

分类号：TP391

密 级：公开

学校代码：10363

学 号：2220910108



安徽工程大学

Anhui Polytechnic University

硕士学位论文

题 目 面向低剂量双能CT的深度学习
式成像方法研究

论 文 作 者 吴凡
校 内 导 师 刘进（副教授）
校 外 导 师 郑亮（工程师）
专业学位类别 计算机技术
研究方向（领域） 智能系统与应用

论文提交日期： 2025 年 5 月 9 日

分类号：TP391

单位代码：10363

密 级：公开

学 号：2220910108

题 目 面向低剂量双能 CT 的深度学习式成像方法研究

英文并列

题 目 Research on Deep Learning-Based Imaging Methods for
Low-Dose Dual-Energy Computed Tomography

学生姓名： 吴凡

校内导师： 刘进（副教授）

校外导师： 郑亮（工程师）

专业学位类别： 计算机技术

研究方向（领域）： 智能系统与应用

论文答辩日期： 2025 年 5 月 10 日

安徽工程大学学位论文原创性声明

本人郑重声明：我恪守学术道德，崇尚严谨学风。所呈交的学位论文，是本人在导师的指导下，独立进行研究工作所取得的成果。除文中已明确注明和引用的内容外，本论文不包含任何其他个人或集体已经发表或撰写过的作品及成果的内容。论文为本人亲自撰写，我对所写的内容负责，并完全意识到本声明的法律后果由本人承担。

学位论文作者签名：吴凡

日期：2025年5月9日

安徽工程大学学位论文版权使用授权书

学位论文作者完全了解学校有关保留、使用学位论文的规定，同意学校保留并向国家有关部门或机构送交论文的复印件和电子版，允许论文被查阅或借阅。本人授权安徽工程大学可以将本学位论文的全部或部分内容编入有关数据库进行检索，可以采用影印、缩印或扫描等复制手段保存和汇编本学位论文。

保密 ☐，在 ____ 年解密后适用本版权书。

本学位论文属于

不保密 ☒.

学位论文作者签名：吴凡

日期：2015年5月9日

指导教师签名：21巴

日期：2015年5月9日

面向低剂量双能 CT 的深度学习式成像方法研究

摘 要

双能计算机断层成像 (Dual-energy CT, DECT) 通过对获得的两个不同能量区间数据利用基材料分解数学模型进行基材料分解, 重建出了基材料图像以及物质的有效原子序数和电子密度图。相比于传统 CT 成像, 双能 CT 图像重建技术可以提供关于组织成分和对比剂分布的定性和定量信息, 目前双能 CT 已经广泛应用于肾结石表征, 碘定量检查等诸多临床诊断中, 具有重要的临床诊断意义。然而, 目前的双能 CT 基材料图像分解任务主要面临着两个方面的问题: ①由于双能 CT 需要对患者进行两次扫描, 会给患者的健康带来潜在的风险, 如儿童、孕妇和敏感个体, 对辐射更为敏感。同时, 双能 CT 扫描通常需要大量的时间和资源, 包括设备使用时间和成本。②受双能 CT 图像的噪声影响, 分解后的基材料图像噪声会进一步放大, 导致分解精度下降, 基材料图像中出现与噪声相关的伪影, 影响后续诊断任务。为了解决因投影数据不足造成 DECT 图像噪声和 DECT 基材料分解产生的噪声放大问题, 论文将对 DECT 稀疏重建和基材料分解技术展开介绍与研究, 主要的研究工作和创新点体现在:

(1) 对稀疏角度下的 DECT 图像重建问题、DECT 图像基材料分解问题以及相关理论知识进行了详细分析论述, 并对怎样有效提高稀疏角度 DECT 重建和 DECT 基材料分解过程中的精确度问题的方法进行了深入研究。同时对相关方法进行了实验验证, 分析该相关方法性能的优劣, 总结稀疏角度 DECT 图像重建和 DECT 图像基材料分解过程中需要注意的关键性问题。

(2) 稀疏角度 DECT 图像中呈现的伪影水平具有较大差异, 单一图像空间先验约束难以取得满意的效果。为此本论文研究了一种基于混合光谱数据生成扩散模型的 DECT 稀疏重建策略。首先, 小波变换通过将图像分解为多频分量, 将其作为先验约束引入生成扩散模型, 能够捕捉复杂细节。通过利用小波变换先验特征, 采用基于小波空间随机微分方程 (Stochastic Differential Equation, SDE) 的生成扩散模型

作为约束，以改进稀疏视图 DECT 重建。此外，为了减轻小波空间 SDE 中单个采样引起的不一致，在图像空间中采用了辅助 SDE。然后，将迭代过程展开到神经网络中，并用可训练的 SDE 替换手动构建的约束组件的梯度。在模型推理阶段，使用不完全互补稀疏视图低能和高能 CT 图像作为输入，以利用 DECT 图像独有的光谱数据一致性。定性和定量的结果显示，所建立的网络模型能够有效地压制各种层次的伪影与噪声，并最大限度地保持原始影像的细节。

(3) 双能计算机断层成像可以实现不同材料的区分，对低剂量重建后图像进行基材料分解可能存在噪声放大问题，其基材料分解质量及准确度有待进一步提升。为此，本论文采用一种基于多通道交叉卷积 UCTransNet 网络 (Multi-channel Cross-convolution UCTransNet, MC-UCTransNet) 的图像域双材料分解方法。该网络以 UCTransNet 为基础架构，设计成双输入双输出端到端的映射形式。其采用通道交叉融合变压器和通道交叉注意模块来更好地捕捉复杂的通道式相关性，实现基材料生成路径之间的信息交换。注意到 CT 图像数据分布的独特性，提出采用基于 Sigmoid 函数的归一化方法对 CT 图像数据进行归一化处理，降低数据的偏度和峰度。损失函数使用 MAE 和 SSIM 组成的混合损失函数，从而保证了分解精度和基材料图像的细节结构重建性能。实验结果表明，在骨骼基材料及软组织碘基材料分解任务中，与对比方法相比，所提方法分解后的基材料图像在准确度及噪声伪影抑制上表现更好。

关键词：双能 CT，图像重建，基材料分解，稀疏角度，图像空间，小波空间

RESEARCH ON DEEP LEARNING-BASED IMAGING METHODS FOR LOW-DOSE DUAL-ENERGY COMPUTED TOMOGRAPHY

ABSTRACT

Dual-energy computed tomography (DECT) utilizes data obtained from two different energy ranges to perform material decomposition using mathematical models, reconstructing material images along with effective atomic numbers and electron density maps. Compared to traditional CT imaging, DECT image reconstruction technology provides qualitative and quantitative information about tissue composition and contrast agent distribution. DECT has been widely applied in clinical diagnoses such as characterization of kidney stones and iodine quantification, demonstrating significant clinical diagnostic value. However, the current DECT material image decomposition task faces two main challenges: 1. DECT requires two scans of the patient, which may pose potential health risks, especially for children, pregnant women, and sensitive individuals who are more susceptible to radiation. Additionally, DECT scanning typically requires substantial time and resources, including equipment usage time and costs. 2. The noise in DECT images can be amplified during the decomposition process, leading to reduced accuracy in the reconstructed material images and the appearance of noise-related artifacts, which can affect subsequent diagnostic tasks. To address the issues of noise in DECT images and the amplification of noise in DECT material decomposition caused by insufficient projection data, this thesis will introduce and study DECT sparse reconstruction and material decomposition techniques. The main work and research innovation are as follows:

(1) A detailed analysis and discussion were conducted on the issues of DECT image reconstruction under sparse views, DECT image basis material decomposition, and related theoretical knowledge. In-depth research was carried out on methods to effectively improve the accuracy

of sparse-view DECT reconstruction and DECT basis material decomposition. Furthermore, relevant methods were experimentally validated, their performance advantages and disadvantages were analyzed, and key issues to be considered in the process of sparse-view DECT image reconstruction and DECT image basis material decomposition were summarized.

(2) In sparse view DECT images, the level of artifacts varies significantly, and a single image space prior constraint may not yield satisfactory results. To address this, this dissertation proposes a DECT sparse reconstruction strategy based on hybrid spectrum data generative diffusion model. Firstly, wavelet transform decomposes an image into multi-frequency components, and by incorporating it as a prior constraint into the generative diffusion model, it can capture intricate details. By leveraging the prior features of wavelet transform, a generative diffusion model based on wavelet-space Stochastic Differential Equation (SDE) is employed as a constraint to improve sparse-view DECT reconstruction. Additionally, to mitigate inconsistencies caused by single sampling in the wavelet space SDE, an auxiliary SDE is used in the image space. The iterative process is then integrated into a neural network, replacing the gradients of manually constructed constraint components with trainable SDEs. During model inference, incomplete complementary sparse view low-energy and high-energy CT images are used as inputs to leverage the unique spectral data consistency of DECT images. Qualitative and quantitative results demonstrate that the established network model effectively suppresses artifacts and noise at various levels while maximizing the preservation of the original image details.

(3) DECT can distinguish between different materials, but performing material decomposition on low-dose reconstructed images may lead to noise amplification issues. The quality and accuracy of material decomposition need further improvement. To this end, this dissertation adopts a dual-material decomposition method in the image domain based on a multi-channel cross-convolution UCTransNet network (MC-UCTransNet). The network is based on the UCTransNet architecture and is designed as an end-to-end mapping with dual input and dual output. It

employs channel cross-fusion transformers and channel cross-attention modules to better capture complex channel-related correlations, facilitating information exchange between the generation pathways of base materials. Recognizing the unique distribution of CT image data, a normalization method based on the sigmoid function is proposed to normalize CT image data, thereby reducing skewness and kurtosis. The loss function is composed of a mixed loss function using MAE and SSIM, ensuring the accuracy of decomposition and the detail structure reconstruction of base material images. Experimental results indicate that in the decomposition tasks for bone-based materials and soft tissue iodine-based materials, the proposed method outperforms the comparative methods in terms of accuracy and noise artifact suppression.

KEY WORDS: dual-energy ct, image reconstruction, base material decomposition, sparse view, image space, wavelet space

目 录

摘 要.....	I
ABSTRACT.....	III
目 录.....	VI
第 1 章 绪论.....	1
1.1 研究背景及意义.....	1
1.2 国内外研究现状.....	3
1.2.1 低剂量 DECT 图像重建	3
1.2.2 双能 CT 基材料图像分解	6
1.3 论文主要工作.....	8
1.4 论文章节安排.....	9
第 2 章 DECT 成像与基材料图像分解理论	10
2.1 CT 成像的数理基础	10
2.1.1 X 射线的产生.....	10
2.1.2 X 射线的衰减规律.....	11
2.2 DECT 图像重建技术	12
2.2.1 DECT 重建理论	12
2.2.2 深度重建算法.....	13
2.3 DECT 基材料图像分解理论	20
2.3.1 双效应图像分解模型.....	20
2.3.2 基材料图像分解模型.....	22
2.4 本章小结.....	23
第 3 章 基于混合谱数据生成扩散模型的 DECT 稀疏重建	24
3.1 稀疏 DECT 重建模型	24
3.1.1 交错角度扫描协议.....	24
3.1.2 数学重建模型.....	25
3.2 HSGDM 模型及优化过程	27
3.2.1 基于 SDE 的生成扩散模型	27
3.2.2 混合谱数据生成扩散模型.....	28
3.2.3 模型优化过程.....	30
3.3 实验结果与分析.....	33
3.3.1 实验设置.....	33
3.3.2 重建结果.....	35
3.3.3 超参数分析.....	40

3.3.4 混合约束消融实验.....	41
3.4 本章小结.....	42
第 4 章 基于多通道交叉卷积 UCTransNet 的 DECT 基材料图像分解方法.....	44
4.1 分解模型与 MC-UCTransNet 网络设计.....	44
4.1.1 图像域基材料图像分解模型.....	44
4.1.2 网络架构.....	45
4.1.3 混合损失函数.....	47
4.2 数据准备.....	48
4.2.1 基材料图像标签与 DECT 图像获取	48
4.2.2 数据预处理.....	50
4.3 实验结果与分析.....	50
4.3.1 基材料图像分解实验结果.....	50
4.3.2 网络设计消融实验.....	57
4.3.3 网络收敛性与复杂性分析.....	60
4.4 本章小结.....	61
第 5 章 总结与展望.....	63
5.1 论文总结.....	63
5.2 研究展望.....	64
参考文献.....	66
攻读学位期间发表的学术成果.....	72
致 谢.....	73

第 1 章 绪论

1.1 研究背景及意义

X 射线计算机断层扫描（Computed Tomography, CT）作为一种重要的医学影像技术，在临床诊疗中发挥着不可替代的作用。该技术能够快速获取解剖学与病理生理学数据，具有较高的成像速度和优异的空间分辨率，显著提升了疾病诊断的准确性与时效性。然而，CT 扫描过程中产生的电离辐射可能对人体产生负面影响，其中高剂量辐射暴露与肿瘤发生及遗传物质损伤存在关联性。在许多国家，CT 检查已被认为是造成医源性辐射最主要的辐射源^[1]。为此，国际辐射防护机构制定了 ALARA（As Low As Reasonably Achievable）原则，强调在保证影像质量与诊断效能的同时，应最大限度地降低辐射剂量。




图 1-1 当前常用的降低 CT 辐射剂量方法

Fig. 1-1 Common Methods for Reducing CT Radiation Dose

如图 1-1 所示，当前 CT 扫描过程中减少 X 射线辐射量的技术路径可分为设备优化与投影模式革新两大类。在设备优化方面，主要技术手段包含调整 X 射线发生装置的电流电压参数、增大螺旋 CT 的螺距设置以及扩大准直器孔径等^[2]。特别是通过调节 X 射线发生装置的电流电压参数，因其操作简便且效果显著，已成为降低辐射剂量的首选方案。但需要指出的是，当管电流参数下调时，穿过被检测物体并抵达探测装置的光子数量将相应减少，这会使获取的投影数据受到噪声干扰的程度加剧。至于管电压的降低，其显著后果是削弱了 X 射线的穿透性能，进而影响重建图像的信噪比，不利于疾病的准确识别。在投影模式革新方

面，主要采用有限角度采集、均匀与不均匀稀疏采样等技术手段。这些方法由于在数据采集过程中存在角度缺失，往往会导致重建图像产生显著的条状伪影，若不进行有效的数据修复，将难以满足临床诊断需求。由此可见，在低辐射条件下提升重建图像的质量水平，已成为该领域亟待解决的关键技术难题。

传统 CT 重建技术采用全光谱 X 射线的平均衰减效应进行成像，这一方法在临床应用中存在显著局限性。首先，由于低能光子更易被物质（材料）吸收，导致探测器接收到的 X 射线平均能量偏高，进而引起重建图像失真。特别是在原子质量较大的物质（如骨骼或金属植入物）附近，这种效应更加明显，容易产生射束硬化伪影，进一步降低图像质量^[3]。其次，传统 CT 成像技术面临另一个重要挑战是异物同形现象，即不同化学成分的组织可能呈现相同的衰减系数。这一现象严重阻碍了组织结构的有效区分，尤其是在需要鉴别相似密度但不同成分组织的临床场景中，如肿瘤与正常组织的区分。双能 CT 这一概念最早由 Alvarez 和 Macovski 于 1976 年提出，其核心原理是通过采集两个独立能量区间的 CT 数据进行基材料图像分解，从而重建出基材料图像、有效原子序数图和电子密度图等定量信息^[4]。相较于常规 CT 成像，DECT 技术不仅能够提供组织成分和对比剂分布的定性和定量信息，还可以生成虚拟单能图、碘基图和虚拟非增强图等多种衍生图像，从而显著提升疾病诊断的可靠性和准确性。在 DECT 成像过程中，基材料图像分解是至关重要的一个步骤。探测得到的两个不同能量区间数据信息需要通过基材料图像分解算法才能实现对不同组织的分离以及分析。目前 DECT 成像方法主要分为两大类^[5]：（1）首先，对双能投影数据进行基材料分解，随后再进行图像重建。该技术将每条射线路径的投影数据转换为与两种基材料特性相关的非能量依赖性分量，通过重建过程获取各基材料的原子序数及电子密度参数，从而实现组织成分的鉴别。尽管该方法能有效抑制射束硬化效应，但对双能投影数据的匹配精度要求较高，且对硬件配置具有较大的依赖性。（2）先重建出双能条件下的线性衰减系数，再基于像素点实施基材料分解。该技术直接对重建图像进行处理，不受探测器性能的制约，具有良好的普适性，已成为当前 DECT 基材料分解的主流方法。然而，X 射线所具有的宽能谱特性为图像重建带来了挑战，具体而言，由于射线束硬化效应的影响，重建得到的线性衰减系数可能会出现误差，在接下来的基材料分解阶段，这些误差可能会被放大，从而影响分解结果的

精确度。因此，在图像重建的基础上进行基材料分解，同时有效控制误差传播并提升分解精度，已成为 DECT 成像领域的一个重要研究热点和难点。

综上所述，论文聚焦于 CT 成像领域的前沿挑战，重点探讨了低剂量 DECT 图像重建与基材料分解的关键技术。基于 DECT 重建与基材料分解的理论框架，研究首先采用深度学习算法对低剂量 DECT 图像进行降噪处理。通过整合 DECT 多能量谱数据间的关联特性，成功将含噪数据还原至近似常规剂量下的 DECT 图像质量。随后，研究利用改进型 U-Net 网络架构与混合损失函数，在图像域层面实现了基材料图像的精确分解，有效解决了传统分解方法中的误差放大问题。最终实现了低剂量条件下 DECT 基材料图像的高精度分解，对 DECT 成像技术的发展起到了一定的促进作用。

1.2 国内外研究现状

1.2.1 低剂量 DECT 图像重建

双能计算机断层扫描被认为是一种具有广阔应用前景的技术，它在物质成分分析、骨密度测定和无损检测等多个领域都展现出了巨大的潜力。DECT 系统利用两个不同能量的 X 射线光谱来提高成像能力。这种双光谱成像技术依赖于线性衰减系数随能量变化的特性，这对于区分不同类型的组织起着至关重要的作用。目前，已经开发了多种数据采集硬件策略，如图 1-2 所示。一种是在一次扫描中从两个不同的 X 射线源收集投影数据，例如双源 CT 系统（Somatom Definition，西门子）和快速 kVp 切换 CT 系统（Discovery CT750）。另一种策略通过使用单一 X 射线源获得投影数据，而能量投影由双层探测器或光子计数器探测器单独收集^[6-7]。另外，与辐射相关的风险仍然是 CT 扫描中的一个主要问题，这也激发了人们对于降低 CT 扫描辐射剂量的兴趣^[8]。减少采样视角（即稀疏视图）的数量可以降低患者的辐射暴露。然而，使用传统方法重建稀疏视图扫描通常会受到伪影的严重影响。对于 DECT 系统而言，值得注意的是，低能量和高能量图像中所描绘的解剖结构表现出显著的一致性。这种一致性表明成像数据中存在大量相似的光谱信息。通过利用这种相似性以及图像中固有的空间域一致性，有可能提升 DECT 成像的质量，尤其是在稀疏扫描场景中^[9-10]。




图 1-2 不同 DECT 技术的几何图：（a）快速 kVp 切换 CT；（b）双源 CT；（c）双层探测器 CT。

Fig. 1-2 Geometrical Diagrams of Different DECT Technologies: (a) Rapid kVp Switching CT; (b) Dual Source CT; (c) Dual Layer Detector CT.

为了提升 DECT 图像的质量，研究人员已经开发了众多专门针对从稀疏视图投影数据重建的图像重建技术。这些技术主要通过利用相似数据中丰富的先验知识，并设计特定的约束条件来减少噪声和条状伪影。例如，Zhao 等引入了一种基于紧密帧的迭代重建技术，该技术在稀疏光谱乳腺 CT 中实现了卓越的图像质量^[11]。鉴于基于张量的方法在利用不同能量图像之间的相关性方面的有效性，Semerci 等设计了一种包含张量核范数正则化的迭代算法^[12]。为了进一步提高光谱 CT 重建的性能，Li 等引入了一种空间-光谱非局部均值约束方法，该方法利用了空间域和光谱域内的冗余信息^[13]。Zhang 等提出了平均图像诱导非局部均值（Average Image-induced Nonlocal Means, aviNLM）滤波器，旨在利用能量域内信息的相似性来减轻 DECT 图像中噪声诱导的伪影^[14]。Wu 等将图像梯度的 L0 范数整合到张量字典学习（Tensor Dictionary Learning, TDL）中，用于低剂量光谱 CT 重建，显著抑制了图像伪影和噪声^[15-16]。Hu 等提出了一种基于光谱-图像相似性的张量字典增强稀疏性重建方法，旨在提高稀疏视图多能量 CT 成像的准确性^[17]。He 等设计了一种基于 split-Bregman 框架的迭代算法，将低秩相关表示和结构特征提取器作为约束条件^[18]。然而，大多数迭代重建方法的性能受到手工正则化和相关超参数选择的限制。此外，这些方法的高计算需求也对它们的临床部署和应用构成了挑战。

最近，深度学习（Deep Learning, DL）方法在生物医学成像和 CT 图像重建领域展现出了卓越的性能。例如，Chen 等提出了一种用于低剂量 CT 去噪的解剖感知监督对比学习框架（Anatomical Supervised Contrastive Learning, ASCON），该框架融合了基于自注意力机制的 U-Net 和多尺度解剖造影网络^[19]，通过将结

构特异性深度神经网络封装在统计迭代重建框架中,显著提升了 CT 重建的性能。这种改进可以通过在迭代重建阶段利用预训练模型作为正则化项来实现,或者通过优化展开方法,将其中每个迭代步骤都通过卷积神经网络(Convolutional Neural Network, CNN)进行模拟。He 等将投影信息纳入未折叠交替方向乘子法(Unfolded Alternating Direction Method of Multipliers, ADMM)框架中,实现了高质量、低剂量的 CT 重建^[20]。Chen 等提出了一种 LEARN 重建方法,该方法将迭代过程展开为残差 CNN,以提高稀疏重建的性能^[21]。Zhang 等用神经网络替换迭代框架中的正则化项进行 DECT 成像,利用自先验投影和从互补信息中获得的图像来训练该网络,使网络能够从这些扫描中固有的补充信息中学习^[22]。Xiang 等通过解开快速迭代收缩阈值算法设计了 FISTA-Net,有效解决了医学成像中的病态重建问题^[23]。Zhang 等将预训练网络作为先验图像约束集成到稀疏视图 CT 重建的先验图像约束(Prior Image Constrained Compressed Sensing, PICCS)框架中^[24]。Wu 等通过关注和细化改进了稀疏视图 CT 的深度嵌入网络^[25]。Liu 等设计了一种深度残差约束重建模型,该模型使用卷积稀疏编码网络来改进低剂量 CT 成像^[26]。Xia 等设计了一种名为 RegFormer 的新型模型,旨在进行稀疏视图 CT 重建,该模型结合了可学习的局部和非局部正则化技术^[27]。Kang 等从群稀疏性先验中汲取灵感,设计了一个可解释的重建网络来改进特征表示^[28]。尽管这些方法实现了有希望的重建性能和一定的模型透明度,但由于与 DECT 相关的特定数据特性,提高其重建性能的潜力仍然相当大。

基于分数的生成模型(Score-based Generative Models, SGM)在 CT 重建领域取得了显著进展,为生成高质量 CT 图像提供了新的视角和有前途的途径。针对 CT 成像中常见的数据不一致问题,Chung 等创新性地将扩散模型与基于模型的迭代重建相结合,开发了一个扩散 MBIR 网络。这种开创性的模型利用了迭代重建框架中扩散建模的强大功能,显示了在提升图像质量所具有的巨大潜力。Guan 等提出了一种在正弦图域中工作的生成模型 GMSD,用于捕获先验信息;并将其与数据一致性步骤集成,以实现有效的稀疏迭代重建^[29]。Xia 等设计了一种去噪扩散概率模型 DDPM,该模型基于贴片图像块技术,旨在从稀疏视图投影中重建 CT 图像^[30]。Liu 等提出了一种将先验概率模型集成到重建框架中的新方法 DOLCE,为 CT 成像提供了新的视角^[31]。此外,Xia 等通过引入三维空间中子体积概念扩展了去噪扩散概率模型,从而增强了其应用范围和能力^[32]。为了解决

现有求解器中的误差累积的问题, Chung 等在流形约束理论的启发下创造性地提出了一个补充修正项。这一附加组件对于减少传统求解器的错误非常有效^[33]。在他们的后续研究中, Lee 等进一步扩展了扩散求解器的应用范围, 使其能够处理含噪的线性逆问题^[34]。这些开创性的工作证明了 SGM 在 CT 重建方法中的应用价值, 并凸显了其卓越的优势。Liu 等利用 SGM 生成的多能量和组织图像, 基于材料分解优化框架生成造影剂图像^[35]。Li 等开发了一种用于图像空间数据的无监督评分生成模型, 即 UISG, 用于低剂量 CT 重建。该模型在高频稀疏变换之前通过投影一致性步骤整合了扩散过程, 以实现高保真度的图像重建^[36]。Fernsel 等在渐进优化框架中应用 SGM 解决了非凸重建优化问题, 并取得了更优的结果^[37]。尽管如此, 目前的方法在 CT 重建中仍面临一些挑战。例如, 在处理不同类型组织和不同级别噪声伪影时, 这些方法的适应性可能会受到限制。此外, 它们通常难以恢复复杂的结构细节, 并需要进一步提高噪声伪影去除的有效性。大量研究已经表明, 统计迭代重建中的先验约束机制通常对于提高重建质量至关重要。

1.2.2 双能 CT 基材料图像分解

自从 DECT 的概念被提出后, DECT 基材料图像分解算法一直是该领域的研究热点。现有的 DECT 基材料图像分解方法可分为 3 类: 直接重建分解法、基于投影域的分解方法和基于图像域的分解方法^[38]。直接重建分解方法是直接从两个 X 射线能谱上收集数据来重建基图像, 但该类方法的计算复杂度高, 且分解结果受参数的影响大。基于投影域的分解方法能够较好地补偿投影域材料分解过程中的非线性效应, 并能较好地修正射线束硬化伪影, 但高度依赖于测量投影的空间几何一致性, 这对双源和快速切换 DECT 等成像设备来说是一个挑战。基于图像域的分解方法首先从两个测量数据集单独或联合重建出双能量图像, 然后通过重建图像的线性组合形成基图像, 具有灵活性高的优势。但受高低能 CT 图像的噪声影响^[39], 分解后的基材料图像噪声会进一步放大, 导致分解精度下降, 基材料图像中出现与噪声相关的伪影, 从而影响后续诊断任务。基于图像域的基材料分解中, 传统的矩阵反演算法对于输入的重建图像噪声敏感, 会显著降低基材料图像的信噪比^[40-41]。为此, Zhao 等通过将边缘保持滤波器与局部高分辨率约束反投影重建相结合, 间接降低了分解图像的噪声水平^[42]。Heo 等使用块匹配和 3D

滤波去噪算法实现对分解图像的降噪^[43]。Lee 等将全变分去噪方法应用于分解的预处理和后处理过程,以达到噪声抑制的效果^[44]。Xue 等通过引入负对数似然项和边缘保持正则化来提升基材料分解后的图像质量^[45]。Harms 等利用图像像素之间的相似性正则化来平滑图像并抑制噪声,并通过保留更均匀的噪声功率谱来提高分解效果^[46]。Li 等通过预先学习不同材料的共享特征和交叉依赖关系来提升基材料分解质量^[47]。降俊汝等利用字典学习技术来挖掘基图像之间的稀疏性和关联性,以进一步降低基材料的噪声和伪影^[48]。Ding 等考虑到图像域不同材料图像具有共同或互补的边缘先验信息,提出一种稀疏正则化方法,用于对材料组成进行约束^[49]。总的来说,该类基于迭代正则化的方法在分解过程的迭代时间过长^[50],分解效率低,难以准确描述基材料图像之间的映射关系。卷积神经网络的发展为 DECT 基材料图像分解研究提供了新的途径。Lantz 等提出一种基于 ADMM 的迭代展开方法,将神经网络作为初始化层和正则化器,获得了较高的基材料分解精度^[51]。王冲旭等在传统迭代分解的基础上,使用卷积神经网络代替正则化项,可有效抑制分解后图像的噪声^[52]。Li 等将基材料重建得到的低能图像与原始低能图像的差异作为先验项,可对先前的输出进行反馈和调整,该方法有效减少了材料边缘伪影,但存在超参数难调的问题^[53]。Xu 等提出一种由全卷积网络和全连接层组成的端到端分解双网络,可实现对高低能图像信息的分别提取,但在部分边缘结构的保持方面效果不佳^[54]。Zhang 等提出一种蝴蝶型网络结构,该网络是一种交叉结构,通过残差学习的交叉架构实现特征共享,可显著提升分解的基材料图像质量^[55]。Kawahara 等利用从 DECT 图像中重建的等效 kV 量级 CT 单能图像代替 DECT 图像作为生成对抗网络的输入来完成基材料分解^[56]。受蝴蝶型网络的启发,Shi 等提出一种 DIWGAN 模型,该模型使用两个 U-Net 作为生成器来分别提取特征,并在生成器的解码层以残差学习方式实现多层次特征融合,但该模型在软组织分解图中仍然存在少量的骨骼伪影^[57]。

综上所述,基于深度学习对 DECT 重建图像实现基材料图像分解是目前行之有效的办法。论文将使用深度学习网络模拟 DECT 基材料分解模型,使用 Transformer 模块捕捉双能 CT 图像通道信号相关性,充分利用不同能量区间信息的同时,进一步提高分解后基材料图像的质量以及分解精度,为后续医疗诊断提供精准参考。

1.3 论文主要工作

为降低 X 射线辐射风险而采用的低剂量 DECT 重建技术，在实际应用中面临噪声干扰和伪影增加的问题，这对医疗诊断的准确性产生了不利影响。基材料图像分解算法是 DECT 图像重建的核心环节，其分解精确度决定了该技术临床应用的可靠性。近年来，深度学习方法得益于其在特征提取和模型构建方面的优势，在低剂量 CT 图像重建和 DECT 基材料图像分解领域得到了广泛应用。本课题拟面向低剂量 DECT 图像重建领域，基于深度学习对低剂量 DECT 基材料图像分解技术进行研究。课题选自国家自然科学基金资助项目“多特征学习的肺部 4D-CBCT 优质重建研究”。论文主要研究内容分为以下两个方面：

(1) 低剂量 DECT 图像重建方面，大量研究表明，统计迭代的先验约束机制通常对于提高重建质量至关重要。稀疏角度 DECT 图像中呈现的伪影水平具有较大差异，单一图像域先验约束难以取得满意的效果。为此论文研究了一种基于混合光谱数据生成扩散模型的 DECT 稀疏重建策略，此部分研究将包括两部分：A. 小波变换通过将图像分解为多频分量来充当分析图像的强大工具，旨在捕获图像的复杂细节。而通过将小波变换作为生成结果的先验约束，它有效地增强了扩散模型的稳定性，确保了更稳定和可靠的性能。通过利用先验特征小波变换，采用基于小波域随机微分方程的生成扩散模型作为约束，以改进稀疏视图 DECT 重建。此外，为了减轻小波域 SDE 中单个采样引起的不一致，在图像域中采用了辅助 SDE。B. 将迭代过程展开到神经网络中，并用可训练的 SDE 替换手动构建的约束组件的梯度。在模型推理阶段，使用不完全互补稀疏视图低能和高能 CT 图像作为输入，以利用 DECT 图像独有的光谱数据一致性。

(2) DECT 基材料图像分解方面，在完成图像数据降噪的基础上，论文拟采用一种基于多通道交叉卷积 UCTransNet 网络的图像域双材料分解方法。该网络以 UCTransNet 为基础架构，采用通道交叉融合变压器和通道交叉注意模块来提高基材料分解性能，实现双输入双输出端到端的映射。网络中通道交叉融合模块和通道交叉注意模块可更好地捕捉复杂的通道式相关性，以更充分地进行特征提取与融合，实现基材料生成路径之间的信息交换。另外，考虑损失函数中使用混合损失函数，包括分解出的基材料图像与标签之间的损失以及分解出的基材料

图像经重建后得到的低能图像与原始低能图像之间的损失,从而保证分解基材料图像的准确性。

1.4 论文章节安排

论文主要有 5 章内容, 具体安排如下:

第 1 章, 分别介绍了 CT 领域目前的发展趋势以及论文的研究背景与意义。同时, 对低剂量 CT 图像重建以及 DECT 基材料图像分解技术的国内外研究现状以及目前所存在的技术难点做了详细的介绍与分析, 最后简述了论文的主要研究内容以及文章的整体结构安排。

第 2 章, 调研了 DECT 能量成像与基材料图像分解的基础理论。首先研究了 X 射线的产生及其衰减规律, 并重点研究了 DECT 重建技术, 然后对目前广泛研究的各种深度重建算法类型进行了详细介绍; 之后研究了 DECT 图像基材料图像分解理论并介绍了两种常用的 DECT 基材料图像分解模型。

第 3 章, 对基于混合谱数据生成扩散模型的稀疏角度 DECT 重建技术进行了研究。详细介绍了混合扩散模型稀疏重建流程, 其中包括小波空间扩散模型先验项以及图像空间扩散模型先验项的设计、迭代方案的展开, 并通过在多种稀疏角度数据集上的实验, 对所提出的算法进行了验证, 并对其超参数作了初步分析。

第 4 章, 对基于多通道交叉卷积 UCTransNet 的 DECT 基材料图像分解技术进行了研究。从拟合数学分解模型的角度出发, 设计了专用于基材料分解的网络模型。该网络模型以 UCTransNet 为基础架构, 采用 Transformer 模块来提高基材料分解性能, 实现双输入双输出端到端的映射。通过相关实验, 分析网络模型噪声伪影抑制效果。最后通过消融和参数分析实验, 归纳出该方法的优点与不足。

第 5 章, 对论文在低剂量 DECT 图像重建以及基材料分解方面的研究工作进行了总结, 并对目前所提出方法存在的局限性做了详细的分析, 最后结合该领域的发展趋势对未来的工作重点与方向进行了展望。

第 2 章 DECT 成像与基材料图像分解理论

本章节主要研究了 CT 成像基本原理、DECT 图像重建技术以及基材料图像分解的基本理论基础：首先介绍了 X 射线的产生以及透过物体时的物理效应以及衰减规律，然后重点研究了 DECT 重建的理论和现有的各种深度重建算法模型，最后对 DECT 基材料图像分解模型进行了重点研究。

2.1 CT 成像的数理基础

2.1.1 X 射线的产生




图 2-1 X 射线能谱产生机理

Fig. 2-1 Mechanism of X-ray Energy Spectrum Generation

X 射线与红外辐射及可见光都是电磁波谱的重要组成部分，其产生机制源于高速电子对靶材的轰击过程。典型 X 射线能谱的形成主要归因于电子与靶原子间的三类能量转换过程，如图 2-1 所示。在第一类过程中，当入射电子在靶原子核附近运动时，由于库仑力的作用，其运动轨迹发生显著偏转，同时伴随着辐射能量的损失。这种因电子急剧减速而产生的韧致辐射，其能量大小取决于相互作用过程中释放的入射能量，进而导致连续能谱的形成。第二类能量转换涉及高速电子与靶材内层电子的碰撞，当外层电子跃迁至内层空穴时，会释放特定能量的特征 X 射线，在能谱中表现为明显的峰位结构。特征辐射的能量由参与作用的

两电子壳层结合能差值决定。第三类过程表现为高速电子与靶原子核的直接碰撞，其全部动能均转化为轫致辐射，这一过程决定了 X 射线能谱的最高能量界限。

2.1.2 X 射线的衰减规律

在 CT 扫描中，X 射线与物质间的相互作用主要表现光电效应、康普顿效应和瑞利散射。低能 X 射线光子与低原子序数物质作用时发生光电吸收，光子能量全部用于激发内层电子。光电效应发生概率与原子序数立方成正相关，与光子能量立方成负相关，有利于低对比度组织识别。康普顿散射发生在高能光子与物质作用时，光子保留大部分能量，可能发生多次碰撞，导致检测精度受到影响。其与电子密度相关，与原子序数关系弱，难以提供有效组织对比度，应尽量减少其影响。瑞利散射由电磁波振荡引起，不涉及能量转化或电离，因此在医用 CT 技术研究中通常不予考虑。X 射线穿透被检测物质时的衰减特性遵循 Lambert-Beers 定律，如式（2-1）所示。

$$\mu x = -\ln \frac{I}{I_0} \quad (2-1)$$

其中， μ 表示该材料在 X 射线扫描下的线性衰减系数， x 表示该均匀材料的厚度， I_0 是 X 射线未穿过该材料时的强度， I 是 X 射线穿过该材料后的强度。

特定物质的 X 射线衰减特性由光电效应、康普顿效应和瑞利散射三种机制决定，其线性衰减系数在不同能量下恒定。由于被检测物体通常由多种密度不均的物质组成，图 2-2 直观展示了公式（2-1）描述的 X 射线衰减过程：




图 2-2 X 射线穿过不同衰减物质示意图

Fig. 2-2 Schematic Diagram of X-rays Passing Through Different Attenuating Materials

在任意给定的 X 射线扫描路径中，当 X 射线穿透被检测物体时，该物体可被离散化为一系列具有均匀特性的体素单元，其中每个体素的衰减系数可表示为 $\mu_1, \mu_2, \mu_3, \dots, \mu_n$ ，厚度为 $x_1, x_2, x_3, \dots, x_n$ 。则式 (2-1) 可由以下公式代替：

$$\mu_1 x_1 + \mu_2 x_2 + \dots + \mu_n x_n = -\ln \frac{I}{I_0} \Leftrightarrow \sum_{i=1}^n \mu_i x_i = -\ln \frac{I}{I_0} \quad (2-2)$$

由 (2-1) 式和 (2-2) 式可知，当被扫描物质的密度呈现均匀分布时，其衰减系数将保持恒定，然而，当 X 射线穿过密度不均匀的材料，此时衰减系数沿某一路径 L 穿过某一方向 l ，则 $\mu = \mu(l)$ ，X 射线衰减函数的公式如下：

$$I = I_0 e^{-\int_L \mu(l) dl} \quad (2-3)$$

其中， $\mu(l)$ 是以射线路径 l 为变量的函数， $\int_L \mu(l) dl$ 为 X 射线沿该方向 l 的总衰减，即检测器采集到的投影数据。若能够测得 X 射线衰减前后的强度 I_0, I ，便可求出 $\int_L \mu(l) dl$ ，进而利用多个投影数据重建扫描物体的衰减分布。

2.2 DECT 图像重建技术

2.2.1 DECT 重建理论

在 CT 影像重建领域，解析重建与迭代重建构成了两大主要技术体系。其中，基于 Randon 变换的解析重建算法凭借其高效的计算性能，在临床实践中得以普遍应用。而针对 DECT 图像重建，使用解析法分别处理高、低能投影数据就可以得到对应能量的物质衰减信息，论文中的 DECT 重建过程正是依托于 DECT 扫描系统采集的高、低能量区间投影数据集进行的。

假定使用 $f(x, y)$ 表示待重建图像的像素点， l 表示笛卡尔坐标系下的任意一条直线，其到坐标原点的距离 s ，垂线与 x 轴的夹角设为 β 。则像素点 (x, y) 的二维 Randon 变换如式 (2-4) 所示：

$$P(s, \beta) = \int_{-\infty}^{+\infty} f(s \cos \beta - l \sin \beta, s \sin \beta + l \cos \beta) ds \quad (2-4)$$

Randon 变换以数学形式模拟了 X 射线的投影过程，而通过反投影算法进行 CT 图像重建即对应了 Randon 逆变换过程。解析算法的核心为 Fourier 切片定理，如图 2-3 所示：二维图像中像素点 $f(x, y)$ 投影值 $P(s, \beta)$ 的一维 Fourier 变 $P_\beta(\omega)$

等价于 $f(x, y)$ 二维 Fourier 变换 $F(u, v)$ 中过原点且与 ω 轴夹角为 β 的一个切片。待重建图像中像素点 $f(x, y)$ 的二维 Fourier 变换如式 (2-5) 所示：

$$F(u, v) = \int_{-\infty}^{+\infty} \int_{-\infty}^{+\infty} f(x, y) \exp[-j2\pi(ux + vy)] dx dy \quad (2-5)$$

X 射线投影数据 $P(s, \beta)$ 的一维 Fourier 变换结果如式 (2-6) 所示：

$$P_{\beta}(\omega) = \int_{-\infty}^{+\infty} P(s, \beta) \exp(-j2\pi\omega s) ds \quad (2-6)$$

借助 Fourier 切片定理可得 $F(u, v) = P_{\beta}(\omega)$ ，完成投影信息到图像数据的精准映射。本论文采用解析重建方法，针对 80kVp 和 140kVp 两种能量的 DECT 图像数据分别进行图像重构，再系统地对重建后的图像进行结构恢复和基材料图像分解。




图 2-3 Fourier 切片定理示意图

Fig. 2-3 Schematic Diagram of the Fourier Slice Theorem

2.2.2 深度重建算法

近年来，DL 方法已成为解决医学成像中逆问题的主流方法，与统计迭代重建相比具有更优异的性能和更快的处理速度。在 CT 图像重建领域，DL 模型可通过捕获图像高层特征来显示其学习不确定噪声分布能力。由于它可以有效地适应任何噪声类型，因此对于 CT 重建的整体性能提升有显著促进作用^[58-59]。DL 技术是利用神经网络学习输入数据的特征，并通过非线性叠加将低层特征提取组合，实现任意复杂非线性函数的近似最优化逼近，学习所需要的信息。根据训练是否对配对数据具有依赖性，DL 方法可以大致被划分为有监督式和无监督式两种。

如图 2-4 所示，面向 CT 成像的深度重建算法主要分为有监督学习的深度重建和无监督学习深度重建方法两个方面，并在下文中分小节进行了详细阐述。

监督学习是通过数据的预测与样本标签计算损失值，获得相应的学习模型。监督学习类方法主要包括：支持向量机模型（Support Vector Machines, SVM）、卷积神经网络模型、循环神经网络模型（Recurrent Neural Networks, RNN）等^[60-61]。由于监督学习方法需要大量的标注样本，而误标样本和低质量样本也会大大降低模型性能，无监督学习方法的优势在于无需对样本标签进行预先标注，以数据集中样本间的相似度为依据，自动提取特征并预测。无监督类学习类方法主要包括：变分自编码器（Variational Autoencoder, VAE）、深度信念网络（Deep Belief Network, DBN）、聚类（Clustering）、玻尔兹曼机（Boltzmann Machine, BM）、生成对抗网络（Generative Adversarial Nets, GAN）等^[62-63]。

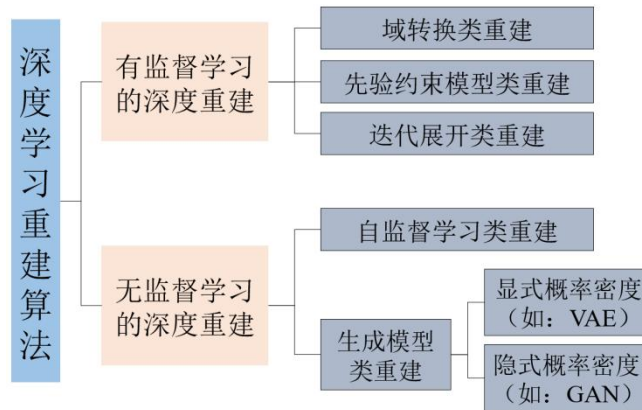


图 2-4 深度学习重建算法分类

Fig. 2-4 Classification of Deep Learning Reconstruction Algorithms

（1）有监督学习的深度重建

基于监督学习的图像重建方法使用配对数据来学习将低质量输入回归到高质量输出的深度神经网络映射。深度重建中，有监督的学习模式最为常见，按照 DL 在重建算法中使用方式，可以将此类重建方法分为三类，如图 2-4 所示。域变换类方法：使用深度神经网络替代 FBP 运算。模型类方法：使用深度神经网络替代统计迭代重建中的先验约束项。迭代展开类方法：使用深度神经网络实现迭代求解。

A. 域变换类方法

域变换类方法其核心思想是使用深度神经网络来替代 FBP 运算，与此同时还可以对投影域和图像域的数据加以处理，以进一步促进重建图像质量的提升。域变换类深度重建算法执行过程如图 2-5 所示^[64]。这类深度重建网络的输入和输出通常分别是投影数据和图像数据。按照解析重建的数据处理流程，研究人员可在域变换的基础上增加两个子网络，分别作用于投影域和图像域数据，这两个子网络通常都使用卷积神经网络来实现。投影数据首先被送入第一个子网络，在其中可以对其进行去噪校正等预处理。然后，使用域变换将预处理后的投影数据转换为 CT 图像数据。最后，运用第二个子网络对 CT 图像进一步处理以提高重建效果。多数文献中用于图像处理的网络也都能适应于进行两个域的数据处理。由于投影域和图像域的 CT 噪声统计分布差异较大，两个域的处理过程可以互补，使重建过程更加有效和稳定。




图 2-5 域变换类深度重建算法流程

Fig. 2-5 Process of Domain Transformation-Based Deep Reconstruction Algorithms

B. 先验约束模型类方法

先验约束模型类方法其核心思想是使用深度神经网络来替代统计迭代重建中的先验约束项。DL 技术能利用大数据有效解决复杂问题，因此，利用深度神经网络构造可学习的先验约束项是可行的。大量研究表明，用神经网络代替传统构造的先验约束项，能取得优于传统统计迭代重建的结果。

先验约束模型类深度重建算法是将预训练好的模型作为先验信息。这类方法一般采用交替方向乘法、原始对偶法等将待求解问题分解为若干个子问题，并通过预训练网络的方式来解决其中的部分子问题，即插即用型形式的深度重建算法是近年研究热点。CT 重建模型可表示为：

$$\min_{\mathbf{u}} \frac{1}{2} (\mathbf{A}\mathbf{u} - \mathbf{p})^T \Sigma^{-1} (\mathbf{A}\mathbf{u} - \mathbf{p}) + \frac{\lambda}{2} \mathbf{u}^T (\mathbf{u} - D(\mathbf{u})) \quad (2-7)$$

其中 $\mathbf{u} \in \mathbb{R}^N$ 表示要求解的衰减系数分布， $\mathbf{p} \in \mathbb{R}^M$ 表示投影数据， $\mathbf{A} \in \mathbb{R}^{M \times N}$ 是预先指定的扫描几何的系统矩阵。 $D(\mathbf{u})$ 为预训练神经网络，以替代先验约束项。有两种方法可以训练这里的先验约束模型。一种是为所有迭代训练一个通用先验约束模型^[65]。这种策略可以使用噪声图像和相应的标签作为训练对来获得先验约束模型。第二种方法是通过动态训练依赖于迭代的先验约束模型。这种策略是在每次迭代中，先验约束模型将对具有不同参数的中间图像进行约束处理，以优化重建性能。

基于先验约束模型的方法是在传统迭代算法的基础上进行的，其训练和优化是分开的，可以使用小规模训练数据集，重建出较高质量的图像。如图 2-6 为基于先验约束模型的前向和后向处理过程流程，其中蓝色和红色箭头分别代表前向和后向方向。如图 2-6 所示。基于先验约束模型的方法采用单独的训练策略，存储计算成本较低，因此可使用更多次的迭代进行重建，并且训练后的先验约束模型可以嵌入到不同的优化方案中，使得基于先验约束模型的方法更加灵活。




图 2-6 先验约束模型类深度重建方法的前向和后向处理过程

Fig. 2-6 Forward and Backward Processing of Prior Constraint Model-Based Deep Reconstruction Methods

C. 迭代展开类方法

迭代展开类方法其核心思想是使用 DL 实现迭代求解。迭代展开是将迭代优化过程展开为有限数量个阶段，并将它们映射到神经网络中，如使用增强拉格朗日方法（Augmented Lagrange Method, ALM）进行展开。因此，这类方法主要研究内容是如何采用深度神经网络模块通过训练的方式实现迭代求解过程。迭代展开类方法中，一部分学者研究采用端到端的训练方式实现迭代求解过程的可学习，

另一部学者研究采用卷积神经网络实现迭代重建中超参数的部分学习。迭代求解过程的可学习的深度重建模型可表示为：

$$\min_{\mathbf{u}, \mathbf{v}, \mathbf{t}} L(\mathbf{u}, \mathbf{v}, \mathbf{t}) = \min_{\mathbf{u}, \mathbf{v}, \mathbf{t}} \frac{1}{2} (\mathbf{A}\mathbf{u} - \mathbf{p})^T \Sigma^{-1} (\mathbf{A}\mathbf{u} - \mathbf{p}) + \frac{\lambda}{2} R(\mathbf{v}) + \mathbf{t}^T (\mathbf{u} - \mathbf{v}) + \frac{\rho}{2} \|\mathbf{u} - \mathbf{v}\|_2^2 \quad (2-8)$$

其中 $\mathbf{v}$, $\mathbf{t}$ 为辅助变量, ρ 为正则化参数。使用交替方向乘子方法, 目标函数 (2-8) 可分解为如下：

$$\begin{cases} \mathbf{u}^{t+1} = \arg \min_{\mathbf{u}} L(\mathbf{u}, \mathbf{v}^t, \mathbf{t}^t) \\ \mathbf{v}^{t+1} = \arg \min_{\mathbf{v}} L(\mathbf{u}^{t+1}, \mathbf{v}, \mathbf{t}^t) \\ \mathbf{t}^{t+1} = \mathbf{t}^t + \rho(\mathbf{u}^{t+1} - \mathbf{v}^{t+1}) \end{cases} \quad (2-9)$$

式 (2-9) 为迭代重建的展开式, 迭代展开类方法就是将上述三个优化问题使用不同的神经网络来替代, 以实现端到端的重建。

基于先验约束模型的方法是在传统迭代算法的基础上进行的, 其训练和优化是分开的。基于迭代展开的方法是一个端到端的过程, 优化被纳入到训练中。如图 2-7 所示, 迭代展开的方法与先验约束模型的方法的前向数据流相似, 但展开类方法的后向数据流是端到端的, 即, 完整的反向数据流是从输出到输入的误差信号的反向投影, 可以以统一的方式进行训练, 其中所有参数, 包括正则化参数, 都可以从训练中获得。




图 2-7 迭代展开类深度重建方法的前向和后向处理过程

Fig. 2-7 Forward and Backward Processing of Iterative Unfolding-Based Deep Reconstruction Methods

(2) 无监督学习的深度重建

随着 DL 的出现及迅猛发展, 与神经网络有关的图像重建方法逐渐得到广泛研究。现有的有监督图像降噪网络需要在大量匹配成对/标记数据中进行训练, 而无监督学习本质上是一个统计方法, 在没有配对数据的情况下, 通过数据自身存

在的规律，来发现潜在的一些结构特征。由于对数据集没有严格要求，近年来，无监督学习逐渐成为生物医学图像处理等领域的研究热点，尤其是针对无监督学习中的自监督学习和基于生成模型这两种类方法，如图 2-4 所示。

A. 自监督学习类方法

自监督学习旨在从数据本身自动生成监督标签，再以构造的监督信息训练网络，由于其具有良好的数据利用效率和泛化能力，因而在许多机器学习实例中已得到了应用。对于回归任务，例如图像去噪、图像重建等，自监督学习通常通过一种掩模形式来实现，其中部分数据对网络隐藏并用于定义训练标签。对于图像重建，使用基于物理先验的自监督学习来解决正则化最小二乘问题，其重建质量可与监督式深度重建相媲美。在这种情况下，掩模是在数据保真步骤中执行的，与先验约束项相分离，并且有助于在使用不同域数据的损失函数。




图 2-8 自监督学习的迭代展开式深度重建算法流程

Fig. 2-8 Process of Self-Supervised Learning Iterative Unfolding Deep Reconstruction Algorithm

自监督学习为图像重建神经网络提供了一种不需要配对数据的训练方法，其中数据欠采样自监督学习（Self-Supervised Learning via Data Undersampling, SSDU）的方法，是医学图像重建中一种泛化的掩模训练过程，基本流程如图 2-8 所示^[66]。在重建流程中，扫描数据 p ，通过掩模 θ 分成 p^θ 和 p^{θ^c} 两部分， $H_{\theta^c}(\cdot)$ 为掩模集 θ^c 对应的域变换算子，DC 表示与深度神经网络相关的数据一致性单元，用于实现扫描数据一致性操作。理论上掩模 θ 是随机选择的，在基于傅里叶变换的变换域可使用基于高斯概率密度的可变密度掩模方法，可实现对傅里叶空间中低频内容的更密集采样用于数据一致性单元。然而，用于掩模的高斯密度需要一个控制其方差的超参数。因此，在后续的研究将 SSDU 扩展到多掩模操作，可使用多个

掩模来定义损失，实现掩模真正意义上的随机选择，同时也避免了超参数的设置^[67]。此外，当域变换操作不适定时，多个掩模的使用也可以提高重建性能。

B. 生成模型类方法

无监督学习生成模型的任务是建立一个从隐向量生成预期数据的模型。以生成模型为基础的特征学习，从网络结构和目标函数的角度提出了许多重建方法，大体上包括隐式的概率模型（如 VAE 等）和显示的概率模型（如 GAN 等）两种。VAE 主要是使用对数似然函数作为训练目标，而 GAN 是使用对抗性训练来最小化模型和数据分布之间的 f 散度或积分概率度量。




图 2-9 生成模型类深度重建的流程图，左侧为先验学习过程和右侧为迭代重建过程

Fig. 2-9 Flowchart of Generative Model-Based Deep Reconstruction, with the Left Side Representing the Prior Learning Process and the Right Side Representing the Iterative Reconstruction Process

使用常规无监督学习方法用于图像重建的流程图如图 2-9 所示，该流程图由无监督的先验学习步骤和迭代重建步骤组成，重建目标函数与基于先验约束模型类方法相同。在先验学习阶段，旨在通过网络训练来学习图像的数据概率分布，特别是学习先验的梯度。在迭代重建阶段使用训练好的先验模型，可以在约束数据保真项的同时约束整体解空间来实现迭代重建算法。交替迭代重建过程可写成：

$$\begin{cases} \mathbf{u}^{t+1/2} = \arg \min_{\mathbf{u}} \frac{1}{2} (\mathbf{A}\mathbf{u} - \mathbf{p})^T \Sigma^{-1} (\mathbf{A}\mathbf{u} - \mathbf{p}) + \frac{\alpha}{2} \|\mathbf{u} - \mathbf{u}^t\|_2^2 \\ \mathbf{u}^{t+1} = \arg \min_{\mathbf{u}} \frac{\beta}{2} \|\mathbf{u} - \mathbf{u}^{t+1/2}\|_2^2 + \frac{\lambda}{2} \mathbf{u}^T \left(\mathbf{u} - \Psi \left(\mathbf{u}^{t+1/2} \right) \right) \end{cases} \quad (2-10)$$

其中 $\Psi(\cdot)$ 为生成模型网络， α 和 β 为拉格朗日乘子。

2.3 DECT 基材料图像分解理论

X 射线作为一种电磁波，既具有波动性（如相干散射），也具有粒子特性（如光电效应、康普顿效应），其在扫描物体时会产生吸收和散射现象，从而导致 X 射线强度的衰减。在 X 射线能量较低的情况下，光电吸收效应占据主导地位；随着 X 射线能量的增加，康普顿散射效应逐渐成为主要机制；当 X 射线能量足够高时，还会出现相干散射现象。这表明 X 射线穿过物体时产生的衰减和 X 射线能量有关，另外根据式（2-3）可得，衰减的程度还取决于物质特性。通过采用单一能量的 X 射线源，并测量出 X 射线在穿透扫描材料前后的强度变化，即可获得材料在该扫描路径上线性衰减系数的积分值，如式（2-11）所示：

$$I = \int_0^{E_{\max}} S(E) e^{-\int \mu(E,l) dl} dE \quad (2-11)$$

根据式（2-11）能够得到投影数据的计算表达式为：

$$P = -\ln \frac{I}{I_0} = \ln(I_0) - \ln(I) = \int_0^{E_{\max}} S(E) dE - \int_0^{E_{\max}} S(E) e^{-\int \mu(E,l) dl} dE \quad (2-12)$$

其中， $\mu(E)$ 表示物质在能量 E 下的线性衰减系数，可将其表述为一组基函数 $\{f_i(E), i=1, 2, \dots, n\}$ 的线性组合：

$$\mu(E) = a_1 f_1(E) + a_2 f_2(E) + \dots + a_n f_n(E) \quad (2-13)$$

其中 $\{a_i, i=1, 2, \dots, n\}$ 为需要拟合的权重系数，在能量范围适用于医学临床的条件下，衰减系数的精确性与 $\{f_i(E), i=1, 2, \dots, n\}$ 拟合误差呈负相关，误差值越低，表明其对物质衰减特性的表征越可靠。目前，在满足拟合要求的双能分解模型中，双效应图像分解法和基材料图像分解法是两种应用较为广泛的技术方案。

2.3.1 双效应图像分解模型

在 X 射线强度衰减过程中，光电吸收、康普顿散射及相干散射构成了主要作用机制。鉴于临床医学领域应用的 X 射线能量普遍维持在 200keV 以下，这一能量水平无法满足相干散射的发生条件，故其影响可不予考虑。而光电吸收与康普顿散射这两种物理过程均受到物质特性参数和射线能量水平的双重制约。基于此，线性衰减系数可通过光电效应与康普顿效应的线性叠加来表征，其数学表达式如式（2-14）所示：

$$\mu(E) = a_c f_{KN}(E) + a_p f_p(E) \quad (2-14)$$

其中, $f_{KN}(E)$ 表示只与能量有关、与材料无关的康普顿散射作用, 可表示为:

$$f_{KN}(\alpha) = \frac{1+\alpha}{\alpha} \left[\frac{2(1+\alpha)}{1+2\alpha} - \frac{1}{\alpha} \ln(1+2\alpha) \right] + \frac{1}{2\alpha} \ln(1+2\alpha) - \frac{1+3\alpha}{(1+2\alpha)^2} \quad (2-15)$$

其中 $\alpha = \frac{E}{510.975} \text{ keV}$ 。 $f_p(E)$ 表示只与能量有关、与材料无关的光电吸收作用, 可表示为:

$$f_p(E) = \frac{1}{E^3} \quad (2-16)$$

式 (2-14) 中的 a_c, a_p 是与能量无关而只与材质有关的物理量, 分别为康普顿散射效应和光电效应系数, 可表示为:

$$a_c = K_1 \frac{\rho Z}{A} \quad (2-17)$$

$$a_p = K_2 \frac{\rho Z^n}{A}, n = 4 \sim 5 \quad (2-18)$$

其中, K_1, K_2 为常数, ρ 是该物质的物理密度, 其单位为 g/cm^3 , Z 是该物质的原子序数, 而 A 是该物质的原子量。相较于常规 CT 技术, 双能 CT 的核心优势体现在其能够重构被扫描物质的有效原子序数及电子密度分布图, 这种特性使得不同物质在电子密度-原子序数坐标系中呈现出独特的分布区域, 从而实现物质的有效鉴别。物质电子密度的数学表达式可表示为:

$$\rho_e = 2\rho Z/A \quad (2-19)$$

该模型中有效原子序数 Z_{eff} 和电子密度 ρ_e 可由康普顿散射效应和光电效应的分解系数计算得到, 具体表示如下:

$$Z_{eff} = l_1 \left[\frac{a_p}{a_c} \right]^{1/n}, n = 4 \sim 5 \quad (2-20)$$

$$\rho_e = l_2 a_c \quad (2-21)$$

其中, l_1, l_2 为常数。由式 (2-12) 和 (2-14) 可得双效应图像分解模型高低能谱下的投影函数为:

$$\begin{cases} P_L = \ln \int S_L(E) dE - \ln \int S_L(E) \exp[-A_c f_{KN}(E) - A_p f_p(E)] dE \\ P_H = \ln \int S_H(E) dE - \ln \int S_H(E) \exp[-A_c f_{KN}(E) - A_p f_p(E)] dE \end{cases} \quad (2-22)$$

其中 P_H, P_L 分别是 X 射线扫描物体得到的高低能投影, S_H, S_L 表示 X 射线管分别设置为高能和低能时获得的能谱信息, A_c, A_p 分别为 a_c, a_p 沿投影路径的线积分。根据公式, 若计算有效原子序数和电子密度, 则需要知道 a_c, a_p , 因此需要根据投影函数进行投影分解得到 A_c, A_p , 再进行重建就能进一步获得扫描物质的原子序数以及电子密度, 进而实现对物质的定性与定量评估。

2.3.2 基材料图像分解模型

与双效应图像分解模型类似, DECT 图像的衰减系数可由两种基材料图像衰减系数的线性组合来表征。根据图像域基材料图像分解定理, DECT 图像的基材料图像分解模型可以表述为:

$$\begin{pmatrix} \mu_H \\ \mu_L \end{pmatrix} = \begin{pmatrix} \mu_{1H} & \mu_{2H} \\ \mu_{1L} & \mu_{2L} \end{pmatrix} \begin{pmatrix} x_1 \\ x_2 \end{pmatrix} \quad (2-23)$$

其中, 变量的下标 L 和 H 分别表示低能谱和高能谱数据, 下标 1 和 2 表示两种不同的基材料。 μ_{ij} 是材料 $i \in \{1, 2\}$ 在能谱 $j \in \{L, H\}$ 下的线性衰减系数。 x_1, x_2 为两个基材料在图像中相同位置处的体积分。 μ_L, μ_H 为 DECT 图像像素对, 设 A 表示维数为 $2N \times 2N$ 材料分解矩阵, 其中 N 是图像中的像素总数。则:

$$\vec{\mu} = A\vec{x} \quad (2-24)$$

其中 $\vec{\mu}$ 是一个由高低能图像 $\vec{\mu}_L, \vec{\mu}_H$ 组成的 $2N$ 向量。 $\vec{x}$ 为分解后基材料图像 $\vec{x}_1, \vec{x}_2$ 共同组成的 $2N$ 向量。则 $\vec{x}$ 可通过对式 (2-24) 进行矩阵逆变换得到, 如式 (2-25) 所示:

$$\vec{x} = A^{-1}\vec{\mu} \quad (2-25)$$

其中, A^{-1} 表示由分解系数构成的矩阵, 式中 I 是一个维数为 $N \times N$ 的单位矩阵。则该分解矩阵可由式 (2-26) 计算得到:

$$A^{-1} = \frac{1}{\mu_{2H}\mu_{1L} - \mu_{1H}\mu_{2L}} \begin{pmatrix} -\mu_{2L}I & \mu_{2H}I \\ \mu_{1L}I & -\mu_{1H}I \end{pmatrix} \quad (2-26)$$

DECT 图像域基材料分解的目的是将高低能量区间下被扫描物质的衰减系数转换为两种基材料的不同体积组合, 而所选取基材料的电子密度与原子序数均为已知量。因此, 只需计算得到后, 即可对被扫描材料进行定性及定量评估。

然而, DECT 重建图像中通常存在由射线衰减的平均效应所引起的射束硬化伪影, 此外能谱解析过程也会使重建图像出现误差。直接使用如式 (2-25) 所示

的直接矩阵求逆法进行基材料图像分解会造成误差及伪影的放大,进而影响最终的基材料图像分解精度。因此,本论文基于深度学习方法研究了一种面向低剂量 DECT 重建图像的基材料图像分解方法,利用卷积网络的强大特征提取及建模能力完成高精度的基材料图像分解,为之后 DECT 的进一步应用提供精准参考。

2.4 本章小结

本章对 DECT 探测成像和基材料图像分解理论进行了详细介绍,包括 X 射线的产生、X 射线与物质的相互作用以及 X 射线在物质中的衰减规律,进而以该数理关系为基础引导出 DECT 重建技术。低剂量扫描技术虽能有效减小辐射影响,却也易引发重建图像的严重失真现象。国内外学者在稀疏角度 CT 成像及相应处理技术方面已积累了丰富的研究成果,其实践意义深远,深入探究这些方法将为后续研究提供借鉴和比较分析的素材。因此,本章还详细介绍了目前的各种深度重建算法类型,为后续算法开发提供了基本准则和方向指导。另外,还对双能 CT 基材料图像分解原理进行了分析和推导,并着重介绍了两种分解模型,为本研究奠定了坚实的理论根基。

第3章 基于混合谱数据生成扩散模型的 DECT 稀疏重建

DECT 能够有效区分不同的材料，其图像由同一样品的多次扫描组成，这揭示了 DECT 图像在能量域内的信息相似性。为了利用这些信息相似性并解决 DECT 成像中与过度辐射暴露相关的安全问题，现已有提出了稀疏视图 DECT 成像作为一种解决方案。然而，这种成像方法可能会影响图像质量。因此，本章提出了一种混合光谱数据生成扩散重建模型（Hybrid Spectrum Data Generative Diffusion Reconstruction Model, HSGDM）来提高成像质量。该方法利用 DECT 的光谱相似性，通过交错角度进行稀疏扫描，以获得具有不完全互补视图的低能和高能 CT 图像。随后，将低能和高能 CT 视图组织成多通道形式进行训练和推理，促进低能和高能特征之间的信息交换，从而在提高重建质量的同时降低辐射剂量。在 HSGDM 中，构建了分别在图像空间和小波空间训练的两种类型扩散模型约束项。小波空间扩散模型主要利用伪影的方向和尺度特征，再通过集成图像空间扩散模型，为迭代重建框架建立了一个混合约束。最终，将迭代方法转化为由测量数据指导的内聚采样过程，从而协同生成高质量且一致的稀疏角度 DECT 图像重建。与对比方法相比，该方法在 CT 值精度、细节保留和伪影消除方面表现出竞争力。在消融实验中，通过比较图像空间模型、小波空间模型和混合模型的视觉效果以及定量结果，进一步验证了本方法提出的混合先验的有效性。

3.1 稀疏 DECT 重建模型

3.1.1 交错角度扫描协议

基于光谱互补性的稀疏 DECT 扫描协议如图 3-1（a）所示。在该扫描协议中，不同 X 射线源（能量）的初始扫描位置有一定的角度偏移。这种偏移还导致每个后续扫描位置也保持相同的角度偏移，因为每个源的扫描位置都呈均匀规则的间隔分布，从而实现了不同能量的交错扫描^[7]。图 3-1（a）展示了交错角度扫描作为一种 DECT 扫描协议，其特征是光谱数据不完全互补，且交错角度扫描轨迹是全角度扫描的子集，且该方案有效减少了扫描时间和辐射剂量。图 3-1（b）提供了图 3-1（a）中互补稀疏扫描过程的可视化概述。值得注意的是，DECT 稀疏扫描是在 80kVp（低能量）和 140kVp（高能量）的光子能量下进行的，具有

完整的旋转轨迹。例如在实验部分，通过以 24 个角度间隔进行下采样，从完整的角度扫描投影数据（720 个投影数据角度）中获得了 30 个投影数据角度。在本章实验中，对具有两种不同源能量的全角度数据集进行回顾性子采样策略，获得了非重叠的交错稀疏投影数据集。




图 3-1 交错角度稀疏 DECT 采集：（a）交错角度稀疏扫描和全角度扫描，（b）源旋转角度与源能量的图示说明。

Fig. 3-1 Interleaved angular sparse DECT acquisition: (a) Interleaved angular sparse scanning and full angular scanning, (b) graphical illustration of the source rotation angle versus source energy.

3.1.2 数学重建模型

图像重建的数学模型可以被视为线性逆问题的求解过程，目的是从含有噪声或数据缺失的测量中恢复图像。因此为了实现这一目标，可以采用正向模型对稀疏视图 DECT 重建进行表达^[6]：

$$\begin{pmatrix} \mathcal{P}^L \\ \mathcal{P}^H \end{pmatrix} = A \begin{pmatrix} \mathcal{X}^L \\ \mathcal{X}^H \end{pmatrix} + \begin{pmatrix} \varepsilon^L \\ \varepsilon^H \end{pmatrix} \quad (3-1)$$

其中，变量的上标 L 和 H 分别表示低能谱和高能谱数据。 $\mathcal{P}^i$ 表示稀疏视图 DECT 系统在能谱 $i \in \{L, H\}$ 下的原始投影数据。 A 表示 DECT 稀疏成像系统投影矩阵。 $\mathcal{X}^i$ 表示能谱 i 下的矢量化重建图像。 ε^i 表示在能谱 i 下的测量数据中的噪声。此时，公式（3-1）可以简化为 $\mathcal{P} = A\mathcal{X} + \varepsilon$ 。解决图像重建线性逆问题的常见方法是利用最小二乘法。由于逆问题的病态性质，通常会在重建过程中加入约束项：

$$\mathcal{X} = \arg \min_{\mathcal{X}} \frac{1}{2} \|\mathcal{P} - A\mathcal{X}\|_2^2 + \lambda R(\mathcal{X}) \quad (3-2)$$

其中 $R(\bullet)$ 是一个设计合理的约束项，该约束项包含了 $\mathcal{X}$ 的先验信息。权重 $\lambda > 0$ 用于权衡这两个项。在这个重建框架中，现已提出了与各种优化技术相关的多种约束项，如稀疏变换^[12-14]、张量字典学习^[17]以及 CNN^[25-27]方法。通过将扩散模型

应用于 DECT 图像重建任务，图像空间扩散模型约束目标函数的简化数学表达式表示如下：

$$\mathcal{X}_{t-1} = \arg \min_{\mathcal{X}_t} \frac{1}{2} \|\mathcal{P} - A\mathcal{X}_t\|_2^2 + \lambda R^d(\mathcal{X}_t) \quad (3-3)$$

其中， $R^d(\cdot)$ 表示 SDE 在图像空间中训练得到的约束项。 $\mathcal{X}_t$ 是在第 t 次采样时获得的中间图像。

小波变换在基于稀疏性的约束项设计中至关重要。它作为一种强大的工具，能够类似于其它频率分解方法将图像分解为多频分量。将小波变换引入扩散模型可以有效地提高模型性能的稳定性。本方法将图像空间和小波空间中训练的两个正则化项集成到迭代重建框架中，最终的混合约束重建模型表示为：

$$\mathcal{X}_{t-1} = \arg \min_{\mathcal{X}_t} \frac{1}{2} \|\mathcal{P} - A\mathcal{X}_t\|_2^2 + \lambda_t R_t^d(\mathcal{X}_t) + \eta_t R_w^d(\mathcal{X}_t) \quad (3-4)$$

其中 $R_t^d(\cdot)$ 和 $R_w^d(\cdot)$ 表示约束项。每个约束项对应于扩散模型在实际应用中的推理过程，它们分别在图像空间和小波空间学习得到。参数 λ_t 和 η_t 用作加权因子，用于权衡分别来自图像空间扩散模型和小波空间扩散模型的两个约束项。




图 3-2 HSGDM 的主要过程：（a）图像空间扩散模型的简单训练过程，（b）小波空间扩散模型的简单训练过程，以及（c）HSGDM 的简单推理过程。

Fig. 3-2 Main process of the HSGDM: (a) Simple training process for the image space diffusion model, (b) simple training process for the wavelet space diffusion model, and (c) simple test process for the HSGDM.

HSGDM 的简单重建过程如图 3-2 所示。首先，在图 3-2（a）和 3-2（b）中，分别训练了图像空间扩散模型和小波空间扩散模型两个正则化项。在图 3-2（c）所示的推理过程中，首先将图 3-2（a）中训练得到的图像空间扩散模型用于从稀

疏视图数据中恢复空间结构信息，图 3-2 (b) 中训练得到的小波扩散模型则用于分析各种频率分量以进一步消除噪声和伪影。这种混合模型方法使用两个经过训练的评分函数来对不同的特征进行建模，从而产生准确且稳健的重建结果，这种方法能够有效提高重建图像的保真度并保留重要信息。

3.2 HSGDM 模型及优化过程

3.2.1 基于 SDE 的生成扩散模型

文献[68]和[69]中介绍的基于 SDE 的生成扩散模型是基于分数的生成模型领域的一个典型实例，该模型现已广泛应用于医学成像，以解决病态逆问题。在 SDE 模型中，随机噪声逐渐被添加到干净的数据中并用于训练神经网络，称为前向过程；在后续的去噪过程中，模型会学习如何从受到噪声影响的数据中去除这些干扰，这个过程系统地识别和消除了损坏样品中存在的噪声，从而有效地恢复了它们的质量。这种迭代的去噪方法被称为逆过程，它在图像恢复的整个阶段起着至关重要的作用。扩散模型在训练过程中注入高斯噪声，它遵循特定的分布和强度用于模拟实际图像中可能出现的噪声。去除噪声则是由模型在处理图像时对噪声进行估计和建模，而不是简单地消除添加的噪声。因此，去除的噪声是模型根据图像特征和噪声模式综合推断的结果。从形式上讲，SDE 的扩散模型本质上是训练图像逐渐过渡到噪声，旨在生成由采样变量 $t \in [0, T]$ 索引的一系列采样过程 $\{x(t)\}_{t=0}^T$ 。扩散过程由以下 SDE 规范^[69]：

$$dx = f(x, t)dt + g(t)dw \quad (3-5)$$

其中， $f(x, t)$ 表示线性漂移函数，用于控制扩散过程的确定性趋势，而 $g(t)$ 表示标量扩散系数，用于量化随机波动。向量 w 是典型的布朗运动，模拟扩散过程中的随机成分。SDE 的逆过程可以表示为：

$$dx = \left[f(x, t) - g(t)^2 \nabla_{x_t} \log p_t(x) \right] dt + g(t) d\bar{w} \quad (3-6)$$

其中 dt 表示无穷小的采样间隔。为了通过 SDE 反向过程生成恢复的图像，需要一个依赖于样本的评分函数 $\nabla_{x_t} \log p_t(x)$ ^[70]。因此，基于分数 SDE 的 S_θ 可以通过最小化评分误差来得到：

$$\theta^* = \arg \min_{\theta} \mathbb{E}_{x_t | x_0, x_0} \left\{ \left\| S_\theta(x_t, t) - \nabla_{x_t} \log p(x_t | x_0) \right\|_2^2 \right\} \quad (3-7)$$

其中, $p_t(x_t | x_0)$ 表示扰动函数, 它将初始状态空间 x_0 映射到扰动状态空间 x_t 。在实际研究中, HSGDM 方法采用深度神经网络来估计 SDE 模型的参数 θ^* 。简单地说, 为了近似 $\nabla_x \log p_t(x)$, 可以训练一个深度网络 $S_\theta(x_t, t)$ 。在公式 (3-5) 中, f 和 g 的不同组合可以产生多种类型的 SDE。每一对独特的参数组合都会影响生成 SDE 的特征、行为和属性。对于被广泛认可的变体, 称为爆炸 SDE (Exploding SDE, VE-SDE), f 和 g 可以表示为:

$$f = 0, g = \sqrt{d[\sigma^2(t)]/dt} \quad (3-8)$$

其中, $\sigma(t)$ 表示随时间变化的噪声尺度函数。

3.2.2 混合谱数据生成扩散模型

将小波变换纳入扩散模型对于提高图像重建质量具有显著的益处。因此, 在 HSGDM 方法中, 不仅在传统图像空间中执行了扩散过程, 同时还在小波空间进行了处理。为了在将 DECT 图像分解为两个尺度 (高频尺度捕捉细节, 低频尺度表示粗特征) 时保持平移不变性, 本方法采用离散小波变换 (DWT) 进行图像分解。DWT 有效地保持了图像中的空间对应关系, 确保在多尺度分析中特征位置信息不会丢失。高频尺度包含三个方向的带 (水平 (h)、垂直 (v) 和对角 (d)), 能够有效捕捉和表示图像中大多数高频条状伪影组分。DWT 过程可以表示为:

$$W(x) \rightarrow \{w^L, w^h, w^v, w^d\} \quad (3-9)$$

其中 $W(\bullet)$ 表示 DWT, w^L 表示变换后的低频分量, 而 w^h , w^v 和 w^d 对应于高频子带 (h, v, d)。通过这个分解过程, CT 图像 x 在小波空间内转换为 4 个子图像。为了提高表达的清晰度和效率, 后续部分采用简洁的符号 $\tilde{X}$ 来表示转换后的 CT 图像, 其中包含其所有子带数据, 即 $\tilde{X} = \{w^L, w^h, w^v, w^d\}$ 。




图 3-3 扩散模型在图像空间和小波空间中的训练过程示意图

Fig. 3-3 Schematic of the training processes of the diffusion models in the image space and wavelet space

然后，将训练好的两种类型的 SDE（图像空间和小波空间）替换 DECT 重建框架中手工制作的约束项。为了训练图像空间模型，正向过程遵循标准的 SDE 训练方法，系统地将噪声添加到 DECT 图像中。这种逐渐引入噪声的过程最终将整个图像分布转换为预定义的先验分布，从而使模型能够了解数据中的潜在模式和连接。图 3-3（a）展示了图像空间扩散模型的示意图。DECT 图像空间扩散模型 $S_{\theta_I}(\mathcal{X}_t, t)$ 可以通过优化目标函数来进行训练：

$$\theta_I^* = \arg \min_{\theta_I} \mathbb{E}_{\mathcal{X}_t | \mathcal{X}_0, \mathcal{X}_0} \left\{ \left\| S_{\theta_I}(\mathcal{X}_t, t) - \nabla_{\mathcal{X}_t} \log p(\mathcal{X}_t | \mathcal{X}_0) \right\|_2^2 \right\} \quad (3-10)$$

在设计小波空间扩散模型 $S_{\theta_W}(x_t, t)$ 时，从小波变换中得出的子带图像 $\tilde{X}$ 被用作样本数据，如图 3-3（b）所示。值得注意的是，本方法中单个小波空间扩散模型可以用于同时训练四个子带分量。这种方法主要有两个优点：首先，与为每

个子带训练单独的模型相比，该方法显著降低了计算成本；其次，虽然四个子带图像分别位于单个小波空间内，但它们本质上具有重要的共同属性和特征，这也进一步证明了使用统一模型的合理性^[71-72]。在正向过程中，噪声逐渐添加到每个小波分量中，将原始子带图像分布转换为已知的先验分布。相反，在扩散模型 $S_{\theta_w}(\mathcal{X}_t, t)$ 促进的反向过程中，从噪声表示中重建小波空间中的干净子带图像。这种方法能有效使用 SDE 对图像进行降噪和恢复，同时保留其小波空间特征。用于扩散模型 $S_{\theta_w}(\mathcal{X}_t, t)$ 训练的目标函数可表示为：

$$\theta_w^* = \arg \min_{\theta_w} \mathbb{E}_{\mathcal{W}_t^c | \mathcal{W}_0^c, \mathcal{W}_0^c} \left\{ \left\| S_{\theta_w}(\mathcal{W}_t^c, t) - \nabla_{\mathcal{W}_t^c} \log p(\mathcal{W}_t^c | \mathcal{W}_0^c) \right\|_2^2 \right\} \quad (3-11)$$

其中 w_t^c 表示第 c 个子带图像在第 t 次采样时的值，其中 $c \in \{L, h, v, d\}$ ， $p(w_t^c | w_0^c)$ 表示从 w_0^c 到 w_t^c 的扰动函数。给定一个数据集和一个模型 $S_{\theta_w}(w_t^c, t)$ ，使用公式 (3-11) 中的目标函数训练的优化目标可以估计 w_t^c 第 t 个采样的分数 $\nabla_{w_t^c} \log p(w_t^c)$ ；这使得模型具备一个低频段和三个高频带的丰富先验特征，从而提高了其在 DECT 图像重建中的性能。此外，稀疏角度 CT 图像的伪影特征分布是从两个频段和三个方向分布中提取的，有助于实现高精度建模。

3.2.3 模型优化过程

公式 (3-4) 中的目标函数将数据保真度项、图像空间约束项和小波空间约束项组合到一个联合优化框架中。该框架可以通过在两个空间中利用迭代交替的两步策略来实现求解。在第一步中，重点是通过应用图像空间扩散模型来优化重建图像，目的是优化图像质量并提高其视觉保真度。在此之后，第二步的重点转移到提高小波空间扩散模型中重建图像的数据一致性上。这涉及调整小波系数，使其更好地与原始信号特性一致，确保重建的图像准确且无伪影。这两个步骤可以重写为：

$$\mathcal{X}_{t-0.5} = \arg \min_{\mathcal{X}} \frac{1}{2} \|\mathcal{P} - A\mathcal{X}\|_2^2 + \lambda_t R_t^d(\mathcal{X}_t) \quad (3-12)$$

$$\mathcal{X}_{t-1} = \arg \min_{\mathcal{X}} \frac{1}{2} \|\mathcal{P} - A\mathcal{X}\|_2^2 + \eta_t R_w^d(W(\mathcal{X}_{t-0.5})) \quad (3-13)$$

其中， $\mathcal{X}_{t-0.5}$ 表示公式 (3-12) 中子问题的中间重建图像。在求解公式 (3-12) 中的子问题时，采用对偶变量 λ_t 作为 SDE 生成和数据保真度的可选约束。

$$\{\mathcal{X}_{t-0.5}, \mathcal{V}_{t-1}\} = \arg \min_{\mathcal{X}, \mathcal{V}} \frac{1}{2} \|\mathcal{P} - A\mathcal{X}\|_2^2 + \lambda_t R_t^d(\mathcal{X}) + \frac{\beta_t}{2} \|\mathcal{X} - \mathcal{V}\|_2^2 \quad (3-14)$$

其中 $\beta_t > 0$ 是拉格朗日乘数。公式 (3-14) 中提出的优化问题可以使用交替最小化方法有效地分解为更小、更易于处理的子问题。此方法围绕两个不同变量的交互作用展开，允许对每个变量进行迭代优化。

$$\mathcal{V}_{t-1} = \arg \min_{\mathcal{V}} \frac{1}{2} \|\mathcal{X}_t - \mathcal{V}\|_2^2 + \lambda_t R_t^d(\mathcal{X}_t) \quad (3-15)$$

$$\mathcal{X}_{t-0.5} = \arg \min_{\mathcal{X}} \frac{1}{2} \|\mathcal{P} - A\mathcal{X}\|_2^2 + \frac{\beta_t}{2} \|\mathcal{X} - \mathcal{V}_{t-1}\|_2^2 \quad (3-16)$$

扩散模型的生成过程始于通过反转 SDE 得到的广义数值解。与使用数值 SDE 求解器生成样本的标准做法不同，它更倾向于采用预测-校正 (Predictor-corrector, PC) 采样器，这种方法提供了一种替代且可能更优的解决方案^[68]。该方法因其在处理 SDE 时优化和改进求解过程的有效性而具有显著优势。

在预测阶段，首先对下一个采样步骤中待恢复的图像进行初步估计。随后，在校正阶段，利用马尔可夫链蒙特卡洛 (Markov Chain Monte Carlo, MCMC) 方法对这一估计进行优化，从而提高恢复图像的准确性和质量^[71]。从形式上讲，预测器步骤使用优化的图像空间扩散模型 S_{θ_t} 对采样步骤 t 中的生成图像进行如下修改：

$$\mathcal{V}_{t-1} = \mathcal{X}_t + (\sigma_t^2 - \sigma_{t-1}^2) S_{\theta_t}(\mathcal{X}_{t-0.5}, t) + \sqrt{(\sigma_t^2 - \sigma_{t-1}^2)} n \quad (3-17)$$

其中 $\sigma_t > 0$ 是一个相对于采样步骤 t 单调递增的函数。 $n \sim N(0, 1)$ 表示从标准正态分布中抽取的噪声样本。因此，对于更新后的 $\mathcal{V}_{t-1}$ ，可以使用以下校正步骤器来优化估计图像：

$$\mathcal{V}_{t-1} = \mathcal{V}_{t-1} + \epsilon_{t-1} S_{\theta_t}(\mathcal{V}_{t-1}, t) + \sqrt{2\epsilon_{t-1}} n \quad (3-18)$$

其中 ϵ_{t-1} 是第 $t-1$ 次采样时的步长参数。在 PC 采样器中，预测器步骤和校正器步骤会交替执行预定的迭代次数，以达到收敛的目标。

可以通过应用共轭梯度 (Conjugate Gradient, CG) 算法来解决公式 (3-16) 中的无约束最小化问题以获得 $\mathcal{X}_{t-0.5}$ 。具体来说，通过引入一个系统投影矩阵，并将其结合到投影域中，公式 (3-16) 中的目标函数可以改写如下：

$$\mathcal{X}_{t-0.5} = \arg \min_{\mathcal{X}} \frac{1}{2} \|(\beta_t - 1) A\mathcal{X} - (\beta_t A\mathcal{V}_{t-1} - \mathcal{P})\|_2^2 \quad (3-19)$$

随后可以用它的解析解 $\mathcal{X}_{t-0.5} = \mathcal{V}_{t-1} + \alpha p_t$ 更新图像 $\mathcal{X}_{t-0.5}$ ，其中步长用 α 表示，梯度方向表示为 p_t 。 p_t 的值可以通过满足约束条件 $p_t^T r_t = 0$ 来确定，其中 $r_t = (\beta_t - 1)A\mathcal{X} - (\beta_t A\mathcal{V}_{t-1} - \mathcal{P})$ 。

图像空间和小波空间中的优化过程是相同的。因此，与公式 (3-12) 类似，公式 (3-13) 的求解可以通过交替修改两个不同的步骤来实现。这一过程包括通过扩散模型更新重建图像，然后通过优化最小二乘问题来确保投影数据的一致性。首先，采用 DWT 将 $\mathcal{X}_{t-0.5}$ 转换为小波空间信号，用于小波空间扩散模型，如下所示：

$$W(\mathcal{X}_{t-0.5}) = \{\mathcal{W}_{t-0.5}^L, \mathcal{W}_{t-0.5}^h, \mathcal{W}_{t-0.5}^v, \mathcal{W}_{t-0.5}^d\} = \tilde{\mathcal{X}}_{t-0.5} \quad (3-20)$$

其次，对每个通道上的小波子带图像 $\mathcal{W}_{t-0.5}^c$ 运行包含预测器和校正阶段的小波空间扩散模型。具体来说，预测器阶段通过使用训练好的扩散模型 S_{θ_w} 按照以下步骤执行：

$$\mathcal{W}_{t-1}^c = \mathcal{W}_{t-0.5}^c + (\sigma_t^2 - \sigma_{t-1}^2) S_{\theta_w}(\mathcal{W}_{t-0.5}^c, t) + \sqrt{(\sigma_t^2 - \sigma_{t-1}^2)} n \quad (3-21)$$

接着，在校正器阶段对 $\mathcal{W}_{t-1}^c$ 进行如下操作：

$$\mathcal{W}_{t-1}^c = \mathcal{W}_{t-1}^c + \epsilon_{t-1} S_{\theta_w}(\mathcal{W}_{t-1}^c, t) + \sqrt{2\epsilon_{t-1}} n \quad (3-22)$$

采集完所有子带图像后，即可确定 $\tilde{\mathcal{X}}_{t-1}$ 的值。最终，可以通过应用逆向 DWT (Inverse Discrete Wavelet Transform, IDWT)，即 $\mathcal{X}'_{t-1} = W^T(\tilde{\mathcal{X}}_{t-1})$ ，得到图像空间中新的 $\mathcal{X}'_{t-1}$ 。此处， $W^T(\bullet)$ 表示 IDWT 操作。通过执行 IDWT，图像空间中的数据一致性得到增强，从而减轻不同通道的小波空间 SDE 可能带来的不一致性。

结合梯度下降算法和滤波反向投影 (Filtered Back-Projection, FBP) 的优点，通过 FBP 用 A 的逆向过程替换 A^T 来求解式 (3-13)，从而增强收敛性以获得重建的 DECT 图像^[73]。因此，涉及二次约束的最小化问题可以通过以下更新过程来解决：

$$\mathcal{X}_{t-1} = \mathcal{X}'_{t-1} - \alpha_{t-1} FBP(A\mathcal{X}'_{t-1} - \mathcal{P}) \quad (3-23)$$

其中 $FBP(\bullet)$ 表示 FBP 重建算法， α_{t-1} 是补偿权重参数。

所提出的 HSGDM 重建过程如图 3-4 所示。采样步骤从随机噪声图像 $\mathcal{X}_t$ 开始。在每个重建阶段，重建图像 $\mathcal{X}_t$ 首先进入图像空间扩散模型 S_{θ_i} 进行采样，然后通过带有数据保真项的 CG 算法更新重建图像。接着，更新后的图像通过 DWT

进行处理，并输入到小波空间扩散模型 S_{θ_w} 中进行采样。采样结果通过 IDWT 转换回图像空间，随后通过带有投影残差的 FBP 进一步更新重建的图像。上述更新步骤重复 T 次，最终获得重建图像 $\mathcal{X}_0$ 。

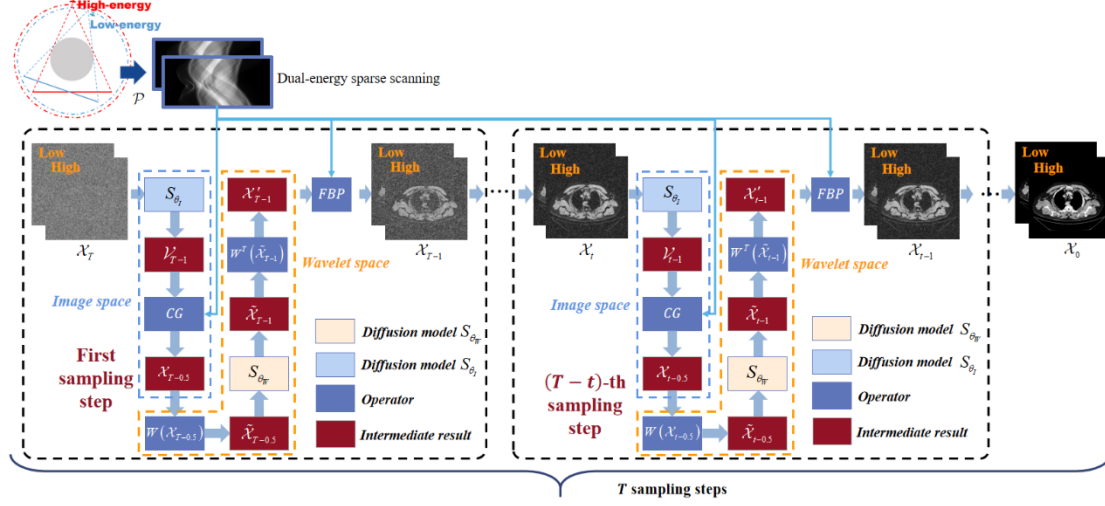


图 3-4 用于 DECT 成像的 HSGDM 方法重建流程图

Fig. 3-4 Flowchart of the HSGDM method for DECT imaging reconstruction

3.3 实验结果与分析

3.3.1 实验设置

(1) 实验数据集

所提出的模型在上海联影医疗股份有限公司提供的数据集上进行训练和评估。DECT 图像是使用 uCT960+ 设备采集的（数据收集和处理协议已获得机构伦理审查委员会批准，批准机构：上海徐汇中心医院，批准号 2015-01，审查日期：2015 年 1 月 29 日）。图像数据通过轴向扫描技术获取，管电流设置为 533mA，双管电压分别为 80kVp 和 140kVp。本研究中使用的数据集包括 13 名接受双能扫描协议的患者，共计 4,420 张切片。在这项研究中，随机选择 10 名患者的 3,400 张切片用于训练，而剩余 3 名患者的 1,020 张切片中随机选择了 600 张用于测试。为了生成具有 30、60 和 90 个稀疏视图的投影数据，采用等角扇形束探测器扫描协议。从 X 射线源到旋转中心的距离固定为 1200 mm，而探测器距离旋转中心 300 mm。使用 FBP 算法，从 X 射线源旋转一圈的 720 个投影角度中生成高质量图像，从而提供全角度 CT 图像（标签）。从这些全角度投影中，再选择性地提取 30、60 和 90 角度数据以重建 DECT 图像。此外，在通过 DECT 的等角

扇形束扫描创建稀疏角度数据集时，以交错方式控制高能和低能扫描对于确保获取的稀疏光谱数据具有不完全互补的空间结构至关重要，这种扫描协议更有利于改进 DECT 重建。

（2）模型训练和参数设置

所有的实验均在 Pytorch 1.12.1、Python 3.9 以及显存为 24GB 的 NVIDIA GeForce RTX 4090 上进行，SDE 的训练参数严格遵守 Song 等设定的指导和建议^[69]，例如 $\delta_t \in [\delta_{\min}, \delta_{\max}] = [0.01, 378]$ ，学习率为 2×10^{-4} 。如图 3-3 所示，与图像空间扩散模型相关的超参数与小波空间扩散模型中使用的超参数完全一致，唯一的区别在于通过 DWT 处理后的图像尺寸参数不同。此外，为了确保每个扩散模型采样过程中的数据一致性，采用了 CG 和 FBP 重建方法对重建图像进行更新，如图 3-4 所示。CG 和 FBP 重建算法通过 ASTRA 工具箱实现^[74]。公式（3-19）中 CG 算法的最优超参数 β_t 通过利用重建结果定量评分的渐进增强策略确定为 0.05。

（3）对比研究和定量指标

为了全面评估所提出的 HSGDM 方法，将其与几种用于稀疏视图投影重建的当代领先方法进行了比较。包括传统的 FBP 重建方法、PWLS-CSCGR 方法（一种在其正则化重建框架中结合了卷积稀疏编码的复杂方法）^[75]、LEARN 方法（一种用于约束重建的深度残差模型）^[21]、GMSD 方法（一种基于分数生成模型的重建方法）^[29]以及 ASCON 方法（一种用于 FBP 图像处理的解剖感知监督对比学习模型）^[19]，并将它们的性能与 HSGDM 进行了比较。

为了定量评估重建图像的质量，采用了两个广泛使用的指标：峰值信噪比（Peak Signal-to-Noise Ratio, PSNR）和结构相似性指数（Structural Similarity Index Measure, SSIM）。这些指标因其能够全面反映图像的保真度和质量而得到广泛认可。此外，Fréchet 起始距离分数（Fréchet Inception Distance Score, FID）是一种用于衡量全角度 CT 图像数据集和重建图像数据集的特征向量之间距离的指标，用于评估视觉特征效果^[76]。

3.3.2 重建结果

(1) 视觉评估

为了直观地展示各种方法的重建性能的有效性,因此对来自特定数据的 DECT 图像进行了定性比较,如图 3-5 所示。重建图像是通过应用低能量扫描和高能量扫描技术生成的,使用了覆盖 $[0^\circ, 360^\circ]$ 角度范围的 30 个角度。第一行是重建的低能图像(80kVp),第二行是其相应的重建高能图像(140kVp)。重建图像的显示窗口设置为 $[30, 300]$ HU。图 3-5 (a) 表示供参考的标签图像。在图 3-5 中的第二列到第七列,分别展示了通过 FBP、PWLS-CSCGR、LEARN、GMSD、ASCON 和 HSGDM 方法重建的图像。红色框内突出显示的区域表示所选的感兴趣区域(Region of Interest, ROI)。在图像的左上角,放大部分提供了该特定 ROI 的更多细节,以便更系统地查看其性能和特征。从整体图像质量的角度来看,如图 3-5 (b) 所示,稀疏扫描之后再通过解析重建会严重降低图像质量。图 3-5 (c) 表明 PWLS-CSCGR 方法未能在伪影抑制和结构平滑之间保持平衡。图 3-5 (d) 中的 LEARN 方法有效地恢复了图像的整体结构,但仍存在残余的条状伪影。图 3-5 (e) 中 GMSD 方法在精细结构特征的保留能力上是有限的。尽管图 3-5 (f) 中的 ASCON 方法在组织区域划分上取得了较好的结果,但其存在明显的边缘模糊问题。相比之下,图 3-5 (g) 中所提出的 HSGDM 方法有效地消除了条状伪影,有助于复杂组织结构的重建。ROI 的视觉细节表明,ASCON 对 ROI 1 和 ROI 2 的重建结果表现出不同程度的结构损失,而 HSGDM 在恢复复杂细节方面表现显著能力。此外,LEARN 的 ROI 3 重建图像存在明显的条带伪影,而 ASCON 的 ROI 3 则存在边缘模糊效应。值得注意的是,HSGDM 的 ROI 3 图像表现优异,展示了明显的组织结构识别和有效的伪影去除效果,并能够确保重建结构与真实图像保持高度一致,保证了高保真度和准确性。

图 3-5 中的重建结果与参考图像的差异图如图 3-6 所示。高能 CT 图像在对比度方面可能比低能 CT 图像表现更差,这可能会阻碍基于学习的算法恢复高能 CT 图像的组织结构。因此,LEARN 方法在 140kVp 时与标签图像的差异明显,这可能是因为图像信息极度不足导致的。低采样率会进一步降低传统监督学习方法的伪影去除能力,尤其是在噪声较大和结构复杂的图像中。与其它重建技术相

比，HSGDM 具有显著优势，它显著减少了噪声，并且其重建在伪影减少和组织细节恢复方面都表现出色。




图 3-5 30 个角度数据的不同方法可视化结果。第一行是 80kVp 时的重建结果，而第二行是 140kVp 时的重建结果。

Fig. 3-5 Visual results of different methods with 30-view data. The first row is the reconstructed result at 80kVp, whereas the second row is the reconstructed result at 140kVp.




图 3-6 通过不同方法获得的相对于参考图像的差异图。第一行是 80kVp 时的结果，而第二行是 140kVp 时的结果。

Fig. 3-6 Difference images relative to the reference image obtained via different methods. The first row is the result at 80kVp, whereas the second row is the result at 140kVp.

图 3-7 展示了图 3-6 中重建的低能 CT 图像 ROI 区域的误差分布。该可视化利用概率密度估计来直观地描述不同 CT 值的概率密度。真实图像和生成 CT 图像之间差异的概率密度曲线显示了 HU 分布的情况。以 0 为中心的曲线表示生成的图像通常与真实图像较为接近，仅有微小差异。如果曲线显示更宽的分布或与 0 值的偏离大，则表示某些 HU 值存在较大差异，从而揭示了生成的图像可能无法准确反映区域的真实密度。如图 3-7 所示，通过 PWLS-CSCGR 方法（不包括 FBP 方法）重建的图像的值分布曲线中表现出了较大的宽度分布，表明其与理想分布不一致。值得注意的是，基于深度学习的方法在 0 HU 处的密度显著改善，突显了其在优化重建过程中产生更准确结果的能力。在这些曲线中，所提

出的 HSGDM 在 0 HU 处的集中度最高, 这表明 HSGDM 方法有效地减少了噪声和伪影, 同时在重建图像中保留了更多细节。




图 3-7 真实图像和重建 CT 图像之间 HU 差异的概率密度

Fig. 3-7 Probability density of different Hounsfield units between the ground truth and reconstructed CT images

图 3-8 展示了应用于 60 角度和 90 角度数据的各种方法重建图像。如图 3-8 (b) 所示, 通过 FBP 重建的图像表现出明显的退化。从稀疏采样的投影中重建图像会给医学诊断带来相当大的挑战, 并且本质上它是一个不适定的问题。PWLS-CSCGR 的结果显示出明显的块状伪影和组织细节的大量丢失。LEARN 有效地去除了条状伪影, 但它也存在过度平滑的问题, 导致组织结构模糊 (如图 3-8 (d) 中放大的 ROI 1 和 4 中的橙色和红色箭头所示) 以及细节结构的丢失 (如图 3-8 (d) 中放大的 ROI 2 中的黄色箭头所示)。如图 3-8 (e) 所示, GMSD 展示了恢复图像细节的能力, 与 LEARN 相比清晰度更高 (如图 3-8 (e) 中放大的 ROI 1 和 4 中的橙色和红色箭头所示), 但它仍然存在过度平滑现象 (如图 3-8 (e) 中放大的 ROI 2 中的黄色箭头所示)。与 GMSD 相比, ASCON 显著提高了图像质量, 并在伪影去除方面取得了显著进展。然而, ASCON 在处理错误结构 (如图 3-8 (f) 中放大的 ROI 1 和 3 中的橙色和绿色箭头所示) 和模糊的组织边界 (如图 3-8 (f) 缩放的 ROI 4 中的红色箭头所示) 方面仍然存在局限性。HSGDM 能够产生高质量的图像, 保留复杂的结构 (见图 3-8 (g) 中放大的 ROI 1、2 和 3) 并保持清晰的组织边界 (如图 3-8 (g) 中放大的 ROI 4 中的红色箭头所示)。通过进一步可视化所提出的方法以及其它方法真实图像和重建图像之间的相应差异图, 如图 3-9 所示, 可以发现 HSGDM 方法去除的噪声伪影成分更多。



图 3-8 不同方法对测试数据的重建结果。第一行和第二行分别展示了 80kVp 和 140kVp 的 60 个角度数据的结果，而第三行和第四行展示了 90 个角度数据的结果。

Fig. 3-8 Reconstruction results of different methods on the test data. The first row and second row show the results for 60-view data at 80kVp and 140kVp, respectively, whereas the third and fourth rows depict the results for 90-view data.




图 3-9 通过不同方法获得的相对于参考图像的差异图像。第一行和第二行分别展示了 80kVp 和 140kVp 的 60 个角度数据的结果，而第三行和第四行展示了 90 个角度数据的结果。

Fig. 3-9 Difference images relative to the reference image obtained via different methods. The first row and second row illustrate the results for 60-view data at 80kVp and 140kVp, respectively, whereas the third and fourth rows depict the results for 90-view data.

图 3-10 展示了 30 角度投影下不同方法重建的矢状面和冠状面图像。可以发现所提出的 HSGDM 方法优于对比方法，提供的视觉质量与参考图像相似。图像中复杂结构得到了更好的保留，如图 3-10 中的红色和蓝色虚线圈所示。另外，HSGDM 方法很好地降低了噪声水平，从而使图像具有更高的清晰度并减少了干扰。




图 3-10 不同方法 30 角度下的冠状面和矢状面结果。所有图像都显示在腹窗[30, 300] HU 中。

Fig. 3-10 The 30-view coronal and sagittal results of the different methods. All the images are displayed in the abdominal window [30, 300] HU.

(2) 定量评估

重建图像的质量通过 PSNR 和 SSIM 评分进行评估，这些评分以测试数据集的平均值 (MEAN) $\pm$ 标准差 (STD) 形式呈现。在表 3-1 中，对于所有三种稀疏情况，FBP 和 PWLS-CSCGR 方法的得分最差。在引入深度迭代重建机制后，LEARN 的性能优于 PWLS-CSCGR。GMSD 和 ASCON 是两种基于 DL 的方法，它们在 PSNR 和 SSIM 方面表现出色。图 3-8 和图 3-10 中呈现的视觉结果证实 GMSD 可以产生过度平滑的结果。HSGDM 方法取得了最高的 PSNR、SSIM 值以及最低的 FID 值，验证了所提出的方法的优势。尤其是当给定 30 个投影角度时，HSGDM 在测试数据集上相比 ASCON 实现了 +3.51 dB 的显著 PSNR 增益。表 3-1 显示，与对比方法相比，所提出的 HSGDM 方法在 PSNR 和 SSIM 指数的均值和方差方面都取得了更好的分数。这些分数间接表明所提方法具有良好的稳定性和泛化能力。

图 3-11 展示了穿过样品切片中红色实线的一维线强度分布，用于评估像素级的 HU 拟合精度。值得注意的是，从 HSGDM 方法获得的线强度在 30 角度和

60 角度扫描情况下都与真实图像线强度最接近。该比较表明，使用 HSGDM 方法重建图像在组织精度上优于对比方法。

表 3-1 测试数据集上不同方法的定量结果 (PSNR [MEANs $\pm$ STDs]、SSIM [MEANs $\pm$ STDs $\times 10^{-1}$] 和 FID

Table 3-1. Quantitative results (PSNR [MEANs $\pm$ STDs], SSIM [MEANs $\pm$ STDs $\times 10^{-1}$]) and FIDs of different methods on the test dataset

Methods	30 views			60 views			90 views		
	PSNR $\uparrow$ (dB)	SSIM $\uparrow$	FID $\downarrow$	PSNR $\uparrow$ (dB)	SSIM $\uparrow$	FID $\downarrow$	PSNR $\uparrow$ (dB)	SSIM $\uparrow$	FID $\downarrow$
FBP	23.25 $\pm$ 1.84	0.39 $\pm$ 0.60	349.01	26.74 $\pm$ 1.74	0.51 $\pm$ 0.73	311.13	29.02 $\pm$ 1.51	0.58 $\pm$ 0.72	256.69
PWLS-CSCGR	30.36 $\pm$ 2.40	0.82 $\pm$ 0.19	235.26	35.13 $\pm$ 2.26	0.91 $\pm$ 0.10	123.02	37.81 $\pm$ 1.92	0.94 $\pm$ 0.06	115.90
LEARN	34.64 $\pm$ 4.39	0.84 $\pm$ 1.51	182.73	37.95 $\pm$ 4.37	0.91 $\pm$ 0.79	122.98	41.12 $\pm$ 3.93	0.95 $\pm$ 0.38	60.24
GMSD	35.65 $\pm$ 3.23	0.92 $\pm$ 0.23	138.66	39.01 $\pm$ 2.47	0.94 $\pm$ 0.14	88.84	40.43 $\pm$ 2.50	0.96 $\pm$ 0.12	71.92
ASCON	35.79 $\pm$ 5.30	0.93 $\pm$ 0.24	126.54	38.77 $\pm$ 5.83	0.95 $\pm$ 0.11	76.19	39.46 $\pm$ 6.09	0.95 $\pm$ 0.12	57.67
HSGDM	39.30$\pm$2.05	0.96$\pm$0.05	52.07	43.05$\pm$1.89	0.98$\pm$0.07	44.34	44.09$\pm$1.62	0.98$\pm$0.05	33.70




图 3-11 穿过红色实线的 HU 值剖面。(a) 80kVp, 30 个角度数据。(b) 80kVp, 60 个角度数据。

Fig. 3-11 The Hounsfield Unit value profile passing through the red solid line. (a) 80kVp, 30-view data. (b) 80kVp, 60-view data.

3.3.3 超参数分析

为了检验 HSGDM 方法的收敛性，图 3-12 绘制了 PSNR 和 SSIM 评分随采样步骤数量的变化曲线。在经过 1600 个采样步骤后，PSNR 和 SSIM 评分的收敛

表明网络训练完成。因此，HSGDM 具有显著的快速收敛速度，确保了高效和及时的优化。




图 3-12 用于 30 个角度 DECT 重建的 HSGDM 方法收敛分析

Fig. 3-12 Convergence analysis of the HSGDM method for 30-view DECT reconstruction




图 3-13 与 CG 算法中不同迭代次数相关的定量结果

Fig. 3-13 Quantitative results associated with different numbers of iterations in the CG algorithm

为了确定 CG 算法中的最优迭代数超参数，通过不同迭代次数获得了 PSNR 和 SSIM 评分。图 3-13 中的结果展示了不同迭代次数下的定量结果。将迭代次数从 45 增加到 60 并未显著改善重建图像的性能。通过精细平衡算法效果与计算效率，最终确定 60 次迭代为参考值，并将其作为模型中 CG 算法的黄金标准。

3.3.4 混合约束消融实验

图 3-14 展示了通过 30 个角度 DECT 投影从各种模型中重建的图像。第一行展示了 80kVp 能级下的重建结果。放大的 ROI 显示，小波空间 SDE 有效地减少了图像中的条状伪影，但其恢复复杂组织结构的能力尚不全面。这一局限性可能源于小波空间 SDE 在频域信号分析方面表现优异，但在空间结构表示方面存在不足。相比之下，图像空间 SDE 能够准确识别组织结构，但仍存在可见的残余

条状伪影。所提出的混合扩散模型成功结合了小波空间和图像空间 SDE 的优势，视觉结果表明，与其它两种模型相比，伪影去除和结构保留效果更好。第二行展示了 140kVp 能级下的重建结果。对于高能 and 低能数据，这三个模型都观察到了类似的现象。此外，通过检查 ROI 中绿色和蓝色虚线圈，可以发现通过图像空间约束重建的组织结构内出现意外的裂纹。然而，小波空间 SDE 虽然缺乏明显的组织纹理，但并未出现裂纹。混合模型有效地利用了两种方法的优势，实现了清晰且精确的组织结构重建。测试集的量化结果如表 3-2 所示，这表明混合约束模型在 PSNR、SSIM 和 FID 指标上显著优于其它方法，混合约束模型在噪声抑制和结构保留方面表现出色。




图 3-14 基于 30 个角度数据集不同模型获得的轴向重建图像。所有图像都显示在腹窗[87, 300] HU 中。

Fig. 3-14 Axial reconstruction images obtained for the different models on the basis of the 30-view dataset. All the images are shown in the abdominal window [87, 300] HU.

表 3-2 不同约束模型的定量结果（PSNR [STD±平均值]和 SSIM [STD±平均值×10⁻¹]）和 FID

Table 3-2. Quantitative results (PSNR [MEANs ± STDs] and SSIM [MEANs ± STDs×10⁻¹]) and FID of different constraint models

Methods	Wavelet space	Image space	Hybrid-model
PSNR (dB) ↑	37.61±1.64	38.90±2.37	39.30±2.05
SSIM↑	0.93±0.03	0.95±0.06	0.96±0.05
FID↓	60.83	55.24	52.07

3.4 本章小结

本章介绍了 HSGDM 重建方法，该方法是一种新颖的深度展开迭代重建框架，它利用混合频谱数据生成扩散模型进行 DECT 重建。来自两个互补稀疏视图扫描的先验模式被用于集成图像和小波空间的混合扩散模型。为了利用频谱数据

的一致性，使用双通道数据模式作为输入，促进了特征信息交换。此外，为了更好地整合从生成模型得出的精心设计的先验约束，在迭代重建过程中对密度数据应用了梯度退火。消融分析证实了所提出的 HSGDM 框架中不同约束项的有效性，并证明了它们对整体性能的贡献。模拟 DECT 数据集的定性和定量评估表明，该方法具有高图像准确性、卓越的组织保存和更少的伪影。在未来的工作中，可以通过额外的临床 DECT 数据或来自各种稀疏扫描水平、身体部位和 CT 扫描仪的多光谱数据来评估所提出的模型。为了在临床场景中有效应用，需要使用更优秀的模型来加速采样过程，提高稀疏扫描情况下 DECT 图像重建的稳健性和泛化性。

第 4 章 基于多通道交叉卷积 UCTransNet 的 DECT 基材料 图像分解方法

基于混合谱数据生成扩散模型的 DECT 稀疏重建方法虽然可以去除 DECT 图像由于稀疏扫描所产生的噪声和伪影,但重建图像中仍然不可避免的存在小部分未能完全消除的噪声伪影,经基材料图像分解算法处理后,会导致重建图中存在的噪声伪影被放大,最终影响分解的基材料图像质量。目前的基材料图像分解方法在复杂场景下存在一些局限性,例如无法准确分解重叠的材料、容易受到噪声干扰等。为了提高低剂量 DECT 成像中基材料图像分解的质量和准确性,本章提出了一种基于多通道交叉卷积 UCTransNet 网络的基材料图像分解方法,该方法通过拟合分解映射函数来实现,网络被相应地设计成双入双出架构。将 DECT 图像以多通道形式输入,旨在实现网络中两条材料生成路径之间的信息交换。通道交叉融合和通道交叉注意力模块能够更好地捕捉复杂的通道相关性,从而更充分地进行特征提取和融合,进一步加强信息交换。为了提高模型拟合性能,使用混合损失对网络进行了训练。为了更好地适应 CT 图像数据的特殊性,本章提出一种基于 Sigmoid 函数的归一化方法对网络输入数据进行预处理。实验结果表明,在水骨基材料及软组织碘基材料图像分解任务中,所提方法能获得高质量的基材料图像,与对比方法相比,分解后基材料图像在准确度及噪声伪影抑制上表现更好。

4.1 分解模型与 MC-UCTransNet 网络设计

4.1.1 图像域基材料图像分解模型

通常材料分解的过程被表述为一个矩阵反演的不适定问题,这是由于在诊断 X 射线能量范围内,两个基材料的双能比 $\mu_{\text{H}} / \mu_{\text{L}}$ 没有显著差异,导致线性矩阵 A 上的条件数很大,直接求逆生成的基材料图像与原始 DECT 图像相比信噪比低,图像严重退化。此外这一分解过程受原 DECT 图像噪声影响较大,为减少这一影响,常采用正则化的约束方法来抑制分解后的基材料图像中的噪声。此时,图像域的基材料图像分解问题可表示为如下目标函数:

$$\min_{\vec{x}} (\vec{x} - A^{-1}\vec{\mu})^T (\vec{x} - A^{-1}\vec{\mu}) + \lambda \cdot R(\vec{x}) \quad (4-1)$$

其中 $\vec{\mu}$ 是一个由高低能图像组成的向量, $\vec{x}$ 为分解后基材料图像共同组成的向量, λ 为权重系数, $R(\vec{x})$ 是先验约束项, 用于约束分解后基材料图像的特定信息。这时 $R(\vec{x})$ 的设计在图像基材料分解领域中至关重要。虽然正则化约束类分解方法能获得高质量的基材料图像, 但其超参数多、算法复杂度高、处理时间长和数据不相容导致的稳定性差等问题, 限制了其临床应用, 难以充分发挥其价值。

为实现从 DECT 到基材料图像这一分解过程, 即对目标函数式 (4-1) 的求解, DL 方法可以将其简化为求解如下目标函数:

$$\min_M \left\| \vec{x} - M(\vec{\mu}) \right\|_2^2 \quad (4-2)$$

其中函数 $M(\bullet)$ 表示为从 DECT 到基材料图像之间的映射过程。这时函数 $M(\bullet)$ 在某种意义上为逆线性矩阵 A^{-1} 。为此, 基于深度学习的 DECT 材料分解任务可以表述为通过数据驱动的方式寻找一个近似的逆线性矩阵函数过程。近年来, 深度学习方法已成为解决医学成像中逆问题的一种重要方法和途径, 与传统方法相比具有更优异的性能和更快的处理速度, 已经越来越受人们重视。在 DECT 图像分解领域, DL 模型可通过捕获图像高层特征来显示其学习不确定噪声分布能力, 以有效地适应任意噪声类型, 能显著提高基材料图像分解能力及分解质量。

4.1.2 网络架构

如图 4-1 所示, 本章以 UCTransNet 网络为基础网络模型, 以软阈值分割结果作为标签图像, 将再重建得到的高低能图像拼接成多通道数据作为网络输入, 使用交叉卷积完成 DECT 图像特征信息交互, 相较于设计独立的两个网络来分别提取高低能 CT 图像特征, 能够更好地利用双能信息, 得到更为准确可靠的结果。UCTransNet 网络使用编码器-解码器架构, 其中编码器生成低分辨率图像特征, 解码器将特征上采样到基材料图像。为了防止编码器中提取的丰富特征信息丢失, 在编码器和解码器之间增加通道 Transformer 结构, 重复 L ($L=4$) 次以构建 L 层 Transformer, 最终第 L 层的四个输出通过上采样并分别与编码器特征进行残差连接被重构为 O_1 、 O_2 、 O_3 和 O_4 , 再通过与解码器特征 D_1 、 D_2 、 D_3 和 D_4 计算尺度权重对其进行加权得到 O_1 、 O_2 、 O_3 和 O_4 , 最后与解码器特征 D_1 、 D_2 、 D_3 和 D_4 进行级联, 用于实现编码器特征和解码器特征之间的特征融合。

如图 1 所示, UCTransNet 网络是在 U-Net 的基础上改进得到的, U-Net 具有捕获多层次特征信息的优势, 但其编码器和解码器之间存在语义鸿沟, 通过简单跳跃连接会影响模型最终性能。而 UCTransNet 使用了通道 Transformer (Channel Transformer, CTrans) 思想来取代 U-Net 中的跳跃连接, 以更好地融合编码器特征。通道 Transformer 由两个模块组成: 通道交叉融合 Transformer (Channel-wise Cross Fusion Transformer, CCT) 模块用于多尺度编码器特征融合, 通道交叉注意 (Channel-wise Cross Attention, CCA) 模块用于解码器特征和增强 CCT 特征的融合。




图 4-1 MC-UCTransNet 网络结构图

Fig. 4-1 Network architecture of MC-UCTransNet

为实现 DECT 图像的有效分解, 论文所使用的 UCTransNet 网络包括 4 个不同尺度: 第一个尺度的特征图 E_1 尺寸为 512×512 , 通道数为 64; 第二个尺度的特征图 E_2 尺寸下降为原来的 1/2, 通道数增加为原来的 2 倍; 第三个尺度的特征图 E_3 尺寸进一步下降为原来的 1/4, 通道数增加为原来的 4 倍; 第四个尺度的特征图 E_4 尺寸下降为原来的 1/8, 通道数增加为原来的 8 倍。编码器端, 不同尺度特征图采用 CCT 模块来捕获局部跨通道信息, 实现多尺度上下文与交叉注意力融合, 减缓可能存在尺度语义差距。解码器端, 使用 CCA 模块融合多尺度特征和解码器阶段的特征, 以解决语义层次不一致的问题, 提高网络对语义层次不一致的处理能力和对目标的感知能力。

CCT 模块结构：网络使用多尺度特征嵌入（Multi-scale Feature Embedding）获取图像在不同尺度上的特征表示 T_i （ $i=1,2,3,4$ ），通过层归一化（Layer Normalization, LN）处理将特征进行归一化，层归一化是通过计算每一层的输入数据的均值和方差来进行归一化的，并对归一化后的数据进行缩放和平移，以恢复数据的原始分布，从而提高模型的稳定性和收敛速度，再使用多头通道交叉注意（Multi-head Cross-Attention, MCA）进行自注意力计算。在 MCA 中，特征图被分为四个头（head），每个头都有自己的查询（ Q_i ）、键（ K ）和值（ V ）矩阵。通过计算查询和键之间的相似度，得到特征图的注意力权重，其中权重表示了每个通道对其它通道的重要性。将注意力权重应用于值矩阵，以加权融合不同通道的特征表示，从而捕捉不同通道之间的相关性，最后使用多层感知器（Multilayer Perceptron, MLP）学习一系列非线性映射，其中，该 MLP 由一个展平层和一个全连接层组成，进一步提取和表达特征之间的复杂关系。

CCA 模块结构：网络将 Transformer 的输出 O_i 与解码器特征 D_i 作为 CCA 的输入，再利用全局平均池化（Global Average Pooling, GAP）生成尺度权重，全局平均池化是对于每个输入特征图，将其所有的像素值进行平均，得到一个单一的值作为该特征图的池化输出。最后对不同尺度特征 O_i 进行加权得到 O_i ，进一步强调重要的尺度信息的融合。

4.1.3 混合损失函数

网络训练时采用了平均绝对误差（Mean Absolute Error, MAE）和结构相似性指数 SSIM 来构造适用于 DECT 基材料图像分解的混合损失函数^[77-79]。其中 MAE 损失的计算如下：

$$L^{\text{MAE}}(y, x) = \frac{1}{m} \sum_{i=1}^m |y_i - x_i| \quad (4-3)$$

其中 x 和 y 表示预测的基材料图像和对应的标签图像。 m 是像素的总数。下标 i 表示第 i 个像素。SSIM 指数计算如下：

$$E_{\text{SSIM}}(x_1, x_2) = \frac{(2\mu_{x_1}\mu_{x_2} + c_1)(2\sigma_{x_1, x_2} + c_2)}{(\mu_{x_1}^2 + \mu_{x_2}^2 + c_1)(\sigma_{x_1}^2 + \sigma_{x_2}^2 + c_2)} \quad (4-4)$$

其中， μ 表示图像的均值， σ^2 是图像的方差， σ_{x_1, x_2} 表示两个图像的协方差。 c_1 和 c_2 是与图像的值范围相关联的常数。这时 SSIM 损失可表示为：

$$L^{\text{SSIM}}(y, x) = 1 - E_{\text{SSIM}}(y, x) \quad (4-5)$$

整个网络时，其混合损失函数设计如下：

$$L = \alpha \cdot L^{\text{MAE}} + \beta \cdot L^{\text{SSIM}} \quad (4-6)$$

其中， α 和 β 为两个手动设置的超参数。

4.2 数据准备

4.2.1 基材料图像标签与 DECT 图像获取

实验中对 80kVp 和 140kVp 管电压下大小为 512×512 的 CT 图像进行加权软阈值分解获得基材料图。以制作骨头和组织基材料图像为例，加权软阈值算法实施过程为：将低于某个阈值 T_s 的像素认为是软组织，高于某个阈值 T_b 的像素视为骨骼，而处于两个阈值中间的像素可以将其视为两种材料的混合，根据该点像素值赋予其骨头和组织所占的权重。

为了模拟不同谱 CT 投影，需要知道 X 射线能谱和指定的能量段。实验中可进一步假设 X 射线能谱被划分成 M 个能量段，这时扇形射束扫描几何下的能谱 CT 投影，是来自第 m ($m=1, \dots, M$) 个能量窗口 ($\Delta E_m = E_{m+1} - E_m$) 沿着 X 射线路径 ℓ ($\ell=1, \dots, L$) 的光子数，计算过程可表示为：

$$z_{m\ell} = \int_{E_m}^{E_{m+1}} I_{m\ell}(E) \exp\left[\int_{r \in \ell} -\mu(E, r) dr\right] dE \quad (4-7)$$

其中衰减系数 $\mu(E, r)$ 为能量 E 下位置 r 处的线性衰减系数， $I_{m\ell}(E)$ 表示从 X 射线源发射的能量 E 的原始光子强度。由于成像对象仅考虑两种材料（骨头和软组织）， $\mu(E, r)$ 可以表示如下：

$$\mu(E, r) = \phi_b(E) \rho_b(r) + \phi_s(E) \rho_s(r) \quad (4-8)$$

其中， $\phi_b(E)$ 和 $\phi_s(E)$ 是能量 E 下骨和软组织的质量衰减系数，该系数可以通过检索美国国家标准与技术研究所（National Institute of Standards and Technology, NIST）报告（Hubbell & Seltzer, 1995）中的表格来确定^[80]。 $\rho_b(r)$ 和 $\rho_s(r)$ 表示骨和软组织在位置 r 处的占比。X 射线源光子通量 $I_{m\ell}^{(0)}$ 可以表示为：

$$I_{m\ell}^{(0)} = \int_{E_m}^{E_{m+1}} I_{m\ell}(E) dE \quad (4-9)$$

将式（4-8）和式（4-9）代入到等式（4-7），可以得到：

$$e_{m\ell} = \int_{E_m}^{E_{m+1}} r_{m\ell}(E) \exp \left[- \int_{r \in \ell} \phi_b(E) \rho_b(r) + \phi_s(E) \rho_s(r) dr \right] dE \quad (4-10)$$

其中, $e_{m\ell} = z_{m\ell} / I_{m\ell}^{(0)}$, $r_{m\ell}(E) = I_{m\ell}(E) / I_{m\ell}^{(0)}$ 表示 X 射线强度和探测器灵敏度的归一化能谱分布。最后, 通过对等式两侧进行对数运算, 得到能谱 CT 的投影数据:

$$p_{m\ell} = \ln \int_{E_m}^{E_{m+1}} r_{m\ell}(E) \exp \left[- \int_{r \in \ell} \phi_b(E) \rho_b(r) + \phi_s(E) \rho_s(r) dr \right] dE \quad (4-11)$$




图 4-2 DECT 图像生成流程图

Fig. 4-2 Flow chart of the DECT image generation

目前, 在给定数量的 CT 图像的情况下, 可以按照式 (4-11) 生成能谱 CT 投影, 然后利用统计迭代重建技术 (Statistical Iterative Reconstruction Technique, SIRT) 重建图像。图 4-2 为能谱 CT 数据模拟的流程图。可以看到生成流程图主要可以分为三个阶段: 基材料图像获取、能谱投影生成和能谱图像重建。实验中将 DECT 图像进行阈值分割以获取指定的基材料图像, 如骨骼和软组织。然后, 根据 X 射线发射光谱和材料衰减系数, 生成能谱 CT 投影数据。最后, 利用重建算法对能谱 CT 投影数据进行重建, 就模拟得到了不同扫描能量段的能谱图, 如 80kVp, 140kVp 的 DECT 图像。

4.2.2 数据预处理

考虑到 CT 图像像素 HU 值范围跨度较大这一特殊性,使用一般的“Min-Max 归一化方法”,可能会导致归一化后的数据失去数据的分布特征,且其对输入数据的异常值非常敏感,会影响模型在训练和预测中的表现。因此,实验中采用 Sigmoid 函数进行数据的归一化处理,将数据映射到一个较小的范围内,这样可以降低数据的偏度和峰度,使数据更接近正态分布,减小数据的尺度差异和模型对输入数据的敏感度,提高模型的鲁棒性。归一化表示公式如下:

$$y = \frac{1}{e^{-x/c}} \quad (4-12)$$

其中, x 为原始图像数据, y 为归一化后的图像数据, c 为常数,实验中将其设置为 1000,用于缩小数据范围,减小数值溢出风险。

4.3 实验结果与分析

4.3.1 基材料图像分解实验结果

(1) 骨-软组织基材料图像分解实验结果

实验在 TensorFlow 2.6、Python 3.8 以及显存为 24GB 的 NVIDIA GeForce RTX 4090 上进行,为了验证论文所设计的 MC-UCTransNet 网络在基材料图像分解任务中的有效性,实验选用矩阵反演 (Matrix Inversion)^[54]、迭代分解方法 (Iterative Decomposition)^[81]、全卷积网络 (Fully Convolutional Network, FCN)^[54]、蝴蝶型网络 (Butterfly Network, Butterfly-net)^[55]和 DIWGAN^[57]五种方法进行对比,其中矩阵反演和迭代分解方法是传统的基材料图像分解方法,FCN、Butterfly-net 和 DIWGAN 是深度学习方法。为定性分析分解图像质量,图 4-3 和图 4-4 中给出了两个部位 (Group 1 和 Group 2) 不同方法的基材料图像分解结果,图中第一列为骨骼和软组织基材料图像的真实标签,作为分解后的参考图像;第二列为直接矩阵反演生成的基材料图像,可以看出,生成的图像噪声较为明显,因为该方法仅线性地组合了来自高低能的图像,导致了噪声水平的放大。第三列为迭代分解后的结果,可以看到基材料图像中噪声和伪影得到了很好的抑制,但由于平滑正则化项的约束,分解后的组织基材料图像内部的纹理结构出现了严重的丢失,出现了过平滑现象。从实验结果图第四列中,可以发现 FCN 方法虽然

能够实现基材料图像的分解，但分解结果边缘和纹理依然不够清晰，整个图像同样过于平滑。而在图第五列蝴蝶型网络结果中，分解图像质量有了显著的提高，骨骼和组织的内部结构被较好地保留了，但部分细节结构上仍存在少量的丢失以及边缘模糊的现象。第六列为 DIWGAN 方法的分解结果，其分解质量相较于蝴蝶型网络也有一定的提升，但同样存在边缘模糊和少量细节丢失的情况。图 4-3 和图 4-4 中第七列为所提方法的分解结果，可以看到生成的骨和软组织图像在视觉效果上与标准图像相似，与对比方法相比，分解后的图像拥有更加清晰的材料图像边缘，组织纹理保持性能更理想，且噪声和伪影最少。




图 4-3 不同方法在 Group 1 测试集中的分解结果，其中第一行为骨基材料图，第二行为软组织基材料图。

Fig. 4-3 Decomposition results of different methods in the Group 1 test set, where the first row represents images with bone-based material, and the second row represents images with soft tissue-based material.




图 4-4 不同方法在 Group 2 测试集中的分解结果，其中第一行为骨基材料图，第二行为软组织基材料图。

Fig. 4-4 Decomposition results of different methods in Group 2 test set, where the first row represents images with bone-based material, and the second row represents images with soft tissue-based material.

不同方法分解后的骨材料和组织材料图像，量化结果如表 4-1、表 4-2 所示。从表中可以看出，MC-UCTransNet 在平均绝对误差 (Mean Absolute Error, MAE)、

均方误差（Mean Squared Error, MSE）、PSNR 和 SSIM 上的表现大部分优于其它五种方法，具有更好的分解精度和图像质量。与此同时，在骨材料及软组织的分解结果中量化方差也较小，这表明所设计网络模型具有更好的稳定性。

表 4-1 不同算法骨基材料（Bone）分解结果定量评价结果

Table 4-1. Quantitative scores of bone-based material decomposition with different methods

Methods	Matrix Inversion	Iterative Decomposition	FCN	Butterfly-net	DIWGAN	MC-UCTransNet
MAE (mean $\times 10^{-2} \pm \text{var} \times 10^{-8}$)	0.7676 ± 4.13	0.7953 ± 2.83	0.2218 ± 2.40	0.1299 ± 0.88	0.1022 ± 0.65	0.0924± 0.59
MSE (mean $\times 10^{-2} \pm \text{var} \times 10^{-9}$)	0.0479 ± 2.26	0.0434 ± 1.89	0.0366 ± 1.66	0.0115 ± 0.30	0.0108 ± 0.22	0.0098± 0.22
PSNR (mean $\pm \text{var}$)	32.6585 ± 0.21	33.0787 ± 0.20	33.8317 ± 0.24	38.8924 ± 0.47	39.1308 ± 0.35	39.5849± 0.46
SSIM (mean $\pm \text{var} \times 10^{-6}$)	0.9701 ± 4.02	0.9851 ± 0.88	0.9807 ± 0.94	0.9926 ± 0.77	0.9934 ± 0.54	0.9939± 0.65

表 4-2 不同算法组织基材料（Tissue）分解结果定量评价结果

Table 4-2. Quantitative scores of tissue-based decomposition results with different methods

Methods	Matrix Inversion	Iterative Decomposition	FCN	Butterfly-net	DIWGAN	MC-UCTransNet
MAE (mean $\times 10^{-2} \pm \text{var} \times 10^{-7}$)	2.7783 ± 2.05	2.4921 ± 2.30	0.5653 ± 0.15	0.2742 ± 0.06	0.2468± 0.04	0.2650 ± 0.04
MSE (mean $\times 10^{-2} \pm \text{var} \times 10^{-8}$)	0.2662 ± 0.83	0.2719 ± 1.03	0.0315 ± 7.06	0.0116 ± 0.008	0.0089 ± 0.006	0.0062± 0.003
PSNR (mean $\pm \text{var}$)	23.6462 ± 0.02	23.5547 ± 0.03	32.9346 ± 0.14	37.2569 ± 0.10	38.4406 ± 0.13	39.9546± 0.13
SSIM (mean $\pm \text{var} \times 10^{-5}$)	0.8589 ± 1.41	0.9321 ± 0.18	0.9574 ± 0.13	0.9871 ± 0.03	0.9888 ± 0.03	0.9904± 0.02

图 4-5 分别为不同分解方法在不同测试集上的骨和组织材料 PSNR 表现，Case1、Case2、Case3 和 Case4 分别代表四个测试集，从图中可看出，大部分情况下，深度学习类相较于传统分解方法能获更高信噪比，而 MC-UCTransNet 在测试集中的结果均优于对比算法，这一量化比较进一步证明该方法具有的鲁棒性。




图 4-5 四组测试集中不同方法的骨基材料（左）和软组织基材料（右）分解结果的 PSNR 值。其中，Case1、Case2、Case3、Case4 表示四个不同的测试集。

Fig. 4-5 PSNR values of bone-based materials (first left) and soft tissue-based materials (first right) decomposition results of different methods in four sets of test sets. Among them, Case1, Case2, Case3, and Case4 represent four different test sets.




图 4-6 四组测试集中不同方法的骨基材料（上）和软组织基材料（下）分解结果的 MAE/MSE/SSIM 值。其中，M1、M2、M3、M4、M5 和 M6 分别代表 Matrix Inversion、Iterative Decomposition、FCN、Butterfly-net、DIWGAN、MC-UCTransNet。

Fig. 4-6 MAE/MSE/SSIM values of bone-based materials (up) and soft tissue-based materials (bottle) decomposition results of different methods in four sets of test sets. Among them, M1, M2, M3, M4, M5 and M6 represent Matrix Inversion, Iterative Decomposition, FCN, Butterfly-net, DIWGAN, MC-UCTransNet, respectively.

图 4-6 分别为不同分解方法在不同测试集上骨和组织材料的 MAE/MSE/SSIM 表现。通过对比可以看出，不同分解方法在骨材料上的表现均优于组织材料上的表现，迭代分解方法比矩阵反演和 FCN 有更好的结构保持能力，与传统方法和 FCN 相比，Butterfly-net、DIWGAN 在骨头和组织分解图像上的 MAE、MSE 和 SSIM 均有显著提升，而 MC-UCTransNet 在组织分解图像的效果上取得了与 DIWGAN 相近的结果，在骨分解图像的表现要优于 Butterfly-net 方法。这也表明论文所提方法在基材料图像分解的质量及结构保持上取得了较好的性能。




图 4-7 不同方法得到的分解结果的低能重建图。第一列为参考的低能图像，第二至第五列分别为 FCN、Butterfly-net、DIWGAN 及 MC-UCTansNet 的重建图像。

Fig. 4-7 Low-energy reconstruction plots of the decomposition results obtained by different methods. The first column is the reference low-energy image, and the second to fifth columns are the reconstructed images of FCN, Butterfly-net, DIWGAN and MC-UCTansNet, respectively.

为进一步分析比较深度学习方法的分解精度，实验中对不同深度学习方法分解得到的图像再重建回 CT 图像，其结果如图 4-7 所示。图 4-7 中的 (a) 为原始低能 (80kVp) CT 图像。图 4-7 (b) 为 FCN 方法分解的基材料图像重建结果，可以看到图像内部出现了一些器官轮廓，但是图像过于平滑，在纹理和细节结构显示方面存在不足。图 4-7 (c) 为 Butterfly-net 分解的基材料图像重建结果，可以看到图像有了清晰的纹理和细节，已经较为接近原始的低能 CT 图像。图 4-7 (d) 为 DIWGAN 分解的基材料图像重建结果，取得了与 Butterfly-net 方法相似的结果，但重建图中存在有一些条状伪影。而图 4-7 (e) 为使用 MC-UCTansNet 分解并重建得到的图像，整体图像质量优于 Butterfly-net 和 DIWGAN 方法的重建结果，重建图中没有出现条状伪影，且图像细节保留较好。图 4-8 (a) - (d) 为对应方法重建图与原始低能图像之间的差异图。从差异图中可以看到，FCN 方法在组织材料上拟合效果较好，但在骨材料的拟合上还有所欠缺，Butterfly-net 方法则进一步改善了骨和组织的拟合效果，大大缩小了解析再重建与原始图像之间的差异，DIWGAN 方法在骨材料的一些小区域上存在明显差异，表明其在该区

域的重建效果较差，而本文所提的 MC-UCTransNet 取得更好的拟合结果，它的基材料重建图像与原始低能图像之间的差异最小。




图 4-8 不同方法得到的分解结果的低能重建图与参考低能图像之间的差异图。第一至第四列分别为 FCN、Butterfly-net、DIWGAN 及 MC-UCTransNet 的重建图像对应的差异图。

Fig. 4-8 Difference between reference low energy images and the decomposition results obtained by different methods. The first to fourth columns show the difference image corresponding to the reconstructed images of FCN, Butterfly-net, DIWGAN and MC-UCTransNet, respectively.

(2) 碘-软组织基材料图像分解实验结果

为验证论文所提方法在不同分解任务中的性能，实验进一步验证了其在胸部碘和软组织基材料图像分解中的效果，图 4-9 和图 4-10 为不同方法分解后的结果图。图 4-9 和图 4-10 中第一列为标签图像，第二第三列分别为矩阵反演和迭代分解方法获得碘和软组织基材料图像，可以发现分解后的基材料图像出现了明显的细节丢失，组织材料中的感兴趣区域轮廓也并不清晰。图 4-9 和图 4-10 中第四列为 FCN 方法的分解结果，虽然感兴趣区域轮廓较为清晰，但其碘基图像的骨头出现了大面积丢失，同时，软组织基图像中也出现了一些错误结构。第五列为 Butterfly-net 方法的分解结果，较前三种方法分解图像质量有了明显的提升，

但其边缘仍存在一定程度的模糊。第六列为 DIWGAN 方法的分解结果，虽然相较于 Butterfly-net 方法边缘更为清晰，但仍存在一些错误结构。图中第七列为 MC-UCTransNet 方法的分解结果，可以看到分解后的基材料图像边缘结构较清晰，图像对比度高。




图 4-9 不同方法在 Group 1 测试集中的分解结果，其中第一行为碘基材料图，第二行为软组织基材料图。

Fig. 4-9 Decomposition results of different methods in the Group 1 test set, where the first row represents images with iodine-based material, and the second row represents images with soft tissue-based material.




图 4-10 不同方法在 Group 2 测试集中的分解结果，其中第一行为碘基材料图，第二行为软组织基材料图。

Fig. 4-10 Decomposition results of different methods in the Group 2 test set, where the first row represents images with iodine-based material, and the second row represents images with soft tissue-based material.

不同方法分解后的碘材料和组织材料图像，量化结果如表 4-3、表 4-4 所示。从表中可以看出，MC-UCTransNet 除去在碘材料上的 SSIM 表现略低于 Butterfly-net 以及在 MAE 上的表现略低于 DIWGAN，在 MAE、MSE、PSNR 和 SSIM 上的表现均优于其它五种方法，具有更好的分解精度和图像质量。在碘材料及软组织的分解结果中量化方差也较小，这表明所设计网络模型具有更好的稳定性。

表 4-3 不同算法碘基材料 (Iodine) 分解结果定量评价结果

Table 4-3. Quantitative scores of iodine-based material decomposition results of different methods

Methods	Matrix Inversion	Iterative Decomposition	FCN	Butterfly-net	DIWGAN	MC-UCTransNet
MAE ($\text{mean} \times 10^{-2} \pm \text{var} \times 10^{-8}$)	1.0684 $\pm$ 73.29	1.0729 $\pm$ 77.35	0.2807 $\pm$ 3.22	0.1634 $\pm$ 0.51	0.1157$\pm$0.95	0.1427 $\pm$ 0.43
MSE ($\text{mean} \times 10^{-2} \pm \text{var} \times 10^{-9}$)	0.0613 $\pm$ 3.26	0.0649 $\pm$ 3.87	0.0322 $\pm$ 1.04	0.0042 $\pm$ 0.04	0.0052 $\pm$ 0.06	0.0040$\pm$0.01
PSNR ($\text{mean} \pm \text{var}$)	31.6845 $\pm$ 0.25	31.4407 $\pm$ 0.26	34.4763 $\pm$ 0.25	43.3787 $\pm$ 0.34	42.3866 $\pm$ 0.33	43.5526$\pm$0.13
SSIM ($\text{mean} \pm \text{var} \times 10^{-6}$)	0.9667 $\pm$ 6.22	0.9793 $\pm$ 4.38	0.9753 $\pm$ 1.89	0.9948$\pm$0.10	0.9940 $\pm$ 0.22	0.9947 $\pm$ 0.14

表 4-4 不同算法软组织基材料 (Tissue) 分解结果定量评价结果

Table 4-4. Quantitative scores of soft tissue-based material decomposition results with different methods

Methods	Matrix Inversion	Iterative Decomposition	FCN	Butterfly-net	DIWGAN	MC-UCTransNet
MAE ($\text{mean} \times 10^{-2} \pm \text{var} \times 10^{-7}$)	2.3850 $\pm$ 6.30	2.2024 $\pm$ 5.85	0.6133 $\pm$ 0.43	0.4009 $\pm$ 0.17	0.3295$\pm$0.24	0.3466 $\pm$ 0.16
MSE ($\text{mean} \times 10^{-2} \pm \text{var} \times 10^{-8}$)	0.2148 $\pm$ 1.96	0.2202 $\pm$ 1.98	0.0313 $\pm$ 0.04	0.0115 $\pm$ 0.08	0.0125 $\pm$ 0.02	0.0112$\pm$0.03
PSNR ($\text{mean} \pm \text{var}$)	24.5465 $\pm$ 0.08	24.4386 $\pm$ 0.08	32.9122 $\pm$ 0.08	36.3110 $\pm$ 0.58	36.9219 $\pm$ 0.22	37.3843$\pm$0.37
SSIM ($\text{mean} \pm \text{var} \times 10^{-5}$)	0.8732 $\pm$ 2.19	0.9317 $\pm$ 0.47	0.9539 $\pm$ 0.23	0.9807 $\pm$ 0.19	0.9814 $\pm$ 0.11	0.9815$\pm$0.15

4.3.2 网络设计消融实验

为了验证方法的有效性, 实验中进一步对通道注意力机制、损失函数和归一化预处理三个模块进行了验证。实验采用了无注意力的 U-Net 方法验证通道注意力对于 DECT 基材料图像分解问题的适用性, 使用仅包含 MAE 的损失函数验证结构相似性损失对分解结果的促进作用, 并使用最大最小归一化验证提出的归一化方法对于分解后图像质量的提升效果。

不同模块有效性的验证结果见表 4-5 和表 4-6。从表格 4-5 和表 4-6 中的第二列可以看出, 在没有引入通道注意力机制时, 模型的预测结果受限于特征提取和特征融合的能力, 导致在高低能图像之间的信息交换上表现不佳, 影响最终分解图像的量化指数。然而, 当引入通道注意力机制后, 可以有效提取特征并进行特征融合, 从而获得更准确的分解结果。进一步考虑加入 SSIM 的混合损失函数的有效性, 通过比较表 4-5 和表 4-6 中的第三列数据, 可以看出量化结果均有所下降, 这验证了混合损失函数在基材料图像分解任务中的有效性。通过结合 MAE 损失和 SSIM 损失, 能够更好的优化模型, 提高基材料图像分解结果的准确性。最后, 实验验证了最大最小归一化的数据进行预处理方法的有效性, 通过比较表 4-5 和表 4-6 中第四列和第五列的量化结果, 可以看到采用最大最小归一化预处

理方法，其分解后的基材料图像的 PSNR 出现了显著下降，这也验证论文采用基于 Sigmoid 的归一化方法的有效性，通过这种预处理方法，可有效降低异常数据对分解结果的影响。

表 4-5 不同模型下骨基材料（Bone）分解结果的定量评价

Table 4-5. Quantitative scores of bone-based material image under different models

Methods	(w/o) Attention	(w/o) SSIM	Max-Min normalization	MC-UCTransNet
MAE ($\text{mean} \times 10^{-2} \pm \text{var} \times 10^{-8}$)	0.1271 $\pm$ 1.09	0.1772 $\pm$ 1.56	0.0933 $\pm$ 0.65	0.0924$\pm$0.59
MSE ($\text{mean} \times 10^{-2} \pm \text{var} \times 10^{-10}$)	0.0129 $\pm$ 3.09	0.0123 $\pm$ 2.51	0.0085$\pm$1.55	0.0098 $\pm$ 2.17
PSNR ($\text{mean} \pm \text{var}$)/dB	38.3890 $\pm$ 0.37	38.5899 $\pm$ 0.34	35.4132 $\pm$ 0.50	39.5849$\pm$0.46
SSIM ($\text{mean} \pm \text{var} \times 10^{-7}$)	0.9912 $\pm$ 9.33	0.9917 $\pm$ 8.66	0.9932 $\pm$ 8.35	0.9939$\pm$6.53

表 4-6 不同模型下软组织基材料（Tissue）分解结果的定量评价

Table 4-6. Quantitative scores of decomposition results of soft tissue-based material image under different models

Methods	(w/o) Attention	(w/o) SSIM	Max-Min normalization	MC-UCTransNet
MAE ($\text{mean} \times 10^{-2} \pm \text{var} \times 10^{-7}$)	0.3258 $\pm$ 0.13	0.4766 $\pm$ 1.11	0.2369$\pm$0.07	0.2650 $\pm$ 0.04
MSE ($\text{mean} \times 10^{-2} \pm \text{var} \times 10^{-10}$)	0.0159 $\pm$ 3.10	0.0278 $\pm$ 6.91	0.0069 $\pm$ 0.41	0.0061$\pm$0.27
PSNR ($\text{mean} \pm \text{var}$)/dB	35.9114 $\pm$ 0.22	33.4747 $\pm$ 0.17	29.9182 $\pm$ 0.16	39.9546$\pm$0.13
SSIM ($\text{mean} \pm \text{var} \times 10^{-6}$)	0.9832 $\pm$ 0.91	0.9826 $\pm$ 0.92	0.9859 $\pm$ 2.02	0.9904$\pm$0.15




图 4-11 损失函数在不同超参数组合下的测试集中的 PSNR 和 SSIM

Fig. 4-11 PSNR and SSIM in the test set for the loss function under different combinations of hyperparameters.

为了确定最佳的混合损失函数权重超参数组合，论文使用网格搜索法进行超参数检索，分别将 α 和 β 作为 MAE 和 SSIM 的权重超参数。为了保证权重的相

对均衡性、控制总体损失的大小，论文将这两个权重超参数之和设置为 1，同时根据经验，设置 α 取值范围为[0.2, 1]， β 取值范围为[0, 0.8]。图 4-11 为不同超参数组合下的测试集 PSNR 曲线，从图中可以看出使用 $\alpha = 0.75$ 、 $\beta = 0.25$ 时，获得的 PSNR 和 SSIM 值较高。

为了确定最佳的通道注意力结构，对网络通道注意力模块使用的不同组合的特征融合尺度进行测试，其量化结果如表 4-7 所示。从表 4-7 中可以看到，使用所有的特征融合尺度（记为 $E_1 + E_2 + E_3 + E_4$ ）的情况下可以获得最佳的性能，其 PSNR 和 SSIM 分别为 39.5849 dB 和 0.9939（Bone）、39.9546 dB 和 0.9904（Tissue），也是所有模型中最高的。当去除最低尺度的特征融合（ E_1 ）时，性能稍微下降。仅使用第二第三与第四尺度融合（记为 $E_2 + E_3 + E_4$ ）时，PSNR 和 SSIM 分别为 38.0509 dB 和 0.9922（Bone）、35.6849 dB 和 0.9857（Tissue）。当仅使用最高尺度的特征融合（记为 $E_3 + E_4$ ）时，量化指标仅略低于使用所有尺度的情况，其 PSNR 和 SSIM 分别达到 39.4329 dB 和 0.9934（Bone）、38.8624 dB 和 0.9892（Tissue）。当不使用通道注意力模块时，性能明显下降。没有注意力的情况下，PSNR 和 SSIM 分别为 38.3890 dB 和 0.9912（Bone）、35.9114 dB 和 0.9832（Tissue）。上述实验结果表明，论文所使用的特征融合尺度并结合通道注意力模块可以获得更好的基材料图像分解性能。

表 4-7 不同尺度特征组合下的模型分解结果量化比较

Table 4-7. Quantitative comparison of model decomposition results under feature combinations of different scales

Models	Bone		Tissue	
	PSNR /dB	SSIM	PSNR /dB	SSIM
$E_1 + E_2 + E_3 + E_4$	39.5849	0.9939	39.9546	0.9904
$E_2 + E_3 + E_4$	38.0509	0.9922	35.6849	0.9857
$E_3 + E_4$	39.4329	0.9934	38.8624	0.9892
(w/o) Attention	38.3890	0.9912	35.9114	0.9832

通过相关的消融实验，其结果表明，当引入通道注意力机制后，能更高效提取特征并进行特征融合，训练时采用混合损失函数在基材料图像分解任务中起到了重要作用，并且使用基于 Sigmoid 的归一化方法能够降低异常数据的影响，从而改善分解结果的准确性。这些实验证据进一步验证了论文所采用的方法的有效性。

4.3.3 网络收敛性与复杂性分析

图 4-12 为不同网络模型在训练集（上）和验证集（下）上的 loss 曲线图。可以看到，在训练初始阶段，MC-UCTransNet 的初始损失值较低；随着训练的进行，DIWGAN 的损失下降最快；在收敛阶段，MC-UCTransNet 的最终收敛点损失值最小。整体上来看，MC-UCTransNet 网络在训练过程中的损失曲线收敛较为平稳，具有较好的稳定性和鲁棒性。而 MC-UCTransNet 和 DIWGAN 网络的验证集 loss 曲线相较于其它两种网络波动性和最终收敛点损失值最小。图 4-13 为不同网络模型在训练集（上）和验证集（下）上的 PSNR 曲线图，在训练集上，MC-UCTransNet 网络的初始 PSNR 较高，曲线波动较小，且收敛速度最快，Butterfly-net 的最终收敛点 PSNR 值最大，但在验证集上，MC-UCTransNet 网络的最终收敛点 PSNR 值要优于 Butterfly-net。表 4-8 为不同算法的复杂度情况对比。从表中可以看到，虽然论文所提方法参数量较大，但其计算量并没有增加多少，训练时间与对比算法相当。从测试计算时间来看，论文所提方法时间较长，后续将进一步研究提高其测试效率的方法。




图 4-12 不同网络模型在训练集及验证集上的 loss 收敛性情况

Fig. 4-12 Convergence of loss on different network in training and validation sets.




图 4-13 不同网络模型在训练集及验证集上的 PSNR 收敛性情况

Fig. 4-13 Convergence of PSNR on different network in training and validation sets.

表 4-8 不同算法的复杂情况对比

Table 4-8. Comparison of the complexity of different models

Methods	Parameters(M)	FLOPs(G)	Train time(min)	Test time(s)
FCN	49	448	92	24
Butterfly-net	3	1702	106	20
DIWGAN	19	1905	128	43
MC-UCTransNet	67	354	94	110

4.4 本章小结

本章针对 DECT 基材料图像分解时存在的噪声伪影大、精度低等问题，提出了一种基于多通道交叉卷积的 UCTransNet 模型，提高了 DECT 基材料图像的分解效果。DECT 图像具有能谱相关性和空间相关性，使用多通道交叉卷积方式进行特征提取，能获得更丰富、更准确的特征表示。另外，借助通道交叉融合变换和通道交叉注意模块可进一步从特征通道信息维度上提高 DECT 图像中的信息交互程度。相较于使用多个网络进行高低能信息特征提取与特征共享的方式，本章所提网络具有更好的简洁性和交互性。与此同时，在网络训练时，采用混合损失函数及使用基于 Sigmoid 归一化的数据预处理方法，可促进分解图像中的噪声

伪影抑制和组织结构细节信息的保持。对比实验和消融实验的结果表明，该算法在噪声抑制、定量和定性评价方面具有普遍优势。后续研究可进一步提高分解效率，同时可考虑扩展为多材料分解模型，以提升其应用面。

第 5 章 总结与展望

5.1 论文总结

在现代临床医学实践中，CT 技术的应用范围已相当普遍，但扫描时产生的 X 射线辐射可能导致患者遭受二次损伤，增加致癌率。鉴于此，在低辐射剂量条件下实现高保真图像重建的研究具有重大意义。另外，传统 CT 扫描方法依赖连续能谱 X 射线穿过人体后的平均衰减效应生成图像，未考虑不同物质对光子能量的吸收特性差异，致使重建图像中普遍存在射束硬化伪影与异物同形现象。而 DECT 通过采集两个独立能量区间的人体衰减数据，结合基材料图像分解技术，可实现对各类组织的定性与定量分析，显著提升造影区域与软组织辨识的精确性。因此，针对低剂量 DECT 数据进行精准的基材料图像分解，是解决当前 CT 技术发展所面临问题的关键途径。一方面，剂量降低会直接导致重建图像噪声水平上升，进而严重影响基材料分解的准确性。另一方面，在 DECT 图像基材料图像分解过程中，射束硬化伪影与噪声的干扰常导致误差放大，可能影响临床诊断的可靠性。本论文聚焦低剂量 DECT 成像的核心问题，首先将训练完成的扩散模型正则化项融入迭代重建算法，有效改善了低剂量 DECT 数据的重建质量，减少了噪声与伪影；随后采用多通道交叉卷积 UCTransNet 网络对重建图像进行基材料分解；最终实现了在低辐射剂量条件下 DECT 基材料图像的精确分解。主要工作可以总结为以下两方面：

1. 基于混合谱数据生成扩散模型的 DECT 稀疏重建

稀疏角度 DECT 重建图像由于投影数据信息不足，往往存在大量噪声和伪影，这些干扰因素严重影响了病灶检测的准确性。针对这一问题，论文第三章从交错扫描采集稀疏角度 DECT 图像数据入手，采用小波空间扩散模型和图像空间扩散模型对高、低能图像数据的对数概率密度函数梯度进行精确建模，学习真实的数据分布，再利用学习到的梯度信息逐步去除噪声，恢复图像信息。将迭代重建算法展开到一个统一的采样过程，通过交替更新的方式保证生成图像的质量。另外，将叠加后的高低能 CT 图像数据用于 HSGDM 的训练和推理，使网络在学习和预测过程中可同时借助 DECT 图像数据的空间分布和能谱相关性有效保留结构纹理信息。实验结果表明，HSGDM 方法获得的图像在主观视觉评价和客观

量化指标方面均展现出显著优势。与对比方法重建图像比较, HSGDM 方法克服了现有诸多算法在噪声伪影去除过程中会损失图像细节的问题, 在 CT 值的精度、细节的保留和伪影的消除方面具有竞争力。以 30 个稀疏角度的重建为例, 测试数据集上的 PSNR 增加了 3.51 dB, SSIM 增加了 0.03, FID 分数降低了 74.47。实现了低剂量条件下高质量的 DECT 图像重建, 进一步为后续的 DECT 基材料图像分解提供优质的数据源。

2. 基于多通道交叉卷积 UCTransNet 的双能 CT 基材料图像分解方法

传统的图像域 DECT 基材料图像分解算法由于重建后的高低能图像依然存在少量噪声以及射束硬化伪影从而导致分解不准确。论文第四章提出一种多通道交叉卷积 UCTransNet 网络来提高基材料图像分解的准确性。以双入双出和多通道交叉卷积形式模拟基材料图像分解数学模型中的映射函数。在基材料图像分解过程中两个通道数据之间施加通道交叉融合转换器和通道交叉注意模块用于加强网络模拟映射函数的能力。网络训练的目标函数为由 MAE 损失、SSIM 损失构成的混合损失函数, 从而保证网络输出的基材料图像中组织细节结构清晰、边缘结构完整。此外, 考虑到 DECT 图像的数据特殊性, 提出一种基于 Sigmoid 的归一化方法专用于 CT 数据的归一化处理, 用于降低数据的偏度和峰度, 降低模型对于数据的敏感性, 提高模型的稳定性和数据拟合能力。实验结果表明, MC-UCTransNet 在分解精度与基材料图像生成质量方面均展现出优越性能, 相较于对比方法分解质量有显著提升。此外, 将分解图合并重建回 DECT 图像的测试结果也进一步表明了 MC-UCTransNet 基材料图像分解方法用于 DECT 图像基材料分解的可靠性, 并在消融实验设计中验证了网络各模块的有效性, 具有较高的应用前景。

5.2 研究展望

本论文聚焦于深度学习框架下的低剂量 DECT 图像重建与基材料图像分解技术研究。首先从低剂量 DECT 数据入手对稀疏扫描数据进行噪声去除, 然后对重建后的图像完成了精确的基材料图像分解。该方法能够对低剂量 DECT 技术的进一步发展起到积极的促进作用。然而, 尽管这些方法在处理低剂量 DECT 基材料图像分解时表现出色, 但目前依然存在部分内容有待进一步研究与改进:

(1) HSGDM 和 MC-UCTransNet 网络模型计算复杂度高。对于 HSGDM 方法：首先，需要在重建框架中训练和应用两个 SDE 模型；其次，HSGDM 重建需要近 2,000 个采样步骤，这都会增加模型的计算成本。而对于 MC-UCTransNet 方法而言，其中使用的注意力模块大大增加了模型的数量，模型训练和推理时需要占用大量的计算资源，这也导致了时间成本相应地增加。未来研究需探索在保证 DECT 图像重建和基材料图像分解质量的同时，降低计算需求，提升实用性。同时，当前的 PSNR、SSIM 和 FID 等图像质量评估指标在诊断应用中的局限性也值得关注，需要寻找更全面的评估手段来评价处理后的 CT 图像。

(2) 为了提高研究方法的实应用价值，论文应更深入地结合临床实践，包括构建适应临床的模型、开发处理算法、设计评价和优化策略。由于临床数据的不足，部分处理效果的验证仍有欠缺。后续工作可侧重于以实际临床任务为导向的成像及基材料图像处理研究。

为了改善 HSGDM 和 MC-UCTransNet 模型计算量大的问题，未来的研究可侧重于降低测试时间以提高实用性的策略。例如，对于 HSGDM 这种深度迭代重建模型而言，可以使用隐藏空间采样和先验信息蒸馏等技术提高模型的图像恢复能力和效率^[82-83]。同时，还需要对 Transformer 学习理论进一步深入研究，设计专门适用于 DECT 数据通道信息交换的 Transformer 模块，以减少计算成本并提高图像质量。此外，针对成像效果的评价标准，论文中使用了常用的 PSNR, SSIM 和 FID 来综合评价图像质量好坏，后续可进一步建立更加完善的评价体系对处理后的图像进行评估，如邀请临床医生作为观察者，对噪声伪影抑制、解剖结构保真等多方面进行盲评。临床应用评估也是重要的指标，量化比较稀疏角度 DECT 图像质量改进所带来的临床应用精度的提升，同时还需进一步探究高质量稀疏角度 DECT 图像在诊断中的临床价值。未来还需继续探索并设计更优异的深度神经网络模型，以进一步减少扫描角度降低辐射剂量，能在极度稀疏角度的情况下复原出可利用的 DECT 数据，做到真正有价值的低剂量成像。

参考文献

- [1] Brenner D J, and Hall E J. Computed tomography-an increasing source of radiation exposure[J]. New England Journal of Medicine, 2007, 357(22): 2277-2284.
- [2] 张彦彩, 朱小忠. 螺旋 CT 低剂量扫描研究进展[J]. 中国医学影像技术, 2010, 26(007): 1376-1378.
- [3] Park H S, Hwang D, and Seo J K. Metal artifact reduction for polychromatic X-ray CT based on a beam-hardening corrector[J]. IEEE Transactions on Medical Imaging, 2015, 35(2): 480-487.
- [4] Alvarez R E, and Macovski A. Energy-selective reconstructions in x-ray computerized tomography[J]. Physics in Medicine & Biology, 1976, 21(5): 733-744.
- [5] Xing Y, Zhang L, Duan X, et al. A reconstruction method for dual high-energy CT with MeV X-rays[J]. IEEE Transactions on Nuclear science, 2011, 58(2): 537-546.
- [6] Li L, Chen Z, and Jiao P. Dual-energy CT reconstruction based on dictionary learning and total variation constraint[C]. 2012 IEEE Nuclear Science Symposium and Medical Imaging Conference Record (NSS/MIC), 2012: 2358-2361.
- [7] Zhang Y, Lv T, Ge R, 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.
- [8] Wang S, Yu H, Xi Y, et al. Spectral-image decomposition with energy-fusion sensing for spectral CT reconstruction[J]. IEEE Transactions on Instrumentation and Measurement, 2021, 70: 1-11.
- [9] Wu W, Hu D, An K, et al. A high-quality photon-counting CT technique based on weight adaptive total-variation and image-spectral tensor factorization for small animals imaging[J]. IEEE Transactions on Instrumentation and Measurement, 2020, 70: 1-14.
- [10] Zhu G, Zhang Y, Mao W, et al. Multi-Stage Dual-domain Networks with Informative Prior and Self-Augmentation for Dual-Energy Limited-Angle CT Reconstruction[J]. IEEE Transactions on Instrumentation and Measurement, 2024, 73: 1-12.
- [11] Zhao B, Gao H, Ding H, et al. Tight-frame based iterative image reconstruction for spectral breast CT[J]. Medical physics, 2013, 40(3): 031905.
- [12] Semerci O, Hao N, Kilmer M E, et al. Tensor-based formulation and nuclear norm regularization for multienergy computed tomography[J]. IEEE Transactions on Image Processing, 2014, 23(4): 1678-1693.
- [13] Li B, Shen C, Chi Y, et al. Multienergy cone-beam computed tomography reconstruction with a spatial spectral nonlocal means algorithm[J]. SIAM journal on imaging sciences, 2018, 11(2): 1205-1229.

- [14] Zhang H, Zeng D, Lin J, et al. Iterative reconstruction for dual energy CT with an average image-induced nonlocal means regularization[J]. *Physics in Medicine & Biology*, 2017, 62(13): 5556-5574.
- [15] Wu W, Zhang Y, Wang Q, et al. Low-dose spectral CT reconstruction using image gradient ℓ_0 -norm and tensor dictionary[J]. *Applied Mathematical Modelling*, 2018, 63: 538-557.
- [16] Wu W, Wang Q, Liu F, et al. Block matching frame based material reconstruction for spectral CT[J]. *Physics in Medicine & Biology*, 2019, 64(23): 235-246.
- [17] Hu D, Wu W, Xu M, et al. SISTER: Spectral-image similarity-based tensor with enhanced-sparsity reconstruction for sparse-view multi-energy CT[J]. *IEEE Transactions on Computational Imaging*, 2019, 6(1): 477-490.
- [18] He Y, Zeng L, Xu Q, et al. Spectral CT reconstruction via low-rank representation and structure preserving regularization[J]. *Physics in Medicine & Biology*, 2023, 68(2): 025011.
- [19] Chen Z, Gao Q, Zhang Y, et al. ASCON: Anatomy-aware supervised contrastive learning framework for low-dose CT denoising[C]. *International Conference on Medical Image Computing and Computer-Assisted Intervention*, 2023: 355-365.
- [20] He J, Wang Y, Yang Y, et al. LdCT-Net: low-dose CT image reconstruction strategy driven by a deep dual network[C]. *Medical Imaging 2018: Physics of Medical Imaging*, 2018, 10573: 891-896.
- [21] Chen H, Zhang Y, Chen Y, et al. LEARN: Learned experts' assessment-based reconstruction network for sparse-data CT[J]. *IEEE transactions on medical imaging*, 2018, 37(6): 1333-1347.
- [22] Zhang W, Wang L, Li L, et al. Reconstruction method for DECT with one half-scan plus a second limited-angle scan using prior knowledge of complementary support set (Pri-CSS)[J]. *Physics in Medicine & Biology*, 2020, 65(2): 025005.
- [23] Xiang J, Dong Y, and Yang Y. 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.
- [24] Zhang C, Li Y, and Chen G H. Accurate and robust sparse-view angle CT image reconstruction using deep learning and prior image constrained compressed sensing (DL-PICCS)[J]. *Medical physics*, 2021, 48(10): 5765-5781.
- [25] Wu W, Guo X, Chen Y, et al. Deep embedding-attention-refinement for sparse-view CT reconstruction[J]. *IEEE Transactions on Instrumentation and Measurement*, 2022, 72: 1-11.
- [26] Liu J, Zhang T, Kang Y, et al. Deep residual constrained reconstruction via learned convolutional sparse coding for low-dose CT imaging[J]. *Biomedical Signal Processing and Control*, 2023, 85: 1048-1068.

- [27] Xia W, Yang Z, Lu Z, et al. RegFormer: A local–nonlocal regularization-based model for sparse-view CT reconstruction[J]. IEEE Transactions on Radiation and Plasma Medical Sciences, 2023, 8(2): 184-194.
- [28] Kang Y, Liu J, Wang K, et al. Deep convolutional dictionary learning network for sparse view CT reconstruction with a group sparse prior[J]. Computer Methods and Programs in Biomedicine, 2024, 244: 108010.
- [29] Guan B, Yang C, Zhang L, et al. Generative modeling in sinogram domain for sparse-view CT reconstruction[J]. IEEE Transactions on Radiation and Plasma Medical Sciences, 2023, 8(2): 195-207.
- [30] Xia W, Cong W, and Wang G. Patch-based denoising diffusion probabilistic model for sparse-view CT reconstruction. arXiv preprint arXiv:2211.10388, 2022.
- [31] Liu J, Anirudh R, Thiagarajan J J, et al. Dolce: A model-based probabilistic diffusion framework for limited-angle CT reconstruction[C]. Proceedings of the IEEE/CVF International conference on computer vision, 2023: 10498-10508.
- [32] Xia W, Shi Y, Niu C, et al. Diffusion prior regularized iterative reconstruction for low-dose CT. arXiv preprint arXiv:2310.06949, 2023.
- [33] Chung H, Ryu D, McCann M T, et al. Solving 3d inverse problems using pre-trained 2d diffusion models[C]. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2023: 22542-22551.
- [34] Lee S, Chung H, Park M, et al. Improving 3D imaging with pre-trained perpendicular 2D diffusion models[C]. Proceedings of the IEEE/CVF International Conference on Computer Vision, 2023: 10710-10720.
- [35] Liu Y, Zhou X, Wei C, et al. Sparse-view spectral CT reconstruction and material decomposition based on multi-channel SGM[J]. IEEE Transactions on Medical Imaging, 2024.
- [36] Li Y, Sun X, Wang S, et al. Generation model meets swin transformer for unsupervised low-dose CT reconstruction[J]. Machine Learning: Science and Technology, 2024, 5(2): 025005.
- [37] Fernsel P, Kereta Ž, and Denker A. Convergence Properties of Score-Based Models for Linear Inverse Problems Using Graduated Optimisation[C]. 2024 IEEE 34th International Workshop on Machine Learning for Signal Processing (MLSP), 2024: 1-6.
- [38] Su T, Sun X, Yang J, et al. DIRECT-Net: a unified mutual-domain material decomposition network for quantitative dual-energy CT imaging[J]. Medical physics, 2022, 49(2): 917-934.
- [39] 符慧娟, 席晓琦, 韩玉, 等. 基于深层残差编解码的显微CT图像去噪算法[J]. 激光与光电子学进展, 2023, 60(14): 1410014.
- [40] 龙超, 金恒, 黎玲, 等. 基于特征融合的非局部均值CT图像降噪[J]. 光学学报, 2022, 42(11): 1134024.

- [41] Kelcz F, Joseph P M, and Hilal S K. Noise considerations in dual energy CT scanning[J]. Medical Physics, 1979, 6(5): 418-425.
- [42] Zhao W, Niu T, Xing L, et al. Using edge-preserving algorithm with non-local mean for significantly improved image-domain material decomposition in dual-energy CT[J]. Physics in Medicine & Biology, 2016, 61(3): 1332.
- [43] Heo S Y, An B, Kim D, et al. Feasibility study of block-matching and 3D filtering denoising algorithm in multi-material decomposition technique for dual-energy computed tomography[J]. Journal of the Korean Physical Society, 2023, 82(3): 305-314.
- [44] Lee H, Kim H J, Lee D, et al. Improvement with the multi-material decomposition framework in dual-energy computed tomography: a phantom study[J]. Journal of the Korean Physical Society, 2020, 77(6): 515-523.
- [45] Xue Y, Ruan R, Hu X, et al. Statistical image-domain multimaterial decomposition for dual-energy CT[J]. Medical Physics, 2017, 44(3): 886-901.
- [46] Harms J, Wang T, Petrongolo M, et al. Noise suppression for dual-energy CT via penalized weighted least-square optimization with similarity-based regularization[J]. Medical Physics, 2016, 43(5): 2676-2686.
- [47] Li Z, Ravishankar S, Long Y, et al. DECT-MULTRA: Dual-energy CT image decomposition with learned mixed material models and efficient clustering[J]. IEEE transactions on medical imaging, 2019, 39(4): 1223-1234.
- [48] 降俊汝, 余海军, 龚长城, 等. 基于 DECT 图像域的 DL-RTV 多材料分解研究[J]. 光学学报, 2020, 40(21): 2111004.
- [49] Ding Q, Niu T, Zhang X, et al. Image-domain multimaterial decomposition for dual-energy CT based on prior information of material images[J]. Medical Physics, 2018, 45(8): 3614-3626.
- [50] 陈强华, 丁锦红, 周胜, 等. 一种指数型滤波反投影解析法与迭代法相结合的层析图像重建算法[J]. 激光与光电子学进展, 2022, 59(23): 2310001.
- [51] Lantz M, and Ongie G. Learning-Based Material Decomposition in Dual Energy CT Using an Unrolled Estimator[C]. 2023 IEEE 20th International Symposium on Biomedical Imaging (ISBI), 2023: 1-5.
- [52] 王冲旭, 陈平, 潘晋孝, 等. 基于迭代残差网络的 DECT 图像材料分解研究[J]. CT 理论与应用研究, 2022, 31(01): 47-54.
- [53] Li Z, Long Y, and Chun I Y. An improved iterative neural network for high-quality image-domain material decomposition in dual-energy CT[J]. Medical Physics, 2023, 50(4): 2195-2211.
- [54] Xu Y, Yan B, Zhang J, et al. Image decomposition algorithm for dual-energy computed tomography via fully convolutional network[J]. Computational and mathematical methods in medicine, 2018, 2018(1): 2527516.

- [55] Zhang W, Zhang H, Wang L, et al. Image domain dual material decomposition for dual-energy CT using butterfly network[J]. Medical Physics, 2019, 46(5): 2037-2051.
- [56] Kawahara D, Saito A, Ozawa S, et al. Image synthesis with deep convolutional generative adversarial networks for material decomposition in dual-energy CT from a kilovoltage CT[J]. Computers in Biology and Medicine, 2021, 128: 104111.
- [57] Shi Z, Li H, Cao Q, et al. A material decomposition method for dual-energy CT via dual interactive Wasserstein generative adversarial networks[J]. Medical Physics, 2021, 48(6): 2891-2905.
- [58] Wang G. A perspective on deep imaging[J]. IEEE Access, 2016, 4: 8914-8924.
- [59] Xia W, Shan H, Wang G, et al. Physics-/model-based and data-driven methods for low-dose computed tomography: A survey[J]. IEEE signal processing magazine, 2023, 40(2): 89-100.
- [60] Lecun Y, Boser B, Denker J S, et al. Backpropagation applied to handwritten zip code recognition[J]. Neural Computation, 1989, 1(4): 541-551.
- [61] Williams R J, and Zipser D A learning algorithm for continually running fully recurrent neural networks[J]. Neural Computation, 1989, 1(2): 270-280.
- [62] Akcakaya M, Yaman B, Chung H, et al. Unsupervised Deep Learning Methods for Biological Image Reconstruction and Enhancement: An overview from a signal processing perspective[J]. IEEE Signal Processing Magazine, 2022, 39(2): 28-44.
- [63] Tabacof P, Tavaers J, and Valle E. Adversarial images for variational autoencoders[EB/OL]. (2016-12-1) [2023-3-20]. <http://arxiv.org/abs/1612.00155>.
- [64] Liang K, Yang H, and Xing Y. 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>.
- [65] Li T, Li X, Wang J, et al. Nonlinear sinogram smoothing for low-dose X-ray CT[J]. IEEE Transactions on Nuclear Science, 2004, 51(5): 2505-2513.
- [66] Yaman B, Hosseini S A H, Moeller S, et al. Self-supervised learning of physics-guided reconstruction neural networks without fully sampled reference data[J]. Magnetic resonance in medicine, 2020, 84(6): 3172-3191.
- [67] Yaman B, Gu H, Hosseini S A H, et al. Multi-mask self-supervised learning for physics-guided neural networks in highly accelerated magnetic resonance imaging[J]. NMR in Biomedicine, 2022, e4798.
- [68] Song Y, Sohl-Dickstein J, Kingma D P, et al. Score-Based Generative Modeling through Stochastic Differential Equations[C]. International Conference on Learning Representations, 2021.
- [69] Yang L, Zhang Z, Song Y, et al. Diffusion models: A comprehensive survey of methods and applications[J]. ACM Computing Surveys, 2023, 56(4): 1-39.
- [70] Song Y, Shen L, Xing L, et al. Solving Inverse Problems in Medical Imaging with Score-Based Generative Models[C]. International Conference on Learning Representations, 2022.

- [71] Zhang J, Mao H, Wang X, et al. Wavelet-inspired multi-channel score-based model for limited-angle CT reconstruction[J]. IEEE Transactions on Medical Imaging, 2024, 1-1.
- [72] Wu W, Wang Y, Liu Q, et al. Wavelet-improved score-based generative model for medical imaging[J]. IEEE transactions on medical imaging, 2023, 43(3): 966-979.
- [73] Gao H. Fused analytical and iterative reconstruction (AIR) via modified proximal forward-backward splitting: a FDK-based iterative image reconstruction example for CBCT[J]. Physics in Medicine & Biology, 2016, 61(19): 7187-7204.
- [74] Van Aarle W, Palenstijn W J, Cant J, et al. Fast and flexible X-ray tomography using the ASTRA toolbox[J]. Optics express, 2016, 24(22): 25129-25147.
- [75] Bao P, Xia W, Yang K, et al. Convolutional sparse coding for compressed sensing CT reconstruction[J]. IEEE transactions on medical imaging, 2019, 38(11): 2607-2619.
- [76] Heusel M, Ramsauer H, Unterthiner T, et al. Gans trained by a two time-scale update rule converge to a local nash equilibrium[J]. Advances in neural information processing systems, 2017, 6629-6640.
- [77] Zhao H, Gallo O, Frosio I, et al. Loss functions for image restoration with neural networks[J]. IEEE Transactions on computational imaging, 2016, 3(1): 47-57.
- [78] Yang Q, Yan P, Zhang Y, et al. Low-dose CT image denoising using a generative adversarial network with wasserstein distance and perceptual loss[J]. IEEE transactions on medical imaging, 2018, 37 (6): 1348-1357.
- [79] Johnson J, Alahi A, and Fei-Fei L. Perceptual losses for real-time style transfer and super-resolution[C]. Computer Vision-ECCV 2016: 14th European Conference, 2016: 694-711.
- [80] Hubbell J H, and Seltzer S M. Tables of X-Ray Mass Attenuation Coefficients and Mass Energy-Absorption Coefficients 1 keV to 20 MeV for Elements $Z = 1$ to 92 and 48 Additional Substances of Dosimetric Interest[EB/OL]. (1995-1-1) [2023-10-21]. <http://physics.nist.gov/PhysRefData/XrayMassCoef/cover.html>.
- [81] Niu T, Dong X, Petrongolo M, et al. Iterative image-domain decomposition for dual-energy CT[J]. Medical physics, 2014, 41(4): 041901.
- [82] Rombach R, Blattmann A, Lorenz D, et al. High-resolution image synthesis with latent diffusion models[C]. Proceedings of the IEEE/CVF conference on computer vision and pattern recognition, 2022: 10684-10695.
- [83] Song Y, Dhariwal P, Chen M, et al. Consistency models[C]. International conference on machine learning, 2023: 32211-32252.

攻读学位期间发表的学术成果

已录用的论文:

- [1] 吴凡, 刘进, 张意, 等. 面向 CT 成像的深度重建算法研究进展[J]. 中国体视学与图像分析, 27(04):387-404, 2022.
- [2] 吴凡, 金潼, 詹郭睿, 等. 基于多通道交叉卷积 UCTransNet 的双能 CT 基材料分解方法[J]. 光学学报, 2024, 44(05): 136-150.
- [3] Liu J, Wu F, Zhan G, et al. DECT sparse reconstruction based on hybrid spectrum data generative diffusion model[J]. Computer Methods and Programs in Biomedicine, 2025, 261: 108597.
- [4] Kang Y, Liu J, Wu F, et al. Deep convolutional dictionary learning network for sparse view CT reconstruction with a group sparse prior[J]. Computer Methods and Programs in Biomedicine, 2024, 244: 108010.

发明专利:

- [1] 一种基于深度卷积稀疏表示重建网络的能谱 CT 成像方法[P], 发明专利: 2023104570041, 刘进, 亢艳芹, 吴凡, 等.

软件著作权:

- [1] 安徽工程大学, 医学双能 CT 图像重建工具软件[P], 软件著作权: 2024SR1754898.
- [2] 安徽工程大学, CT 图像分割及可视化工具软件 V1.0 [P], 软件著作权: 2023SR0211720.

致 谢

在硕士毕业论文即将完成之际，我由衷地感激所有在研究生阶段给予我帮助、支持和鼓励的人。正是他们的陪伴与付出，使我得以顺利走完这段学术旅程，圆满完成论文。

首先，我要由衷地感谢我的导师。导师严谨的治学态度、深厚的学术造诣和敏锐的洞察力，为我的研究提供了重要的指导。在论文选题、研究方法的制定以及撰写过程中，导师始终给予我细致、无私的帮助。在此，我向导师表达最崇高的敬意和诚挚的感谢。

其次，我要感谢实验室的同学们。在研究生阶段，我们携手共进，共同度过了许多难忘的时光。在学术上，我们相互学习、交流与启发；在生活中，我们彼此关心、支持与鼓励。这些珍贵的陪伴与友谊，让我的求学之路更加充实而温暖。

此外，我要衷心感谢我的家人和朋友。在求学的旅程中，他们始终是最坚实的后盾，给予我无尽的关爱与支持。在面对困难和挑战时，他们的鼓励让我始终保持信心与勇气，坚定前行。

最后，我要诚挚感谢所有参与论文评审和答辩的老师。他们提出的宝贵意见和建议，使我的论文更加完善。在此，我向他们表达由衷的谢意，并期望在未来的学术道路上，能够继续得到他们的指导与帮助。

在这段研究生生涯中，我不仅收获了宝贵的学术成果，也积累了丰富的人生经验。这段经历将成为我前行的动力，激励我不断努力，为学术研究和社会发展贡献自己的力量。再次向所有给予我帮助、支持和鼓励的人表达诚挚的感谢！

