·CT关键技术专栏·

基于隐式神经表示的能谱 CT 重建与物质分解方法研究

夏颖贤[a,b] 周浩[a,b] 邓一凡[a,b] 王志磊[a,b] 陈志强[a,b] 高河伟[a,b*]

（清华大学 a.工程物理系；b.粒子技术与辐射成像教育部重点实验室，北京 100084）

【摘要】 目的 解决能谱CT传统重建方法依赖离散体素网格、计算复杂度高，且在低剂量与欠采样条件下重建质量下降、物质分解精度不足的技术难题。**方法** 提出一种基于隐式神经表示（implicit neural representation, INR）的能谱CT重建与物质分解方法。该方法采用多分辨率哈希编码将空间坐标映射为高维特征，并通过轻量级多层感知机（multi-layer perceptron, MLP）解码输出基物质密度，将重建过程转化为最小化投影一致性损失的非线性优化问题。**结果** 基于快速千伏切换仿真数据与双层平板探测器实际数据完成性能验证，与传统的投影域物质分解结合滤波反投影（filter back projection, FBP）的两步法相比，该方法有效提升了图像的信噪比与物质分解精度，并在稀疏视图条件下展现出更强的鲁棒性。**结论** 本方法可为新一代能谱CT技术的低剂量临床应用提供新的算法路径与理论依据。

【关键词】 隐式神经表示；能谱CT；物质分解；图像重建

【中图分类号】 TL81 **【文献标识码】** A **【DOI】** 10.11876/mimt202602001

Research on spectral CT reconstruction and material decomposition method based on implicit neural representation

Xia Yingxian[a,b], Zhou Hao[a,b], Deng Yifan[a,b], Wang Zhilei[a,b], Chen Zhiqiang[a,b], Gao Hewei[a,b]*

(a. Department of Engineering Physics; b. Key Laboratory of Particle & Radiation Imaging, Ministry of Education, Tsinghua University, Beijing 100084, China)

【Abstract】 Objective To address the technical challenges of traditional spectral CT reconstruction methods, including reliance on discrete voxel grids, high computational complexity, degraded reconstruction quality, and insufficient material decomposition accuracy under low-dose and under-sampling conditions. **Methods** A spectral CT reconstruction and material decomposition method based on implicit neural representation (INR) is proposed. This method adopts multi-resolution hash encoding to map spatial coordinates into high-dimensional features, decodes base material densities via a lightweight multi-layer perceptron (MLP), and converts the reconstruction process into a nonlinear optimization problem minimizing projection consistency loss. **Results** Performance verification was conducted based on simulation data from fast kV switching and actual data from a dual-layer flat-panel detector. Compared with the traditional two-step method combining projection-domain material decomposition and filtered back projection (FBP), the proposed method effectively improves the image signal-to-noise ratio and material decomposition accuracy, demonstrating stronger robustness under sparse-view conditions. **Conclusion** The present invention can provide a new algorithmic path and theoretical basis for the low-dose clinical application of next-generation spectral CT technology.

【Key words】 Implicit neural representation; Spectral CT; Material decomposition; Image reconstruction

基金项目：国家重点研发计划“诊疗装备与生物医用材料”重点专项（2024YFC2417500）

第一作者：夏颖贤，男，博士研究生，助理研究员，研究方向：CT成像技术及应用

通信作者：高河伟，男，博士研究生，教授，研究方向：CT成像技术及应用

计算机断层扫描（computed tomography, CT）作为现代医学影像诊断的核心技术，在疾病筛查、临床诊断及治疗规划中发挥着不可替代的作用[1-3]。随着临床对精准诊疗需求的不断提升，能谱CT（Spectral CT）技术应运而生。相较于传统单能成像，能谱CT利用多能量数据实现物质分解与定量分析，能够有效区分不同原子序数的组织材料，显著提升了病变检出率与诊断特异性[4]。然而，能谱成像对投影数据的质量极为敏感。在实际应用中，受限于辐射剂量控制、扫描速度要求及探测器物理特性，采集数据常面临投影噪声大、投影视角稀疏或高低能数据不匹配等问题。如何在数据采样受限或低剂量条件下，保证能谱图像的重建质量及物质分解精度，仍是医学物理与工程领域亟待解决的关键问题[5]。

在能谱CT重建的具体算法层面，现有方法主要分为“两步法”与“一步法”。传统两步法将物质分解和图像重建过程解耦。其中，投影域分解结合滤波反投影（filter back projection, FBP）是常见的实现策略。该方法先在投影域完成高低能数据的物质分解，再对分解后的基物质投影分别进行重建。然而，投影域分解过程对噪声敏感，低信噪比投影数据经分解后噪声会被进一步放大；且FBP作为解析重建算法，对数据完备性要求较高，在欠采样条件下无法有效约束逆问题的病态性，易产生条纹伪影[6]。另一种图像域分解策略则是先重建后分解，同样面临噪声传递与误差累积的问题。相比之下，一步法重建策略试图直接从多能投影数据中恢复基物质密度图，避免了中间环节的误差传递。这类方法通常基于统计迭代重建框架，通过引入精确的物理衰减模型来优化重建结果。尽管传统一步法在噪声抑制和硬化校正方面表现优异，但其本质上仍依赖于离散体素网格的显式表示。这种离散化不仅导致计算复杂度极高、重建耗时漫长，且在面对极端低剂量或稀疏视图数据时，由于病态逆问题的特性，重建质量会显著下降[7]。此外，近期引入深度学习加速的混合重建方案虽提升了计算速度，却未能摆脱离散网格对分辨率和几何灵活性的束缚，难以满足临床对高效、高精度能谱成像的迫切需求[8]。

隐式神经表示（implicit neural representation, INR）作为一种新兴的连续场景表示方法，通过神经网络隐式编码信号，能够以紧凑的参数实现任意分辨率的信号重建，并在稀疏视图恢复方面展现出独特优势[9-16]。鉴于此，本研究旨在提出一种基于INR的能谱CT重建与物质分解方法，首先通过INR模型建立投影数据与基物质物体场之间的连续映射关系，然后构建适用于能谱CT的INR重建和物质分解框架。该方法无需额外的标签数据进行监督训练，直接基于投影数据的一致性进行物理驱动优化。本研究在快速千伏切换仿真及双层平板探测器实际数据下，验证了其在提升图像信噪比及物质分解准确性方面的有效性，以期为新一代能谱CT技术的低剂量临床应用提供新的解决思路。

1 基于隐式神经表示的能谱CT成像建模

与传统基于离散体素网格的重建方法不同，本研究利用INR将待重建的物质密度场建模为连续函数。该模型不仅描述了X射线与物质相互作用的衰减过程，还定义了神经网络如何隐式编码物体内部的空间分布，从而实现从三维连续坐标到多能投影数据的可微分映射。

1.1 能谱CT物理前向模型

在能谱CT成像中，X射线源发射的是多能谱射线束。根据Beer–Lambert定律，能量积分型探测器接收到的强度 I_i 与入射强度 I_0 之间的关系由光子能量 E 上的积分决定。对于第 i 条射线路径 $\mathcal{L}_i$，其测量到的投影值 p_i 可表示为：

$$p_i=-\ln\left(\frac{I_i}{I_0}\right)=-\ln\left(\int S(E)\exp\left(-\int_{\mathcal{L}_i}\mu(\mathbf{x},E)\mathrm{d}l\right)\mathrm{d}E\right) \quad (1)$$

其中，$S(E)$ 表示射线对应的归一化的能量加权的X射线能谱分布，$\mu(\mathbf{x},E)$ 是位置 $\mathbf{x}\in R^3$ 处能量为 E 的线性衰减系数。

为了实现物质分解，我们将线性衰减系数建模为 K 种基物质的线性组合（一般而言，$K=2$）。假设基物质的线性衰减系数已知为 $f_k(E)$，则任意位置的衰减系数可分解为：

$$\mu(\mathbf{x},E)=\sum_{k=1}^{K}\rho_k(\mathbf{x})\cdot f_k(E) \quad (2)$$

其中，$\rho_k(\mathbf{x})$ 表示位置 $\mathbf{x}$ 处第 k 种基物质的密度分布

图。传统重建方法试图求解离散化的 ρ_k 矩阵，而本研究的目标是通过隐式神经网络直接拟合 $\rho_k(\mathbf{x})$。基于INR的能谱CT成像方法示意图见图1。

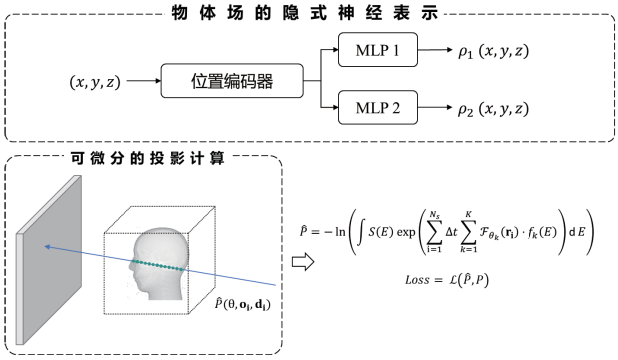


图 1 基于隐式神经表示的能谱CT成像方法

1.2 物体场的隐式神经表示

为了高效地参数化物质密度场，本研究采用多分辨率哈希编码[17]代替传统的位置编码。该方法通过维护多个不同分辨率的哈希表，将连续的空间坐标映射为高维特征向量，从而显著提升网络对高频信号的拟合能力及训练速度。

具体而言，我们定义 L 个不同分辨率的网格层级，每个层级包含一个哈希表 Θ_l，表中存储了可学习的特征向量。对于任意输入坐标 $\mathbf{x}=(x,y,z)$，在第 l 层网格中，我们首先找到包围该点的网格顶点 $\{\mathbf{v}_j\}_{j=1}^{8}$。通过哈希函数 $\mathcal{H}$ 将顶点坐标映射到哈希表的索引：

$$\mathrm{idx}_j=\mathcal{H}_T(\mathbf{v}_j) \tag{3}$$

其中，T 是哈希表的大小。随后，通过查询哈希表获取顶点的特征向量，并利用三线性插值得到该坐标在第 l 层的特征表示 $\mathbf{h}_l(\mathbf{x})$。将所有层级的特征向量拼接，得到最终的空间编码特征 $\mathbf{h}(\mathbf{x})$：

$$\mathbf{h}(\mathbf{x})=[\mathbf{h}_1(\mathbf{x})^\top,\mathbf{h}_2(\mathbf{x})^\top,\ldots,\mathbf{h}_L(\mathbf{x})^\top]^\top \tag{4}$$

该特征向量随后输入到一个轻量级的多层感知机（multi–layer perceptron, MLP）$\mathcal{M}_\phi$ 中，输出 K 种基物质的密度值：

$$[\rho_1(\mathbf{x}),\ldots,\rho_K(\mathbf{x})]^\top=\mathcal{M}_\phi[\mathbf{h}(\mathbf{x});\phi]=[\mathcal{F}_{\theta_1}(\boldsymbol{x}),\ldots,\mathcal{F}_{\theta_K}(\boldsymbol{x})]^\top \tag{5}$$

其中，ϕ 为MLP的权重参数。这种哈希编码机制使得模型能够在参数量紧凑的前提下，实现对复杂解剖结构的高保真连续表示。

1.3 基于隐式神经表示的投影计算与优化

将式（5）代入式（1）和式（2），我们建立了从网络参数 $\Theta=\{\theta_1,\ldots,\theta_K\}$ 到投影数据 $\mathbf{p}$ 的端到端映射。对于给定的射线路径 $\mathbf{r}_i(t)=\mathbf{o}_i+t\cdot\mathbf{d}_i$（其中 $\mathbf{o}_i$ 为源点，$\mathbf{d}_i$ 为方向），线积分过程通过数值积分近似计算：

$$\hat{\mathbf{p}}_i(\Theta)=-\ln\left(\int S(E)\exp\left(-\sum_{i=1}^{N_s}\Delta t\cdot\sum_{k=1}^{K}\mathcal{F}_{\theta_k}(\mathbf{r}_i)\cdot f_k(E)\right)\mathrm{d}E\right) \tag{6}$$

其中，$\mathbf{r}_i$ 为沿射线采样的 N_s 个点的深度值，Δt 为采样步长。此外，为进一步提升效率与准确性，重要性采样机制也在实践中被使用。重要性采样中，在初始进行均匀采样后，根据采样值的大小进行加权或重采样，以提高近似精度。

重建过程转化为一个非线性优化问题。我们最小化预测投影 $\hat{\mathbf{p}}(\Theta)$ 与实际测量投影 $\boldsymbol{p}^{\mathrm{g}}$ 之间的损失函数 $\mathcal{L}$：

$$\Theta^*=\arg\min_{\Theta}\sum_i|\boldsymbol{p}_i^{\mathrm{g}}-\hat{\mathbf{p}}_i(\Theta)|_2^2 \tag{7}$$

通过反向传播算法更新网络参数 Θ，最终训练好的网络即代表了连续的物质密度分布场，可直接用于生成任意分辨率的能谱图像。

相较于传统的数据驱动的深度学习方法，INR的优化目标更类似于迭代重建，不需要额外的标签数据。其优化目标直接基于投影数据的一致性，因此具有更高的物理可解释性和重建可信度。与此同时，INR摒弃了体素化建模方式，而采用网络结构进行隐式建模，在保留结构关联性的同时显著压缩参数量，使其更适合用于CT重建和物质分解中数据受限的场景。但由于网络容量有限，INR容易陷入局部最优，因此选择合理的优化方式对于提升最终重建质量至关重要，我们将在实验中讨论这一点。

2 实验设计与结果分析

2.1 实验参数

为验证所提方法的有效性，我们基于快速千伏切换（仿真实验）和双层平板探测器（实际实验）的能谱CT开展了实验。表1展示了能谱CT实验的几何参数。

表1 能谱CT实验的几何参数

几何参数	快速千伏切换	双层平板探测器
射线源到探测器的距离	1 184 mm	1 184 mm
射线源到旋转中心的距离	750 mm	750 mm
等距探测器的尺寸和数目	0.45 mm × 960	0.45 mm × 960
重建体像素大小	0.5 mm × 0.5 mm	0.5mm × 0.5mm
旋转一圈（360°）的采样数	360	723
重建像素数目	512 × 512	512 × 512

所提网络架构主要由多分辨率哈希编码层与两个MLP组成，旨在实现从三维空间坐标到两个基物质密度值的高精度映射。

具体配置如下：设置哈希网格的层级数 $L=16$，每层特征向量的维度 $F=2$。哈希表大小 T 设为 2^{19}，以平衡分辨率覆盖范围与哈希冲突概率。分辨率参数方面，基础分辨率 $N_{\min}$ 设为16，确保能够覆盖并精细表达图像的高频边缘信息。对于任意输入坐标 $\mathbf{x}$，该层通过三线性插值从各层级网格中提取特征，并拼接形成维度为 $L\times F=32$ 的特征向量 $\mathbf{h}(\mathbf{x})$，作为MLP的输入。

两个MLP负责将编码后的特征向量分别解码为两种基物质密度值。考虑到能谱CT重建任务的复杂性与稀疏视图数据的病态性，网络设计遵循“轻量化与高表现力并重”的原则。网络结构包含2个隐藏层，每层神经元数量为32。相较于深层网络，浅层网络在INR任务中不仅训练速度更快，且配合哈希编码后已具备足够的非线性拟合能力。激活函数方面，隐藏层采用ReLU函数；输出层则采用LeakyReLU激活函数。值得注意的是，两个MLP网络输出分别对应仿真实验中的水和碘或实际实验中的水和骨头两种基物质的密度分布。这种端到端的映射结构直接输出物质密度，避免了传统方法中图像域分解可能引入的误差。

针对INR模型在能谱CT重建中的训练特性，本研究采用以下优化策略以加速收敛并提升重建质量。采用Adam优化器进行参数更新，参数设置为 $\beta_1=0.9$，$\beta_2=0.999$。初始学习率设定为 1×10^{-3}，每个epoch的batchs为投影数，针对快速千伏切换仿真数据，每20个epoch学习率衰减为原学习率的1/10，共训练80个epoch；针对双层平板实验数据，每30个epoch学习率衰减为原学习率的1/10，共训练60个epoch。在每次迭代中，随机从高低能投影数据集中采样一批射线（batch size = 2 048），而非使用全量投影数据。这种随机梯度下降策略不仅降低了单次迭代的显存需求，还引入了随机性，有助于网络跳出局部最优解。在计算投影积分时，沿每条射线均匀采样384个点进行数值积分。为了进一步提高积分精度并捕捉高频细节，在均匀采样点的基础上实现重要性采样[18]，进一步提高前向渲染的准确性。

对于物质分解，另一个可能存在的问题是，基物质密度值量级上的差异性可能带来网络训练的不稳定性，为了进一步提升网络的训练速度，我们不直接利用隐式网络建模密度，而是建模：

$$\rho_i(\mathbf{x})=m_i\mathcal{F}_{\theta_k}(\mathbf{x}) \tag{8}$$

其中，m_i 是这种基物质的特异性系数，在实验中，我们直接使用这种物质的能谱加权平均线性衰减系数作为它的特异性系数，即：

$$m_k=\int S(E)f_k(E)\mathrm{d}E \tag{9}$$

通过上述网络架构与优化方法的协同设计，所提模型能够在稀疏且含噪的投影数据约束下稳定收敛并重建出高质量的基物质密度图。

2.2 基于千伏切换技术的能谱CT实验结果

首先使用多能模体针对千伏切换能谱CT开展仿真实验。高、低能的X射线源的管电压分别是80 kV和140 kV，X射线源的光谱使用SpekCalc软件[19]生成。为系统评估基于INR的能谱CT重建方法的有效性，本研究利用快速千伏切换仿真数据，将所提方法与投影域多项式物质分解结合FBP的传统两步法进行了对比实验。该方法先在投影域完成高低能数据的物质分解，再对分解后的基物质投影分别进行FBP重建。实验重点考察两种方法在稀疏视图及低剂量噪声条件下的图像重建质量与物质分解精度。

如图2所示，传统两步法在投影视角稀疏的条件下，重建图像中普遍出现明显的条纹伪影、噪声放大及边缘模糊。这主要源于以下两方面原因：其一，投影域物质分解过程对噪声敏感，低信噪比投影数据经分解后噪声被进一步放大；其二，FBP作为解析重建算法，对数据完备性要求较高，在欠采样条件下无法有效约束逆问题的病态性。

相比之下，本研究所提出的方法展现出更优的重建质量。得益于多分辨率哈希编码对空间高频特征的强拟合能力，INR重建出的基物质碘图在组织

边缘处更为锐利，解剖结构的连续性保持得更好。传统两步法常见的条纹伪影与边缘振铃效应在 INR 结果中得到明显抑制。这主要归功于连续隐式表示打破了离散网格的固定分辨率限制，能够自适应地拟合任意空间频率的信号。

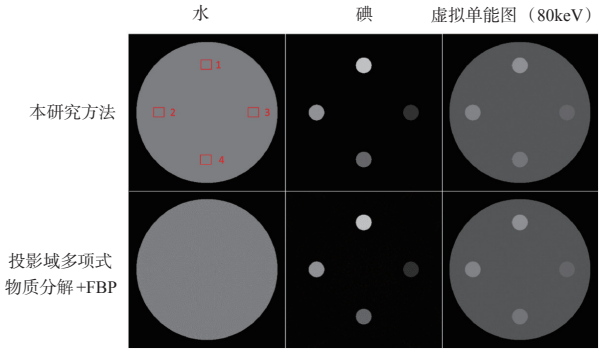


图 2 基于千伏切换技术的能谱 CT 实验结果

注：FBP 为滤波反投影。

我们对图 2 中所标示的水基物质图的感兴趣区域（region of interest, ROI）进行定量分析。如表 2 所示，相较而言，本研究方法和对比方法的基物质的结果都无明显误差，但是本研究方法的方差更小，降噪效果也更为显著。实验结果表明，在相同剂量条件下，INR 方法的物质分解噪声显著低于传统两步法。传统两步法虽在投影域完成分解，避免了图像域分解的部分误差传递，但其分解过程仍依赖于投影数据的线性近似模型，且分解后的基物质投影经 FBP 重建时，无法利用物质间的空间相关性进行联合约束，导致分解结果中存在噪声残留。

表 2 基于千伏切换技术的能谱 CT 实验结果的水基物质图的 ROI 定量比较

ROI	本研究方法		对比方法	
	均值	方差	均值	方差
1	1 000.332 4	8.092 8	1 000.061 5	712.553 1
2	1 000.338 4	6.603 0	999.847 8	782.306 3
3	999.995 9	9.021 7	1 000.117 7	847.190 2
4	1 000.272 3	5.974 3	999.936 6	853.660 5

注：ROI 为感兴趣区域。

2.3 基于双层平板探测器的能谱 CT 实验结果

为验证方法在真实临床场景下的适用性，本研究进一步使用双层平板探测器[20]采集的实际能谱投影数据，与传统投影域多项式物质分解结合 FBP 方法进行了对比测试。

如图 3 所示，本研究在配备原型双层平板探测器的锥束 CT 系统上开展实验。实验所用 X 射线球管的工作电压为 120 kV，工作电流为 3.2 mA，并采用 2 mm 厚铝平板滤过板作为患者前射线滤过装置。双层平板探测器（美国瓦里安）由 2 块非晶硅（α–Si）平板构成，像素矩阵为 2 880 × 2 880，两块平板均镀有 550 μm 厚的碘化铯（CsI）闪烁体。每块平板的原始像素尺寸为 0.15 mm × 0.15 mm，支持 2 × 2 或 3 × 3 像素合并模式，且每块平板均设有 7 档增益模式，平板之间未额外加装中间滤过片。我们通过准直实现扇束扫描来验证方法的有效性。

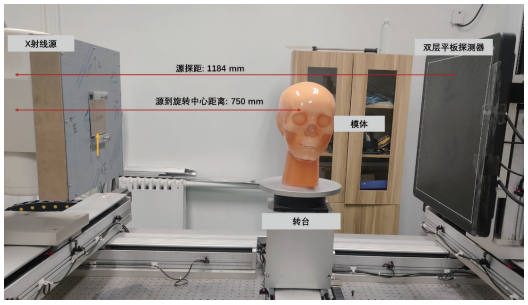


图 3 基于双层平板探测器的能谱 CT 实验平台

如图 4 所示，与传统两步法相比，INR 重建的基物质密度图在整体对比度与细节清晰度上均更具优势。在骨骼边缘等高梯度区域，传统方法因 FBP 的频域滤波特性易出现伪影扩散或边缘模糊，而 INR 结果保持了更锐利的边界与更少的伪影干扰。在低对比度软组织区域，INR 方法重建的图像背景更均匀，细微结构的可见度有所提升，这得益于哈希编码对多尺度特征的有效捕捉与连续表示对噪声的内在抑制。

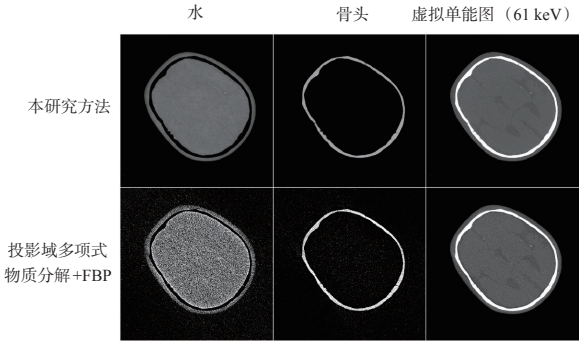


图 4 基于双层平板探测器的能谱 CT 实验结果

注：FBP 为滤波反投影。

3 结论

本研究针对能谱 CT 在低剂量及稀疏视图条件下重建质量下降及物质分解精度不足的问题，提出了一种基于 INR 的能谱 CT 重建与物质分解方法。本研究突破了传统离散体素网格表示的限制，利用多

分辨率哈希编码与MLP构建了连续的物质密度场模型，并结合物理前向模型，实现了从投影数据到基物质密度图的端到端映射。

本研究主要结论如下。首先，在建模层面，本研究采用的连续隐式表示方法能够有效克服离散化带来的分辨率限制与存储瓶颈。通过引入多分辨率哈希编码，模型在参数量紧凑的前提下显著提升了对高频解剖结构的拟合能力，解决了传统方法在极端稀疏视图下容易产生的混叠与伪影问题。其次，在优化策略上，将物理衰减模型嵌入网络训练过程，确保了重建结果的物理可解释性。方法在有效抑制低剂量噪声的同时，较好地保留了物质界面的边缘结构信息，避免了过度平滑导致的细节丢失。最后，实验验证表明，该方法在快速千伏切换（仿真）与双层平板探测器（实际）两种数据模式下均表现出良好的适应性。相较于传统迭代重建算法，本方法在低剂量条件下显著提升了图像信噪比与物质分解的准确性，且无需额外的标签数据进行监督训练，展现了无监督物理驱动重建的优势。

尽管本研究取得了初步成效，但仍存在一定局限性。例如，INR的训练时间相较于传统解析算法仍较长，且目前主要集中于二维切片重建。未来的研究工作将聚焦于以下方面：一是进一步优化网络架构与采样策略，引入更高效的并行计算机制以缩短训练与推理时间，满足临床实时性需求；二是将该方法扩展至三维体积重建，充分利用空间连续性信息以提升整体重建质量；三是探索更多样的正则化先验与自适应权重策略，以增强模型在更复杂临床场景下的鲁棒性。总体而言，本研究为新一代低剂量、高精度能谱CT成像提供了新的算法路径与理论依据，具有潜在的临床应用价值。

[参 考 文 献]

[1] Kalender W A. Computed tomography: fundamentals, system technology, image quality, applications [M]. 3rd ed. Hoboken: John Wiley & Sons, 2011.

[2] Peters T M. Computed tomography: fundamentals, system technology, image quality and applications [J]. Physics in Medicine & Biology, 2001, 46(5): 1593.

[3] Seeram E. Computed tomography: physical principles, clinical applications, and quality control [M]. 4th ed. Amsterdam: Elsevier, 2015.

[4] Marin D, Boll D T, Mileto A, et al. State of the art: dual–energy CT of the abdomen [J]. Radiology, 2014, 271(2): 327–342.

[5] Schilham A, van Hamersvelt R W, de Jong P A, et al. Material analysis through X–ray attenuation decomposition in spectral computed tomography [J]. Scientific Reports, 2025, 15: 27714.

[6] Kim B, Shim H, Baek J. A streak artifact reduction algorithm in sparse–view CT using a self–supervised neural representation [J]. Medical Physics, 2022, 49(12): 7497–7515.

[7] Mory C, Sixou B, Si–Mohamed S, et al. Comparison of five one–step reconstruction algorithms for spectral CT [J]. Physics in Medicine & Biology, 2018, 63(23): 235001.

[8] Chen X, Xia W, Yang Z, et al. SOUL–net: a sparse and low–rank unrolling network for spectral CT image reconstruction [J]. IEEE Transactions on Neural Networks and Learning Systems, 2024, 35(12): 18620–18634.

[9] Molaei A, Aminimehr A, Tavakoli A, et al. Implicit neural representation in medical imaging: a comparative survey [C] //Proceedings of the IEEE/CVF International Conference on Computer Vision. Piscataway: IEEE, 2023: 2381–2391.

[10] Zhu Y, Liu Y, Zhang Y, et al. Implicit neural representation for medical image reconstruction [J]. Physics in Medicine & Biology, 2025, 70(12): 12TR01.

[11] Shen L, Pauly J, Xing L. NeRP: implicit neural representation learning with prior embedding for sparsely sampled image reconstruction [J]. IEEE Transactions on Neural Networks and Learning Systems, 2022, 35(1): 770–782.

[12] Zhang Y, Shao H C, Pan T, et al. Dynamic cone–beam CT reconstruction using spatial and temporal implicit neural representation learning (STINR) [J]. Physics in Medicine & Biology, 2023, 68(4): 045005.

[13] Lee J, Baek J. Iterative reconstruction for limited–angle CT using implicit neural representation [J]. Physics in Medicine & Biology, 2024, 69(10): 105008.

[14] Song B, Shen L, Xing L. Piner: prior–informed implicit neural representation learning for test–time adaptation in sparse–view CT reconstruction [C] //Proceedings of the IEEE/CVF Winter Conference on Applications of Computer Vision. Piscataway: IEEE, 2023: 1928–1938.

[15] Najaf M, Ongie G. Accelerated optimization of implicit neural representations for CT reconstruction [C] //Proceedings of IEEE 22nd International Symposium on Biomedical Imaging (ISBI). Piscataway: IEEE, 2025: 1–5.

[16] Wang Y, Liang N, Wang S, et al. Implicit neural prior–guided diffusion for spectral CT reconstruction [J]. Medical Physics, 2025, 52(7): e17946.

[17] Müller T, Evans A, Schied C, et al. Instant neural graphics primitives with a multiresolution hash encoding [J]. ACM Transactions on Graphics (TOG), 2022, 41(4): 1–15.

[18] Mildenhall B, Srinivasan P P, Tancik M, et al. Nerf: representing scenes as neural radiance fields for view synthesis [J]. Communications of the ACM, 2022, 65(1): 99–106.

[19] Poludniowski G, Landry G, Deblois F, et al. SpekCalc: a program to calculate photon spectra from tungsten anode x–ray tubes [J]. Physics in Medicine & Biology, 2009, 54(19): N433.

[20] Wang Z, Zhou H, Gu S, et al. Dual–energy head cone–beam CT using a dual–layer flat–panel detector: hybrid material decomposition and a feasibility study [J]. Medical Physics, 2023, 50(11): 6762–6778.