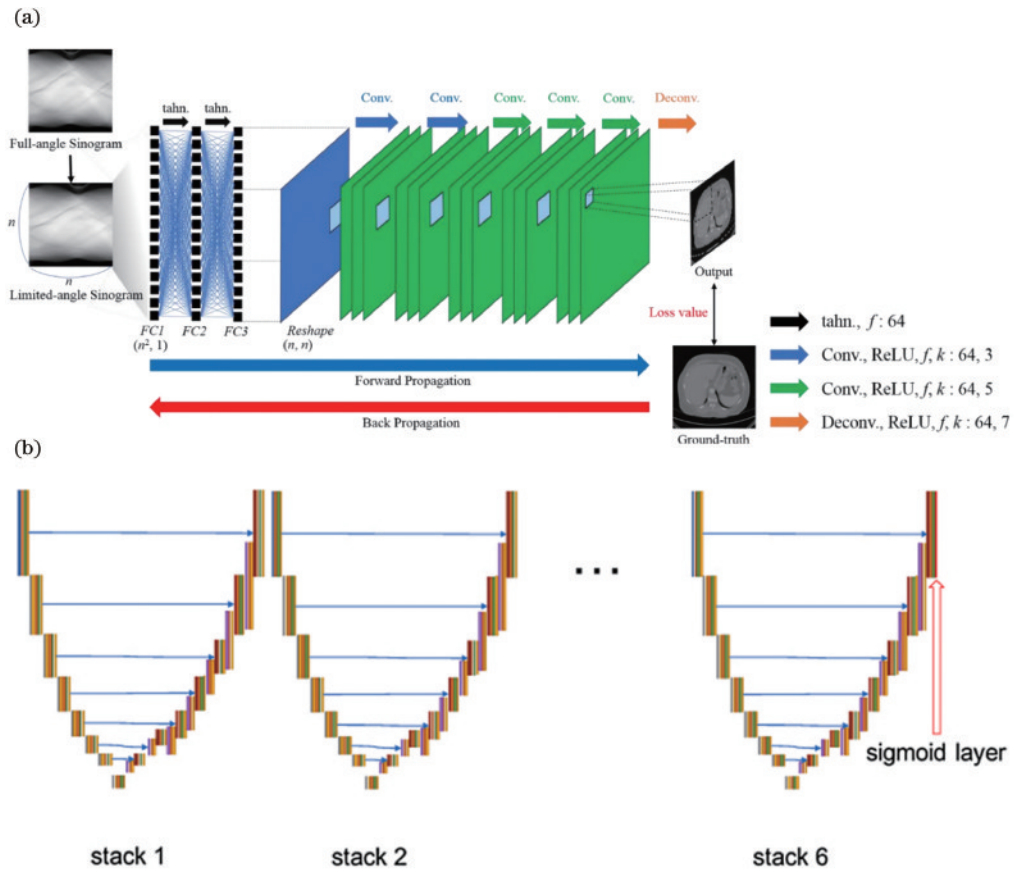


图 29 全学习重建模型。(a)基于全连接层的重建网络^[124-125];(b)基于堆叠U-net的重建网络^[128]
 Fig 29 Full-learning reconstruction model. (a) Reconstruction network based on fully connected layer^[124-125]; (b) reconstruction network based on stacked U-net^[128]




图 30 全学习重建模型重建结果。(a)文献[125]CT重建结果;(b)文献[128]CT重建结果
 Fig. 30 Reconstruction results of full-learning reconstruction models. (a) CT reconstruction results in Ref. [125]; (b) CT reconstruction results in Ref. [128]

堆叠 U-net 的端到端重建网络,如图 29(b)所示,在输入网络前将正弦图上采样至与 CT 图像尺寸一致,随后利用多个堆叠的 U-net 直接映射至同尺寸的 CT 图像。该网络由 6 个级联的 U-net 组成并且使用卷积层取代最大池化运算,避免细节结构的丢失。使用全卷积网络取代全连接层进行重建的方法能在保证 CT 重建质量的情况下在极短时间内实现 CT 重建,重建结果如图 30(b)所示,重建速度得到了提升。

8.2 基于可学习的物理解析算法的重建模型

利用数据驱动的学习方式结合神经网络构建的反投影解析算法可以很好结合两者优点,减少全连接层带来的模型内存占用大的问题,同时在 CNN 中融入物理指导过程。Wurfl 等^[129]利用 CNN 学习反投影算法中的权重值来改进 FBP 算法,网络中权重补偿模块可以消除正弦域中投影数据缺失产生的伪影。He 等^[130]根据滤波反投影机制,将 FBP 算法拆分为 3 个网络模块,构建了一个基于 CNN 近似 Radon 变换的反投影重建网络(iRadonMAP),如图 31(a)所示,其中模块一(FCF)使用全连接层代替斜坡滤波器对正弦图沿着旋转角度的数据进行一维卷积滤波,模块二(SBP)利用正弦域数据中满角度正弦曲线点与对应图像域数据中像素点之间的几何关系,建立了一个可学习的反投影层,而非使用全连接网络,保证了重建高分辨率 CT 图像的可行性,

模块三(rCNN)使用一个残差 CNN 对反投影后的图像进行进一步微调以提高稀疏角度 CT 图像重建的质量,重建结果如图 31(b)所示,所提出的可学习 FBP 算法的重建性能优于传统迭代算法与图像域后处理方法。在此基础上,He 等^[131]结合 CT 成像系统的几何建模过程和 CNN 提取的先验特征,通过在正弦图滤波网络中融入下采样成像几何模块,将真实数据的投影几何关系转换为虚拟成像关系,使得网络能够通过轻量级的反投影模块来实现快速和准确重建。Li 等^[132]同样参考 FBP 滤波反投影原理,设计一个从包含噪声的稀疏角度弦图到 CT 图像的重建网络(ICT-Net),在文献[130]基础上增加了卷积滤波模块对被噪声污染的正弦图进行滤波,随后才利用卷积模块和全连接层执行从正弦域到图像域的数据变换,最后设计具有可学习权重的模块代替 FBP 算法中的反投影求和操作。Xie 等^[133]类似地也提出了一种基于可调网络的反投影解析算法与 WGAN 模型相结合的端到端直接重建网络,利用 Radon 变换中线积分关系的约束对正弦域投影数据有限角度信息进行 CT 重建,网络反投影模块只需学习图像射线积分与弦图域中点数据的几何关系,其中 Wasserstein 距离损失提高了 GAN 模型训练的稳定性。基于可学习的解析算法的反投影模型相比只用全连接层模拟反投影的算法,进一步降低了网络计算空间的复杂度。

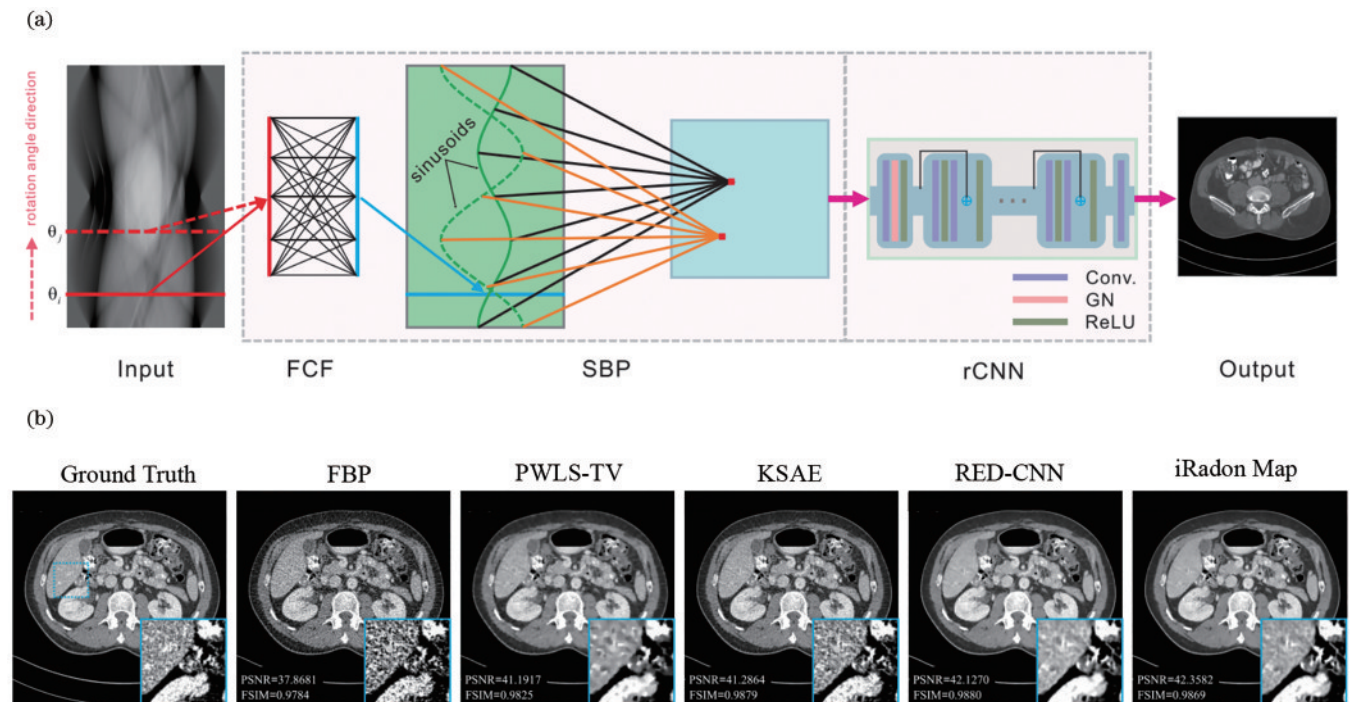


图 31 基于可学习的物理解析算法的重建模型及重建结果对比^[130]。(a) iRadonMAP 模型;(b) CT 重建结果对比
Fig. 31 Reconstruction model based on learnable physical analytic algorithm and comparison of reconstruction results^[130].

(a) iRadonMAP model; (b) comparison of CT reconstruction results

8.3 基于无监督和自监督的端到端重建模型

不依赖于标签数据的无监督端到端重建方法也受到关注。Zhou 等^[134]基于 GAN 提出一种端到端 CT 重

建网络(Tomo-GAN),Tomo-GAN 包括正弦域自适应 GAN(Sino-GAN)和重建 GAN(Recon-GAN)两个模块。仅利用模拟的弦图数据,使用无监督算法来训练

Tomo-GAN,从而预测真实的CT重建。Sino-GAN使用具有循环一致性的对抗网络,构建了与生成图像一致的正则项,从而将模拟的正弦数据转换至真实的正弦域中;Recon-GAN则通过循环GAN损失进行训练优化,通过无监督算法重建的CT图像的清晰度相比传统迭代算法要更高。

相比无监督算法,自监督算法可以进一步在不利用标签数据对网络进行完整训练条件下,通过迭代优化过程直接调整网络权重,实现对弦图数据的重建,进一步减轻网络对标签数据的依赖性并提高泛化性能。Liu等^[135]在文献[136]基础上结合空间转换网络,提出一种自监督稀疏角度反投影模型,模型中的CNN同样作为稀疏角度反投影结构,随后通过一个空间转换网络学习投影的仿射变换参数,将重建的图像转换为稀疏角度弦图,最后与原始弦图一起进行损失优化,从而实现无标签的自监督CT图像重建过程,并且使用的空间转换网络可以解决传感器在不同角度的非均匀性导致弦图数据产生噪声的问题,但由于网络结构和损失函数较为简单,恢复性能并不佳。Zang等^[137]更进一步结合了基于深度学习与基于模型重建的优点,提出

了一种基于自监督的合成正弦图和预测重建CT图像的框架(IntraTomo),如图32(a)所示,IntraTomo包括正弦图预测和图像优化两个模块。在CT图像预测模块,结合傅里叶特征投影层与全连接层,以自监督的方式直接将空间坐标值映射到重建图像密度场中,而非通过弦图进行映射重建;随后构建一个可微的投影模块得到完整的投影数据,进一步利用重建图像中的局部和全局先验信息结合凸优化算法对重建图像进行优化。相比传统迭代和深度先验重建方法,IntraTomo能够实现对采样角度数量更少的正弦图进行重建,结果如图32(b)所示。Kim等^[138]同样利用基于空间坐标的神经场表示方法,通过傅里叶特征映射得到CT图像值,同时进一步结合稀疏弦图的伪影特性对原始稀疏角度CT的伪影进行估计。不同于上述工作,通过对稀疏角度弦图建立自监督损失,Shu等^[139]利用测量弦图的反投影CT图作为无训练网络迭代的自监督标签,同时结合TV正则化对网络优化的CT图像进行约束和去噪,其中网络输入的潜在向量与网络权重同时被优化以增强网络生成能力,并为了减少迭代参数计算量,利用投影矩阵法向算子加速正反投影的计算过程。但

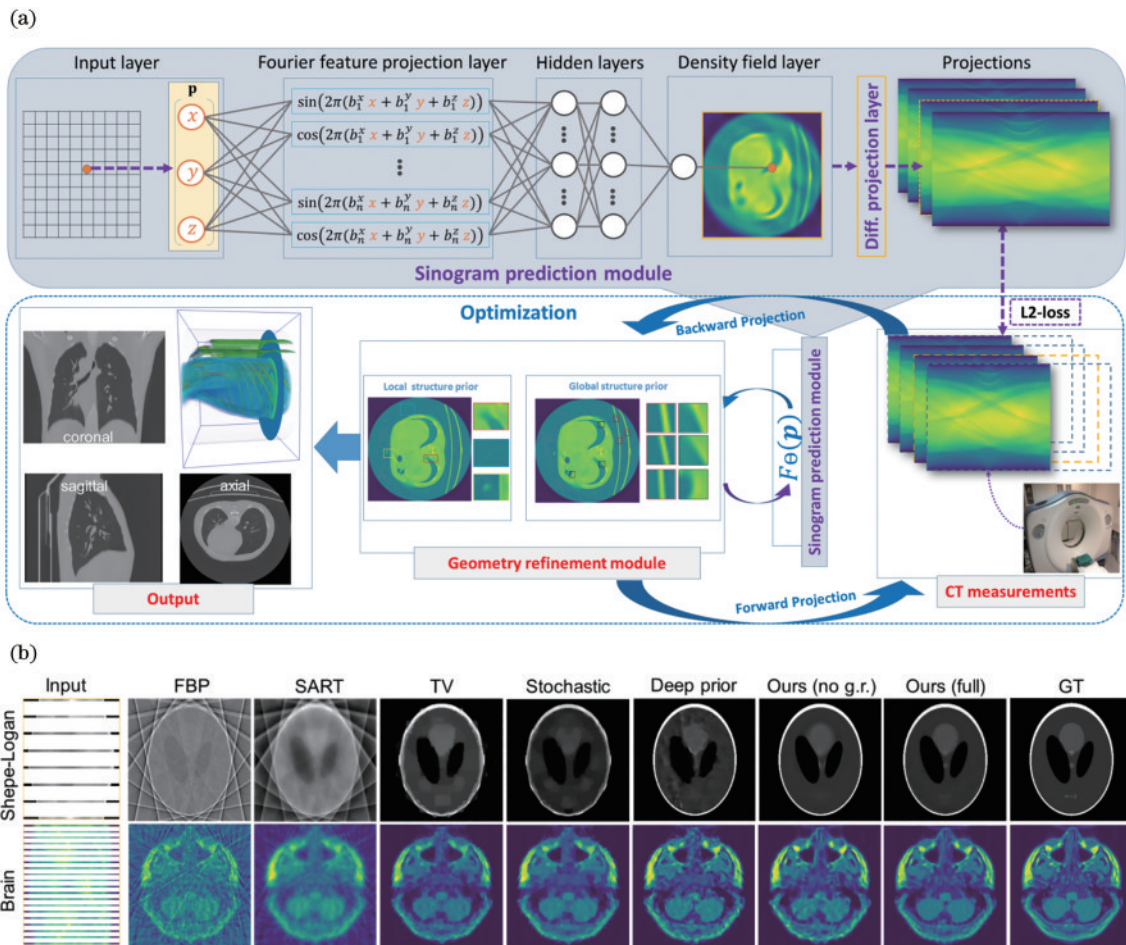


图 32 基于自监督的无训练投影重建模型及重建结果^[137]。(a)IntraTomo模型;(b)CT重建结果对比

Fig. 32 Self-supervised untrained projection reconstruction model and reconstruction results^[137]. (a) IntraTomo model; (b) comparison of CT reconstruction results

无训练网络需要通过多次优化迭代的方式对网络权重进行调整,仍然存在重建时间长的问题。

8.4 端到端映射重建方法总结

虽然基于 AUTOMAP 的重建模型可以在无需 CT 重建的专业知识前提下,直接从极端的稀疏或有限角度投影数据映射重建得到 CT 图像,但这种方法缺少物理解析重建指导过程,重建精度并不高。同时基于 AUTOMAP 的重建方法需要构建与投影矩阵维度相同的全连接层,这增加了模型所需的计算存储空间,无法重建分辨率较高的 CT 图像。而后续改进的基于 U-net 的域变换重建算法虽然减少了模型的计算开销,但相比单域、双域或者迭代重建算法,重建精度并不高。基于 CNN 的可学习式物理解析算法利用数

据驱动的训练方式学习反投影过程,以更新所设计的重建算法中的权重参数,相比基于 AUTOMAP 的黑盒学习形式,融合了物理重建过程,重建得到的图像质量要更高,并且利用的可学习的物理解析算法能够增强模型对不同稀疏或有限角度数据的重建的泛化能力。无训练网络利用自监督的方式实现对模型参数的优化训练,从而在不依赖标签数据的条件下对不同的输入数据调整网络的参数,在当前少数据的医学影像领域中具有明显的优势,但其存在迭代次数多导致重建时间长的问题,如何加快迭代速度仍然是一个需要进一步优化的难题。相比其他深度学习重建算法,结合 CNN 与 FBP 构建的可学习的端到端重建解析算法是平衡重建精度与速度的较优选择。表 11~13 对基

表 11 基于神经网络的全学习重建模型总结

Table 11 Summary of full-learning reconstruction model based on neural network

Reference	Network detail	Loss function	Dataset	Feature
[122]	Fully connected	MSE	Human FDG PET	Advantages: the algorithm design is simple to implement; does not require CT reconstruction expertise
[123]	Fully connected	MSE		
[124-125]	Fully connected	MSE	AAPM Low Dose CT	
[126]	Fully connected, residual learning, multi-channel fusion	MSE	TCGA-ESCA	Limitations: low reconstruction accuracy; large number of parameters in the fully connected layer
[127]	Skip connection	MSE	Shepp-Logan phantom, Forbild phantom	
[128]	Skip connection	MSE		

表 12 基于可学习的物理解析算法的重建模型总结

Table 12 Summary of reconstruction model based on learnable physical analytic algorithm

Reference	Network detail	Loss function	Dataset	Feature
[129]	Fully connected	MSE	AAPM Low Dose CT	Advantages: incorporates physical reconstruction process; reduced model parameters
[130]	Fully connected, residual learning	MSE	AAPM Low Dose CT	
[131]	Residual learning, upsampling and downsampling block	MSE	AAPM Low Dose CT	
[132]	Hard shrinkage operator, multi-channel fusion	MSE	Coronary artery, abdomen CT	Limitations: reconstruction accuracy and network structure need further optimization
[133]	Skip connection	SSIM loss, MAE, Wasserstein loss	Breast CT	

表 13 基于无监督或自监督的端到端重建模型总结

Table 13 Summary of unsupervised or self-supervised end-to-end reconstruction models

Reference	Network detail	Loss function	Dataset	Feature
[134]	Convolution-based	MSE	Multi-grain structures CT	Advantages: network training does not depend on label; greater generalization of self-supervised networks
[135]	LSTM, residual learning, skip connection	MSE, Profiles loss, GAN loss	AAPM Low Dose CT	
[137]	Fourier feature projection layer, full connected	MSE	Logan phantom, ATLAS, Covid-19, SL and LoDoPaB-CT, Pepper, Rose	Limitations: self-supervised network reconstruction process requires optimized weights resulting in long reconstruction time; the accuracy of untrained network reconstruction is still relatively low
[138]	Fourier feature projection layer, full connected	MSE	XCAT, AAPM Low Dose CT	
[139]	Convolution-based	MSE, TV loss	Shepp-Logan phantom, LIDC-IDRI, random ellipses	

于神经网络的全学习投影重建模型、基于可学习的物理解析算法的重建模型、基于无监督或自监督的端到端重建模型相关文献中所使用的网络细节结构、损失函数、数据集及算法的优点和局限性进行了总结。

9 分析与讨论

结构恢复性能是稀疏或有限角度 CT 重建不断提升的需求,本文综述了深度学习在稀疏或有限角度 CT 重建中相关研究工作的最新研究进展。相比传统图像滤波去伪影、弦图插值或者迭代重建算法,引入神经网络来增强 CT 图像结构的恢复取得更好效果,并在一定程度上克服了传统方法的局限,其优点如下。

1) 基于深度学习的图像域后处理方法通过建立基于数据驱动的神经网络模型,网络中卷积核或者 Transformer 中全连接层参数可以从标签 CT 图像的先验信息中得到学习填充,从而实现自适应滤波去伪影过程,相比传统手工设计的滤波函数,深度学习方法具有更强的伪影表征能力与泛化性。

2) 基于深度学习的正弦图插值方法同样能够通过设计的可学习卷积核实现对缺失的投影数据的自适应插值修复,相比传统的插值算法,其能够在标签弦图的全局信息中学习满角度弦图的全局数据分布特征,从而增强了在极端稀疏或有限角度弦图中的修复能力,最终能够实现更少角度的 CT 重建。

3) 基于深度学习的双域数据处理方法通过在网络嵌入可微分的 FBP 算法,实现端到端训练和测试重建,同时具有上面两种方法对数据保真度方面的优势,进一步提高了重建质量。

4) 基于深度学习的迭代重建方法通过利用数据驱动的神经网络模型嵌入 CT 图像的先验信息,避免

了传统迭代算法的正则项选择,同时也增强了模型的泛化能力,而在结合了凸优化算法的迭代算法中,进一步利用深度学习的强大非线性映射能力能够实现对非凸等子问题的求解,降低了迭代过程的计算复杂度并加快了传统 CT 迭代重建算法的收敛速度。

5) 基于深度学习的端到端映射方法将深度学习技术的优势引入到 FBP 算法的重建过程,构建了具有一定物理指导过程的自动流形映射重建算法,相比传统 FBP 算法,其通过数据驱动方式训练调整映射网络的结构参数,能够实现对稀疏或者有限角度 CT 的无伪影重建。

在以上讨论基础上,表 14 对 5 类方法的应用问题、使用到的网络主体结构、算法对应输入输出及优点和局限性进行了总结。由表 14 可见,U-net 是常用的网络结构,当前基于 U-net 的稀疏或有限角度 CT 重建已经有了许多成熟的应用,这是由于在医学图像领域中组织器官影像的结构具有对称和固定的特点,图像中没有特别丰富具有区分度的语义信息,所以在医学图像中高级语义信息和低级特征信息都比较重要,并且通常医学图像的数据并不容易获取,U-net 网络结构与深度相对比较简单,比较适用于数据集规模比较小的情况。随着深度学习的发展,Transformer 和 DDPM 等新的神经网络结构在稀疏或者有限角度 CT 重建中得到应用,相比 U-net 与 GAN,进一步提高了对 CT 图像的结构恢复性能。Transformer 中多头注意力机制可以提取图像的全局特征,实现长距离依赖关系建模,增强了网络对特征的表达能力,从而关注图像全局结构信息的恢复,但是在平衡 Transformer 本身的全局矩阵运算的成本开销和模型的恢复能力方面仍需要进一步研究。相比 GAN,

表 14 基于深度学习的稀疏或者有限角度 CT 重建应用

Table 14 Applications of sparse-view or limited-angle CT reconstruction based on deep learning

Application problem	Network structure	Input-Output	Advantage	Limitation
Image post-processing	FCN, GAN, U-net, Transformer, DDPM	CT-CT	Adaptive artifact removal; simple and doable	Lack of fidelity to the sinograms; MSE loss leads to structural ambiguity
Sinogram pre-processing	FCN, GAN, U-net	Sinogram-Sinogram	Adaptive interpolation; simple and doable	Lack of fidelity to CT images; may introduce tiny false structures
Dual-domain data processing	FCN, GAN, U-net, Transformer	Sinogram-CT	End-to-end reconstruction; dual-domain data fidelity	The existing model structure is relatively simple; increased amount of computation
Iterative reconstruction	FCN, GAN, U-net, Transformer	Sinogram/CT-CT	Reduce the computational complexity and labor experiment costs	The process of iterating multiple times cannot be avoided; the reconstruction time is still long
End-to-end mapping reconstruction	MLP, FCN, GAN, U-net	Sinogram-CT	MLP or CNN mapping method is simple to design; the learnable analytical reconstruction algorithm has a physical process guidance	MLP or CNN mapping methods lack physical reconstruction process and the reconstruction accuracy is not high

DDPM 在图像生成过程具有更高的稳定性,能够去除更多的伪影信息和生成更加丰富精确的细节结构,但是针对最大似然优化较差和采样重建次数较多的问题,仍需要进行进一步研究解决。

此外,在表 14 不同应用问题中,前面两种单一域的处理方法能够简单快速实现对 CT 图像伪影的去除,但这两种深度学习方法都缺乏对另一个域数据的保真度。双域数据联合处理方法则通过构建双损失函数对双域重建网络的输出进行约束,实现了对弦图和 CT 图像数据的同步保真,但相比单域方法,在一定程度上增加了模型的参数量和计算成本。深度学习迭代重建方法则在重建复杂度、迭代时间上得到进一步优化改进,但仍避免不了迭代优化过程。端到端映射重建则融合了物理解析算法和数据驱动的神经网络模型的优势,但基于简单的全连接层网络或自监督的映射方式仍然存在计算时间长的问题。相比迭代和端到端映射重建方法,基于双域数据联合处理的方法通过嵌入可微分的 FBP 算法作为正弦域到 CT 图像域数据变换的过渡层实现端到端重建,平衡了重建的速度与精度,能够更好地应用到实际的系统中。因此,在双域网络的基础上进一步融合基于神经网络直接重建的优势,通过无监督方式建立可学习的物理解析重建算法是一个值得深入探索的研究方向。

在现阶段中,深度学习的兴起为传统的重建方法提供了许多新的思路,许多研究工作都有效地解决了 CT 重建后图像视觉质量降低的问题,但是目前将深度学习技术应用在稀疏或有限角度 CT 重建中仍面临着诸多挑战。

1) 网络结构的设计和超参数的选择。基于深度学习的图像滤波去伪影和弦图插值方法为 CT 重建提供了高视觉性能基准的图像恢复方案,其中网络层数、卷积核数量和参数初始化选择是影响图像重建质量和结构恢复的关键因素。但由于网络的可解释性问题仍然没有得到解决,在设计网络结构时超参数的选择没有准确理论基准指导。因此,需要探索一种合适的机制来最优化网络模型的参数以提高稀疏或有限角度 CT 数据恢复的准确性。

2) 显存的占用和模型计算量。神经网络具备强大的非线性拟合和泛化能力,可以近似表示任何函数,但是在端到端 CT 重建问题中,当需要重建的 CT 图像分辨率较高时,若简单地使用全连接层作为稀疏或有限角度 CT 重建逆问题的映射函数,模型中全连接层会占用大量 GPU 显存而无法对网络进行训练,并且过大的模型同样不适用于实际临床 CT 系统。因此,在网络设计过程中需要考虑如何更好地将解析算法与神经网络模型结合起来构建反投影层,从而在提高重建图像质量的前提下能够解决模型内存消耗的问题。

3) 监督模型中数据量的需求。当前多数 CNN 在稀疏或有限角度 CT 重建中的应用都是有监督学习方

式,在实际应用场景中由于临床医学的 CT 系统的设置缺少配对的数据,并且患者个人隐私受到保护从而无法大量获取图像数据。针对此问题,迁移学习训练是一种可能的解决办法,利用公开的巨量图像数据集,如 ImageNet 等,对网络进行预训练,然后再使用 CT 图像对网络进行微调,更有利于网络模型的优化和 CT 图像的去噪去伪影。但是,在迁移学习过程中,相比自然图像,医学图像通常是细节和纹理更为丰富的低对比度图像,可能存在着预训练模型不适用于 CT 图像微调任务的问题。因此,需要考虑设计面向特定 CT 重建任务的预训练网络模型才能提高网络去噪去伪影性能。此外,同样可以使用自监督、半监督或者无监督学习方式减少网络训练对标签数据的依赖。

4) 损失函数的设计。在网络模型设计中,如果损失函数仅仅使用单一损失函数,如均方差(MSE)、平均绝对误差(MAE)等,会导致图像恢复时产生图像模糊现象。因此,在设计目标损失函数时,需考虑如何增加图像语义损失函数和感知损失函数等作为整体损失函数的正则项,进而能够较好地保留 CT 图像细节结构,避免图像模糊。

5) 模型泛化能力的提升。目前的临床医学应用中,绝大多数模型的设计都是针对特定的 CT 数据集的部分器官的,但在实际 CT 系统中,CT 图像重建会面临不同供应商设备、不同噪声级别和不同的器官内部解剖结构等差异。因此,考虑设计具有可推广性和泛化能力强的通用网络模型在临床应用中至关重要。

6) 评价指标的衡量。对于重建的 CT 图像,除了需要提高其视觉恢复性能外,还需要通过计算峰值信噪比和结构相似度来衡量其与参考图像之间的数据保真效果。现有的 Transformer 新结构能够在更少采样角度条件下重建得到令人接受的视觉效果,但定量指标仍比较低,因此需要进一步改进或优化 Transformer 结构,增强其对像素级别的 CT 结构特征的恢复能力同时解决图像降维导致特征信息丢失过多的问题,最终构建一种基于注意力的多重增强模型来提高数据保真度。

10 总 结

图像噪声、条状伪影、结构的模糊和丢失是稀疏或有限角度 CT 成像中不可避免的视觉退化问题,它们影响了对临床检测结果判断的准确性。深度学习技术为克服这些问题提供了许多解决方案,并展现出了比传统方法更具优势的重建效果。因此本文对深度学习技术在稀疏或者有限角度 CT 图像恢复中的图像域去伪影后处理、正弦图插值预处理、双域数据联合优化处理、迭代重建以及端到端直接映射重建的 5 类方面进行了综述分析,并按照不同结构网络与应用问题进行分类总结,最后探讨了现有相关研究的可能改进方

向以及面临挑战,希望为未来研究人员提出新的稀疏或者有限角度 CT 图像重建解决方案提供一定的研究思路,最终提高深度学习技术在辅助稀疏或者有限角度 CT 图像诊断应用中的准确性。

参 考 文 献

- [1] Brenner D J, Hall E J. Computed tomography: an increasing source of radiation exposure[J]. *The New England Journal of Medicine*, 2007, 357(22): 2277-2284.
- [2] Ciompi F, Chung K, van Riel S J, et al. Towards automatic pulmonary nodule management in lung cancer screening with deep learning[J]. *Scientific Reports*, 2017, 7(1): 1-11.
- [3] Hall E J, Brenner D J. Cancer risks from diagnostic radiology[J]. *The British Journal of Radiology*, 2008, 81(965): 362-378.
- [4] Smith B D. Image reconstruction from cone-beam projections: necessary and sufficient conditions and reconstruction methods[J]. *IEEE Transactions on Medical Imaging*, 1985, 4(1): 14-25.
- [5] Shepp L A, Logan B F. The Fourier reconstruction of a head section[J]. *IEEE Transactions on Nuclear Science*, 1974, 21(3): 21-43.
- [6] 李印生, 陈阳, 马建华, 等. 基于自适应方向性滤波和非局部均值修补的 CT 图像金属伪影消除[J]. *中国生物医学工程学报*, 2011, 30(3): 377-381.
Li Y S, Chen Y, Ma J H, et al. Metal artifact reduction in CT based on adaptive steering filter and nonlocal sinogram inpainting[J]. *Chinese Journal of Biomedical Engineering*, 2011, 30(3): 377-381.
- [7] Yuan Y, Zhang Y B, Yu H Y. Adaptive nonlocal means method for denoising basis material images from dual-energy computed tomography[J]. *Journal of Computer Assisted Tomography*, 2018, 42(6): 972-981.
- [8] Geraldo R J, Cura L M V, Cruvinel P E, et al. Low dose CT filtering in the image domain using MAP algorithms[J]. *IEEE Transactions on Radiation and Plasma Medical Sciences*, 2017, 1(1): 56-67.
- [9] Zhang H, Sonke J J. Directional sinogram interpolation for sparse angular acquisition in cone-beam computed tomography[J]. *Journal of X-Ray Science and Technology*, 2013, 21(4): 481-496.
- [10] Kim G, Park C, Lee D, et al. Analytic computed tomography reconstruction in sparse-angular sampling using a sinogram-normalization interpolation method[J]. *Journal of the Korean Physical Society*, 2018, 73(3): 361-367.
- [11] Zeng G L. Sparse-view tomography via displacement function interpolation[J]. *Visual Computing for Industry, Biomedicine, and Art*, 2019, 2(1): 13.
- [12] Gordon R. A tutorial on art (algebraic reconstruction techniques)[J]. *IEEE Transactions on Nuclear Science*, 1974, 21(3): 78-93.
- [13] Rudin L I, Osher S. Total variation based image restoration with free local constraints[C]//*Proceedings of 1st International Conference on Image Processing*, November 13-16, 1994, Austin, TX, USA. New York: IEEE Press, 2002: 31-35.
- [14] Buades A, Coll B, Morel J M. A review of image denoising algorithms, with a new one[J]. *Multiscale Modeling & Simulation*, 2005, 4(2): 490-530.
- [15] LaRoque S J, Sidky E Y, Pan X C. Accurate image reconstruction from few-view and limited-angle data in diffraction tomography[J]. *Journal of the Optical Society of America. A, Optics, Image Science, and Vision*, 2008, 25(7): 1772-1782.
- [16] Chen Z J, Qi H L, Jin Y, et al. Sparse-view computed tomography reconstruction using an improved non-local means[J]. *Journal of Medical Imaging and Health Informatics*, 2015, 5(8): 1910-1914.
- [17] Altaf F, Islam S M S, Akhtar N, et al. Going deep in medical image analysis: concepts, methods, challenges, and future directions[J]. *IEEE Access*, 2019, 7: 99540-99572.
- [18] 李昆鹏. 基于卷积神经网络的 CT 重建算法研究[D]. 太原: 中北大学, 2022.
Li K P. Research on CT reconstruction algorithm based on convolutional neural network[D]. Taiyuan: North University of China, 2022.
- [19] 拉斐尔·C. 冈萨雷斯, 理查德·E. 伍兹. 数字图像处理[M]. 阮秋琦, 阮宇智, 译. 4 版. 北京: 电子工业出版社, 2020.
Gonzalez R C, Woods R E. Digital image processing[M]. Ruan Q Q, Ruan Y Z, Transl. 4th ed. Beijing: Electronic Industry Press, 2020.
- [20] Kak A C, Slaney M, Wang G. Principles of computerized tomographic imaging[J]. *Medical Physics*, 2002, 29(1): 107.
- [21] Kulathilake K A S H, Abdullah N A, Sabri A Q M, et al. A review on deep learning approaches for low-dose computed tomography restoration[J]. *Complex & Intelligent Systems*, 2021: 1-33.
- [22] Chauhan R, Ghanshala K K, Joshi R C. Convolutional neural network (CNN) for image detection and recognition [C]//2018 First International Conference on Secure Cyber Computing and Communication (ICSCCC), December 15-17, 2018, Jalandhar, India. New York: IEEE Press, 2019: 278-282.
- [23] Chen J W, Chen J W, Chao H Y, et al. Image blind denoising with generative adversarial network based noise modeling[C]//2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition, June 18-23, 2018, Salt Lake City, UT, USA. New York: IEEE Press, 2018: 3155-3164.
- [24] Ren S Q, He K M, Girshick R, et al. Faster R-CNN: towards real-time object detection with region proposal networks[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2017, 39(6): 1137-1149.
- [25] LeCun Y, Bottou L, Bengio Y, et al. Gradient-based learning applied to document recognition[J]. *Proceedings of the IEEE*, 1998, 86(11): 2278-2324.
- [26] Krizhevsky A, Sutskever I, Hinton G E. ImageNet classification with deep convolutional neural networks[J].

- Communications of the ACM, 2017, 60(6): 84-90.
- [27] Simonyan K, Zisserman A. Very deep convolutional networks for large-scale image recognition[EB/OL]. (2014-09-04)[2022-10-08]. <https://arxiv.org/abs/1409.1556>.
- [28] Szegedy C, Liu W, Jia Y Q, et al. Going deeper with convolutions[C]//2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), June 7-12, 2015, Boston, MA, USA. New York: IEEE Press, 2015.
- [29] He K M, Zhang X Y, Ren S Q, et al. Deep residual learning for image recognition[C]//2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), June 27-30, 2016, Las Vegas, NV, USA. New York: IEEE Press, 2016: 770-778.
- [30] Huang G, Liu Z, van der Maaten L, et al. Densely connected convolutional networks[C]//2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), July 21-26, 2017, Honolulu, HI, USA. New York: IEEE Press, 2017: 2261-2269.
- [31] Hu J, Shen L, Albanie S, et al. Squeeze-and-excitation networks[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2020, 42(8): 2011-2023.
- [32] Woo S, Park J, Lee J Y, et al. CBAM: convolutional block attention module[M]//Ferrari V, Hebert M, Sminchisescu C, et al. Computer vision-ECCV 2018. Lecture notes in computer science. Cham: Springer, 2018, 11211: 3-19.
- [33] Shelhamer E, Long J, Darrell T. Fully convolutional networks for semantic segmentation[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2017, 39(4): 640-651.
- [34] Ronneberger O, Fischer P, Brox T. U-Net: convolutional networks for biomedical image segmentation[M]//Navab N, Hornegger J, Wells W M, et al. Medical image computing and computer-assisted intervention-MICCAI 2015. Cham: Springer, 2015, 9351: 234-241.
- [35] Goodfellow I, Pouget-Abadie J, Mirza M, et al. Generative adversarial networks[J]. Communications of the ACM, 2020, 63(11): 139-144.
- [36] Kazemini S, Baur C, Kuijper A, et al. GANs for medical image analysis[J]. Artificial Intelligence in Medicine, 2020, 109: 101938.
- [37] Dosovitskiy A, Beyer L, Kolesnikov A, et al. An image is worth 16×16 words: transformers for image recognition at scale[EB/OL]. (2020-10-22) [2022-11-09]. <https://arxiv.org/abs/2010.11929>.
- [38] Ho J, Jain A, Abbeel P. Denoising diffusion probabilistic models[C]//Proceedings of the 34th International Conference on Neural Information Processing Systems, December 6-12, 2020, Vancouver, BC, Canada. New York: ACM Press, 2020: 6840-6851.
- [39] Frikel J, Quinto E T. Characterization and reduction of artifacts in limited angle tomography[J]. Inverse Problems, 2013, 29(12): 125007.
- [40] 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.
- [41] Gu J, Ye J C. Multi-scale wavelet domain residual learning for limited-angle CT reconstruction[EB/OL]. (2017-03-04)[2022-11-08]. <https://arxiv.org/abs/1703.01382>.
- [42] 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.
- [43] Lee M, Kim H, Kim H J. Sparse-view CT reconstruction based on multi-level wavelet convolution neural network[J]. Physica Medica, 2020, 80: 352-362.
- [44] Mustafa W, Kehl C, Olsen U L, et al. Sparse-view spectral CT reconstruction using deep learning[EB/OL]. (2020-11-30)[2022-10-09]. <https://arxiv.org/abs/2011.14842>.
- [45] 张艳娇, 乔志伟. 基于多残差UNet的CT图像高精度稀疏重建[J]. 计算机应用, 2021, 41(10): 2964-2969.
- Zhang Y J, Qiao Z W. High-precision sparse reconstruction of CT images based on multiply residual UNet[J]. Journal of Computer Applications, 2021, 41(10): 2964-2969.
- [46] Wang J X, Liang J, Cheng J Y, et al. Deep learning based image reconstruction algorithm for limited-angle translational computed tomography[J]. PLoS One, 2020, 15(1): e0226963.
- [47] Jiang Z R, Chen Y X, Zhang Y W, et al. Augmentation of CBCT reconstructed from under-sampled projections using deep learning[J]. IEEE Transactions on Medical Imaging, 2019, 38(11): 2705-2715.
- [48] Liao H F, Huo Z M, Sehnert W J, et al. Adversarial sparse-view CBCT artifact reduction[M]//Frangi A F, Schnabel J A, Davatzikos C, et al. Medical image computing and computer assisted intervention-MICCAI 2018. Lecture notes in computer science. Cham: Springer, 2018, 11070: 154-162.
- [49] 黄锦威, 萧文鹏, 朱思婷, 等. 基于对抗训练的U-Net神经网络在稀疏投影CT图像增强的应用[J]. 中国医学物理学杂志, 2020, 37(5): 612-618.
- Huang J W, Xiao W P, Zhu S T, et al. Application of adversarial training-based U-Net neural network in the enhancement of CT images obtained by sparse projection [J]. Chinese Journal of Medical Physics, 2020, 37(5): 612-618.
- [50] 杜聪聪, 乔志伟, 张艳娇, 等. 用于CT稀疏重建的对抗式多残差深度神经网络改进方法[J]. 中国体视学与图像分析, 2021, 26(2): 145-154.
- Du C C, Qiao Z W, Zhang Y J, et al. Sparse-view CT reconstruction based on an adversarial multi-residual deep neural network[J]. Chinese Journal of Stereology and Image Analysis, 2021, 26(2): 145-154.
- [51] Isola P, Zhu J Y, Zhou T H, et al. Image-to-image translation with conditional adversarial networks[C]//2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), July 21-26, 2017, Honolulu, HI, USA. New York: IEEE Press, 2017: 5967-5976.
- [52] Hegazy M A A, Cho M H, Lee S Y. Half-scan artifact correction using generative adversarial network for dental CT[J]. Computers in Biology and Medicine, 2021, 132: 104313.

- [53] Xie H D, Shan H M, Wang G. Deep encoder-decoder adversarial reconstruction(DEAR) network for 3D CT from few-view data[J]. *Bioengineering*, 2019, 6(4): 111.
- [54] Yang L, Zhang Z L, Song Y, et al. Diffusion models: a comprehensive survey of methods and applications[EB/OL]. (2022-09-02)[2022-11-09]. <https://arxiv.org/abs/2209.00796>.
- [55] Liu J M, Anirudh R, Thiagarajan J J, et al. DOLCE: a model-based probabilistic diffusion framework for limited-angle CT reconstruction[EB/OL]. (2022-11-22)[2023-01-02]. <https://arxiv.org/abs/2211.12340>.
- [56] Song Y, Shen L Y, Xing L, et al. Solving inverse problems in medical imaging with score-based generative models[EB/OL]. (2021-11-15) [2022-08-09]. <https://arxiv.org/abs/2111.08005>.
- [57] Zhang Z C, Liang X K, Dong X, et al. A sparse-view CT reconstruction method based on combination of DenseNet and deconvolution[J]. *IEEE Transactions on Medical Imaging*, 2018, 37(6): 1407-1417.
- [58] Xie S P, Zheng X Y, Chen Y, et al. Artifact removal using improved GoogLeNet for sparse-view CT reconstruction[J]. *Scientific Reports*, 2018, 8(1): 1-9.
- [59] Shen T C, Li X, Zhong Z S, et al. R²-Net: recurrent and recursive network for sparse-view CT artifacts removal [M]//Shen D G, Liu T M, Peters T M, et al. *Medical image computing and computer assisted intervention-MICCAI 2019. Lecture notes in computer science*. Cham: Springer, 2019, 11769: 319-327.
- [60] Zhou H C, Zhu Y N, Wang Q, et al. Multi-scale dilated convolution neural network for image artifact correction of limited-angle tomography[J]. *IEEE Access*, 2019, 8: 1567-1576.
- [61] Shen T C, Yang Y B, Lin Z C, et al. Recurrent learning with clique structures for prostate sparse-view CT artifacts reduction[J]. *IET Image Processing*, 2021, 15(3): 648-655.
- [62] Yang Y B, Zhong Z S, Shen T C, et al. Convolutional neural networks with alternately updated clique[C]//2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition, June 18-23, 2018, Salt Lake City, UT, USA. New York: IEEE Press, 2018: 2413-2422.
- [63] Qian Y F, Xie S P, Zhuang W Q, et al. Sparse-view CT reconstruction based on improved re-sidual network[M]//Okada H, Atluri S N. *Computational and experimental simulations in engineering. Mechanisms and machine science*. Cham: Springer, 2020, 75: 1069-1080.
- [64] Fu Z Y, Tseng H W, Vedantham S, et al. A residual dense network assisted sparse view reconstruction for breast computed tomography[J]. *Scientific Reports*, 2020, 10(1): 1-16.
- [65] Xie S P, Yang T. Artifact removal in sparse-angle CT based on feature fusion residual network[J]. *IEEE Transactions on Radiation and Plasma Medical Sciences*, 2021, 5(2): 261-271.
- [66] Zhang F Q, Zhang M H, Qin B J, et al. REDAEP: robust and enhanced denoising autoencoding prior for sparse-view CT reconstruction[J]. *IEEE Transactions on Radiation and Plasma Medical Sciences*, 2021, 5(1): 108-119.
- [67] Jiang Z R, Zhang Z Y, Chang Y S, et al. Prior image-guided cone-beam computed tomography augmentation from under-sampled projections using a convolutional neural network[J]. *Quantitative Imaging in Medicine and Surgery*, 2021, 11(12): 4767-4780.
- [68] Han K, Wang Y H, Chen H T, et al. A survey on vision transformer[EB/OL]. (2020-12-23)[2022-11-09]. <https://arxiv.org/abs/2012.12556>.
- [69] Zhang Y K, Hu D L, Yan Z H, et al. TIME-Net: transformer-integrated multi-encoder network for limited-angle artifact removal in dual-energy CBCT[J]. *Medical Image Analysis*, 2023, 83: 102650.
- [70] Lee H, Lee J, Cho S. View-interpolation of sparsely sampled sinogram using convolutional neural network[J]. *Proceedings of SPIE*, 2017, 10133: 1013328.
- [71] Lee H, Lee J, Kim H, et al. Deep-neural-network-based sinogram synthesis for sparse-view CT image reconstruction[J]. *IEEE Transactions on Radiation and Plasma Medical Sciences*, 2018, 3(2): 109-119.
- [72] Cao G H, Vekhande S, Dong X. Sinogram interpolation for sparse-view micro-CT with deep learning neural network[J]. *Proceedings of SPIE*, 2019, 10948: 1094820.
- [73] 温静, 乔志伟. 正弦图智能插值法 CT 稀疏重建[J]. *核电子学与探测技术*, 2021, 41(6): 1125-1131.
- Wen J, Qiao Z W. Sparse CT reconstruction with sinogram intelligent interpolation[J]. *Nuclear Electronics & Detection Technology*, 2021, 41(6): 1125-1131.
- [74] Dong J B, Fu J, He Z. A deep learning reconstruction framework for X-ray computed tomography with incomplete data[J]. *PLoS One*, 2019, 14(11): e0224426.
- [75] Fu J, Dong J B, Zhao F. A deep learning reconstruction framework for differential phase-contrast computed tomography with incomplete data[J]. *IEEE Transactions on Image Processing*, 2020, 29(1): 2190-2202.
- [76] Anirudh R, Kim H, Thiagarajan J J, et al. Lose the views: limited angle CT reconstruction via implicit sinogram completion[C]//2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition, June 18-23, 2018, Salt Lake City, UT, USA. New York: IEEE Press, 2018: 6343-6352.
- [77] Bai J N, Dai X B, Wu Q J, et al. Limited-view CT reconstruction based on autoencoder-like generative adversarial networks with joint loss[J]. *Annual International Conference of the IEEE Engineering in Medicine and Biology Society*, 2018, 2018: 5570-5574.
- [78] Dai X B, Bai J N, Liu T L, et al. Limited-view cone-beam CT reconstruction based on an adversarial autoencoder network with joint loss[J]. *IEEE Access*, 2018, 7: 7104-7116.
- [79] Li Z H, Zhang W K, Wang L Y, et al. A sinogram inpainting method based on generative adversarial network for limited-angle computed tomography[J]. *Proceedings of SPIE*, 2019, 11072: 1107220.

- [80] Li Z H, Cai A L, Wang L Y, et al. Promising generative adversarial network based sinogram inpainting method for ultra-limited-angle computed tomography imaging[J]. *Sensors*, 2019, 19(18): 3941.
- [81] Mirza M, Osindero S. Conditional generative adversarial nets[EB/OL]. (2014-11-06) [2022-11-09]. <https://arxiv.org/abs/1411.1784>.
- [82] Liu J C, Li J W. Sparse-sampling CT sinogram completion using generative adversarial networks[C]//2020 13th International Congress on Image and Signal Processing, BioMedical Engineering and Informatics (CISP-BMEI), October 17-19, 2020, Chengdu, China. New York: IEEE Press, 2020: 640-644.
- [83] Ghani M U, Karl W C. Deep learning-based sinogram completion for low-dose CT[C]//2018 IEEE 13th Image, Video, and Multidimensional Signal Processing Workshop (IVMSP), June 10-12, 2018, Aristi Village, Greece. New York: IEEE Press, 2018.
- [84] Yuan H Z, Jia J Z, Zhu Z X. SIPIID: a deep learning framework for sinogram interpolation and image denoising in low-dose CT reconstruction[C]//2018 IEEE 15th International Symposium on Biomedical Imaging (ISBI 2018), April 4-7, 2018, Washington, DC, USA. New York: IEEE Press, 2018: 1521-1524.
- [85] Lee D, Choi S, Kim H J. High quality imaging from sparsely sampled computed tomography data with deep learning and wavelet transform in various domains[J]. *Medical Physics*, 2019, 46(1): 104-115.
- [86] Liang K C, Yang H K, Xing Y X. Comparison of projection domain, image domain, and comprehensive deep learning for sparse-view X-ray CT image reconstruction [EB/OL]. (2018-04-12) [2022-11-09]. <https://arxiv.org/abs/1804.04289>.
- [87] Zhou B, Chen X C, Zhou S K, et al. DuDoDR-Net: dual-domain data consistent recurrent network for simultaneous sparse view and metal artifact reduction in computed tomography[J]. *Medical Image Analysis*, 2022, 75: 102289.
- [88] Wang W, Xia X G, He C J, et al. An end-to-end deep network for reconstructing CT images directly from sparse sinograms[J]. *IEEE Transactions on Computational Imaging*, 2020, 6: 1548-1560.
- [89] Jiao F Y, Gui Z G, Li K P, et al. A dual-domain CNN-based network for CT reconstruction[J]. *IEEE Access*, 2021, 9: 71091-71103.
- [90] Zhang Y K, Lü T L, Ge R J, et al. CD-net: comprehensive domain network with spectral complementary for DECT sparse-view reconstruction[J]. *IEEE Transactions on Computational Imaging*, 2021, 7: 436-447.
- [91] Amirrashedi M, Sarkar S, Ghadiri H, et al. A deep neural network to recover missing data in small animal pet imaging: comparison between sinogram- and image-domain implementations[C]//2021 IEEE 18th International Symposium on Biomedical Imaging (ISBI), April 13-16, 2021, Nice, France. New York: IEEE Press, 2021: 1365-1368.
- [92] Hu D L, Liu J, Lü T L, et al. Hybrid-domain neural network processing for sparse-view CT reconstruction[J]. *IEEE Transactions on Radiation and Plasma Medical Sciences*, 2021, 5(1): 88-98.
- [93] Çiçek Ö, Abdulkadir A, Lienkamp S S, et al. 3D U-Net: learning dense volumetric segmentation from sparse annotation[M]//Ourselin S, Joskowicz L, Sabuncu M R, et al. Medical image computing and computer-assisted intervention-MICCAI 2016. Lecture notes in computer science. Cham: Springer, 2016, 9901: 424-432.
- [94] Han Y, Kang J G, Ye J C. Deep learning reconstruction for 9-view dual energy CT baggage scanner[EB/OL]. (2018-01-04) [2022-11-08]. <https://arxiv.org/abs/1801.01258>.
- [95] Zheng A, Gao H W, Zhang L, et al. A dual-domain deep learning-based reconstruction method for fully 3D sparse data helical CT[J]. *Physics in Medicine and Biology*, 2020, 65(24): 245030.
- [96] Zhao Z W, Sun Y W, Cong P. Sparse-view CT reconstruction via generative adversarial networks[C]//2018 IEEE Nuclear Science Symposium and Medical Imaging Conference Proceedings (NSS/MIC), November 10-17, 2018, Sydney, NSW, Australia. New York: IEEE Press, 2019.
- [97] Ketola J H J, Heino H, Juntunen M A K, et al. Generative adversarial networks improve interior computed tomography angiography reconstruction[J]. *Biomedical Physics & Engineering Express*, 2021, 7(6): 065041.
- [98] Xie E, Ni P J, Zhang R F, et al. Limited-angle CT reconstruction with generative adversarial network sinogram inpainting and unsupervised artifact removal[J]. *Applied Sciences*, 2022, 12(12): 6268.
- [99] Wang C, Shang K, Zhang H M, et al. DuDoTrans: dual-domain transformer provides more attention for sinogram restoration in sparse-view CT reconstruction[EB/OL]. (2021-11-21) [2022-11-09]. <https://arxiv.org/abs/2111.10790>.
- [100] Shi C R, Xiao Y S, Chen Z Q. Dual-domain sparse-view CT reconstruction with Transformers[J]. *Physica Medica*, 2022, 101: 1-7.
- [101] Li R R, Li Q, Wang H X, et al. DDPTransformer: dual-domain with parallel transformer network for sparse view CT image reconstruction[J]. *IEEE Transactions on Computational Imaging*, 2022, 8: 1101-1116.
- [102] Pan J Y, Zhang H Y, Wu W F, et al. Multi-domain integrative Swin Transformer network for sparse-view tomographic reconstruction[J]. *Patterns*, 2022, 3(6): 100498.
- [103] 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.
- [104] 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.
- [105] Hammernik K, Würfl T, Pock T, et al. A deep learning architecture for limited-angle computed tomography

- reconstruction[M]//Bildverarbeitung für die Medizin 2017. Informatik aktuell. Heidelberg: Springer, 2017: 92-97.
- [106] Cheng W L, Wang Y, Li H W, et al. Learned full-sampling reconstruction from incomplete data[J]. *IEEE Transactions on Computational Imaging*, 2020, 6: 945-957.
- [107] Wang J X, Zeng L, Wang C X, et al. ADMM-based deep reconstruction for limited-angle CT[J]. *Physics in Medicine and Biology*, 2019, 64(11): 115011.
- [108] Xia W J, Yang Z Y, Zhou Q Z, et al. A transformer-based iterative reconstruction model for sparse-view CT reconstruction[M]//Wang L W, Dou Q, Fletcher P T, et al. Medical image computing and computer assisted intervention-MICCAI 2022. Lecture notes in computer science. Cham: Springer, 2022, 13436: 790-800.
- [109] 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.
- [110] Zhang H M, Dong B, Liu B D. JSR-net: a deep network for joint spatial-radon domain CT reconstruction from incomplete data[C]//2019 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP), May 12-17, 2019, Brighton, UK. New York: IEEE Press, 2019: 3657-3661.
- [111] Chun I Y, Huang Z 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*, 2020: 32750839.
- [112] 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.
- [113] Bubba T A, Kutyniok G, Lassaras M, et al. Learning the invisible: a hybrid deep learning-shearlet framework for limited angle computed tomography[J]. *Inverse Problems*, 2019, 35(6): 064002.
- [114] Genzel M, Macdonald J, MärZ M, et al. Near-exact recovery for tomographic inverse problems via deep learning[C]//39th International Conference on Machine Learning, July 17-23, 2022, Baltimore, Maryland, USA. Cambridge: PMLR, 2022, 162: 7368-7381.
- [115] 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.
- [116] Wu W W, Hu D L, Niu C, et al. DRONE: dual-domain residual-based optimization network for sparse-view CT reconstruction[J]. *IEEE Transactions on Medical Imaging*, 2021, 40(11): 3002-3014.
- [117] Zhou B, Zhou S K, Duncan J S, et al. Limited view tomographic reconstruction using a cascaded residual dense spatial-channel attention network with projection data fidelity layer[J]. *IEEE Transactions on Medical Imaging*, 2021, 40(7): 1792-1804.
- [118] 陈高宇, 黄秋. 基于融合解析迭代重建网络的高效稀疏投影 CT 重建算法[J]. *中国体视学与图像分析*, 2021, 26(2): 163-172.
- Chen G Y, Huang Q. An efficient CT reconstruction algorithm based on the fused analytical iterative reconstruction network for sparse projections[J]. *Chinese Journal of Stereology and Image Analysis*, 2021, 26(2): 163-172.
- [119] Wu D F, Kim K, El Fakhri G, et al. Iterative low-dose CT reconstruction with priors trained by artificial neural network[J]. *IEEE Transactions on Medical Imaging*, 2017, 36(12): 2479-2486.
- [120] Zhang M H, Zhang F Q, Liu Q G, et al. Sparse-view CT reconstruction via robust and multi-channels autoencoding priors[C]//Proceedings of the 2nd International Symposium on Image Computing and Digital Medicine, October 13-14, 2018, Chengdu, China. New York: ACM Press, 2018: 55-59.
- [121] Chun I Y, Fessler J A. Convolutional analysis operator learning: application to sparse-view CT (Invited Paper) [C]//2018 52nd Asilomar Conference on Signals, Systems, and Computers, October 28-31, 2018, Pacific Grove, CA, USA. New York: IEEE Press, 2019: 1631-1635.
- [122] Zhu B, Liu J Z, Cauley S F, et al. Image reconstruction by domain-transform manifold learning[J]. *Nature*, 2018, 555(7697): 487-492.
- [123] Zhang Q Y, Liang D. Visualization of fully connected layer weights in deep learning CT reconstruction[EB/OL]. (2020-02-17) [2022-11-08]. <https://arxiv.org/abs/2002.06788>.
- [124] Yim D, Kim B, Lee S. Limited-angle CT reconstruction via data-driven deep neural network[J]. *Proceedings of SPIE*, 2021, 11595: 115952V.
- [125] Yim D, Lee S, Nam K, et al. Deep learning-based image reconstruction for few-view computed tomography[J]. *Nuclear Instruments and Methods in Physics Research Section A: Accelerators, Spectrometers, Detectors and Associated Equipment*, 2021, 1011: 165594.
- [126] Ma G W, Zhu Y N, Zhao X. Learning image from projection: a full-automatic reconstruction (FAR) net for computed tomography[J]. *IEEE Access*, 2020, 8: 219400-219414.
- [127] Kalare K W, Bajpai M K. RecDNN: deep neural network for image reconstruction from limited view projection data[J]. *Soft Computing*, 2020, 24(22): 17205-17220.
- [128] Mizusawa S, Sei Y, Orihara R, et al. Computed tomography image reconstruction using stacked U-Net[J]. *Computerized Medical Imaging and Graphics*, 2021, 90: 101920.
- [129] Wurfl T, Hoffmann M, Christlein V, et al. Deep learning computed tomography: learning projection-domain weights from image domain in limited angle problems[J]. *IEEE Transactions on Medical Imaging*, 2018, 37(6): 1454-1463.

- [130] He J, Wang Y B, Ma J H. Radon inversion via deep learning[J]. *IEEE Transactions on Medical Imaging*, 2020, 39(6): 2076-2087.
- [131] He J, Chen S L, Zhang H, et al. Downsampled imaging geometric modeling for accurate CT reconstruction via deep learning[J]. *IEEE Transactions on Medical Imaging*, 2021, 40(11): 2976-2985.
- [132] Li Y S, Li K, Zhang C Z, et al. Learning to reconstruct computed tomography images directly from sinogram data under a variety of data acquisition conditions[J]. *IEEE Transactions on Medical Imaging*, 2019, 38(10): 2469-2481.
- [133] Xie H D, Shan H M, Cong W X, et al. Deep efficient end-to-end reconstruction (DEER) network for few-view breast CT image reconstruction[J]. *IEEE Access*, 2020, 8: 196633-196646.
- [134] Zhou B, Lin X Y, Eck B. Limited angle tomography reconstruction: synthetic reconstruction via unsupervised sinogram adaptation[M]//Chung A C S, Gee J C, Yushkevich P A, et al. *Information processing in medical imaging. Lecture notes in computer science*. Cham: Springer, 2019, 11492: 141-152.
- [135] Liu X Q, Sajda P. Unsupervised sparse-view backprojection via convolutional and spatial transformer networks[EB/OL]. (2020-06-01) [2022-11-09]. <https://arxiv.org/abs/2006.01658>.
- [136] Ye D H, Buzzard G T, Ruby M, et al. Deep back projection for sparse-view CT reconstruction[C]//2018 IEEE Global Conference on Signal and Information Processing (GlobalSIP), November 26-29, 2018, Anaheim, CA, USA. New York: IEEE Press, 2019.
- [137] Zang G M, Idoughi R, Li R, et al. IntraTomo: self-supervised learning-based tomography via sinogram synthesis and prediction[C]//2021 IEEE/CVF International Conference on Computer Vision (ICCV), October 10-17, 2021, Montreal, QC, Canada. New York: IEEE Press, 2022: 1940-1950.
- [138] Kim B, Shim H, Baek J. A streak artifact reduction algorithm in sparse-view CT using a self-supervised neural representation[J]. *Medical Physics*, 2022, 49(12): 7497-7515.
- [139] Shu Z Y, Entezari A. Sparse-view and limited-angle CT reconstruction with untrained networks and deep image prior[J]. *Computer Methods and Programs in Biomedicine*, 2022, 226: 107167.