

# 基于改进 U-Net 网络的双能 CT 材料分解方法

张 然<sup>1,2</sup>, 孔慧华<sup>1,2</sup>, 宋一娇<sup>1,2</sup>, 杜晓双<sup>1,2</sup>, 赵致荷<sup>1,2</sup>

(1. 中北大学 数学学院, 太原 030051;

2. 智能探测技术与装备 山西省重点实验室, 太原 030051)

**摘要:** 双能计算机断层扫描可提供扫描对象的定量信息, 实现材料分解, 进而获取人体组织材料的特定信息; 针对传统的 U-Net 网络从双能 CT 图像中提取非局部特征受限的问题, 提出了一种改进的 U-Net 网络, 旨在提高双能 CT 图像材料分解的准确性; IU-Net 采用多尺度编码器, 通过三条路径从不同角度捕捉输入图像的局部和非局部特征, 并在通道维度上进行融合; 为避免过度平滑处理导致图像细节丢失, 引入了边缘损失, 以构建混合损失函数, 优化重建图像的边缘像素, 产生更清晰的图像; 实验结果表明, 提出的 IU-Net 能够保留更多的图像内部细节, 分解后的图像更加清晰。

**关键词:** 边缘损失函数; 神经网络; 材料分解; 能谱 CT; 多尺度编码

## Dual-Energy CT Material Decomposition Method Based on Improved U-Net Network

ZHANG Ran<sup>1,2</sup>, KONG Huihua<sup>1,2</sup>, SONG Yijiao<sup>1,2</sup>, DU Xiaoshuang<sup>1,2</sup>, ZHAO Xiaohe<sup>1,2</sup>

(1. School of Mathematics, North University of China, Taiyuan 030051, China;

2. Shanxi Province Key Laboratory of Intelligent Detection Technology and Equipment, Taiyuan 030051, China)

**Abstract:** Dual-energy computed tomography can provide quantitative information on the scanned object, realize material decomposition, and then obtain specific information of human tissue materials. To solve the problem that the traditional U-Net network is limited in extracting non-local features from dual-energy CT images, an improved U-Net network is proposed to improve the accuracy of dual-energy CT image material decomposition. The inception u-net (IU-Net) uses multi-scale encoders to capture local and non-local features of input images from different angles through three paths, and to fuse them in channel dimensions. In order to avoid excessive smoothing and loss of image details, the edge loss is introduced to construct a hybrid loss function, optimize the edge pixels of the reconstructed image, and produce clearer images. Experimental results show that the proposed IU-Net can retain more internal details of the image, thus making the decomposed image clearer.

**Keywords:** edge loss function; neural network; material decomposition; energy spectrum CT; multiscale coding

## 0 引言

双能 CT (DECT, dual-energy computed tomography) 是一种先进的医学成像技术, 通过使用两种不同能量水平的 X 射线对患者同一部位进行扫描, 获取更丰富的组织信息, 在临床中发挥着至关重要的作用。

材料分解利用获取的双能投影数据, 通过探索不同材料对 X 射线能量的衰减特性, 将 DECT 图像分解为基材图像。材料分解算法是由阿尔瓦雷斯和马科夫斯基在 1976 年基于双能 CT 率先提出的<sup>[1]</sup>。随着能谱 CT 探测技术的发展, 多材料分解算法 (MD, material decomposition) 应运而生<sup>[2-5]</sup>。传统的多材料分解算法主要分

收稿日期:2024-08-14; 修回日期:2024-09-22。

基金项目:国家自然科学基金项目(62201520);山西省基础研究计划(202103021224190, 202203021222052);山西省留学基金项目(2023-129)。

作者简介:张 然(1999-),女,硕士研究生。

通讯作者:孔慧华(1977-),女,教授。

引用格式:张 然,孔慧华,宋一娇,等. 基于改进 U-Net 网络的双能 CT 材料分解方法[J]. 计算机测量与控制, 2025, 33(1): 252-260.

为一步法和两步法。

一步法即直接迭代的材料分解方法, 通过在单一非线性优化框架中同时进行分解和重建, 可以提高图像质量和精度<sup>[6-7]</sup>。然而, 由于优化问题固有的非凸性, 一步方法往往是计算密集的, 并且可能表现出缓慢的收敛, 对初始化敏感, 并且容易陷入局部最小值, 使其在临床应用中不那么鲁棒<sup>[8]</sup>。

两步法包括基于投影域和基于图像域的材料分解方法<sup>[9]</sup>。基于投影域的材料分解方法先从投影数据中非线性分解两种基材的正弦图, 然后通过解析或迭代算法线性重建特定材料的图像。该方法未充分利用图像域中的空间先验信息且分解性能在很大程度上取决于对能谱的准确估计。与投影域方法采用的非线性分解模型不同, 图像域分解直接对重建的 DECT 图像进行处理<sup>[10-12]</sup>, 实现起来更加方便。因此, 本文主要研究基于图像域的材料分解方法<sup>[13]</sup>。

近年来, 数据驱动的神经网络技术在材料分解领域得到了广泛应用。Incept-Net (inception network) 提高了 DECT 材料分解的鲁棒性, 克服了对剂量变化的敏感性, 并表现出良好的泛化能力<sup>[14]</sup>。基于改进的全卷积神经网络 (FC DenseNet, full convolutional dense network) 在 MD 中也展现出良好的性能, 进一步提升了图像对比度和去噪效果<sup>[15]</sup>。自监督噪声和伪影抑制网络 (SeNAS-Net, self-supervised noise and artifact suppression network) 通过引入自监督训练策略 Ne2Ne (neighbor2neighbor), 在 DECT 中材料分解中表现出优秀的噪声和伪影抑制能力<sup>[16]</sup>。在此基础上, 部分学者将传统的模型驱动的分解方法与数据驱动的神经网络相结合, 构建联合模型驱动的神经网络方法, 并验证了该方法在 DECT 材料分解中的优越性<sup>[17-18]</sup>。

基于神经网络的多材料分解大多采用均方误差 (MSE, mean-squared error) 和交叉熵损失函数, 但 MSE 没有考虑图像中内部细节信息, 往往会产生过于光滑和模糊的图像。近年来, 一些新的损失函数被提出, 旨在克服 MSE 的不足。George Seif 等人提出一个基于边缘的损失函数, 通过直接优化重建图像的边缘像素, 驱动训练后的网络产生高质量的显著边缘, 产生更清晰的图像<sup>[19]</sup>。

为了改善 DECT 中图像域材料分解方法在提取非局部特征方面的限制, 以获得更高质量的分解图像, 提出了一种改进 U-Net 网络的双能 CT 材料分解 (IU-Net, inception u-net) 策略来解决 DECT 中图像域材料分解问题。IU-Net 网络保留了 U-Net 的解码器, 提出了新的编码器。编码器部分采用了类似于 Incept-Net 的结构实现多尺度的特征提取, 即 inception\_B 模块。整个网络结构采用了残差连接和 Dropout 技术, 这些技术

有助于提高网络的训练稳定性和泛化能力。此外, 还定义了混合损失函数, 以避免生成结果过于平滑, 从而更好地保留图像的细节信息。

## 1 方法论述

### 1.1 图像域材料分解模型

在一组高、低电压下, 根据 Lambert-Beer 定律, 测量得到的高、低能投影  $P_H$ ,  $P_L$  可分别表示如下:

$$\begin{cases} P_H = -\ln\left(\int S_H(E) e^{-k_1 \tilde{\mu}_1(E) - k_2 \tilde{\mu}_2(E)} dE\right) \\ P_L = -\ln\left(\int S_L(E) e^{-k_1 \tilde{\mu}_1(E) - k_2 \tilde{\mu}_2(E)} dE\right) \end{cases} \quad (1)$$

式中,  $H$  为高能谱,  $L$  为低能谱, 1、2 为两种基材料,  $S_H(E)$  和  $S_L(E)$  为归一化的高、低能能谱,  $\tilde{\mu}_1(E)$  和  $\tilde{\mu}_2(E)$  为两种材料的 X 射线线性衰减系数,  $k_1$  和  $k_2$  为只与材料有关的两种基材料的分解系数。双能 CT 图像域材料分解模型如下:

$$\begin{bmatrix} \mu_{Hq} \\ \mu_{Lq} \end{bmatrix} = \begin{bmatrix} \mu_{1H} & \mu_{2H} \\ \mu_{1L} & \mu_{2L} \end{bmatrix} \cdot \begin{bmatrix} a_{1q} \\ a_{2q} \end{bmatrix} \quad (2)$$

其中:  $q$  表示第  $q$  个像素点,  $\mu_{Hq}$  和  $\mu_{Lq}$  表示双能 CT 图像在  $q$  位置的像素对,  $a_{1q}$  和  $a_{2q}$  是两种基材料在重建图像  $q$  位置处的体积分。通过对基材料的衰减系数矩阵进行反求, 可以很容易地得到材料分解映射矩阵:

$$\begin{bmatrix} a_{1q} \\ a_{2q} \end{bmatrix} = \frac{1}{\mu_{1H}\mu_{2L} - \mu_{2H}\mu_{1L}} \begin{bmatrix} \mu_{2L} & -\mu_{2H} \\ -\mu_{1L} & \mu_{1H} \end{bmatrix} \begin{bmatrix} \mu_{Hq} \\ \mu_{Lq} \end{bmatrix} \quad (3)$$

但是, 矩阵总是病态的。轻微扰动会导致分解精度急剧下降。因此, 引入可逆算子  $F$ , 建立映射关系:

$$\mathbf{Y} = F(\mathbf{A}) \quad (4)$$

来描述重建图像矩阵  $\mathbf{Y}$  与材料分解映射矩阵  $\mathbf{A}$ 。因此, 材料分解可以看作是一个成像逆问题。算子  $F^{-1}$  是通过训练神经网络解决问题的关键。

由于卷积神经网络 (CNN, convolutional neural network) 因其强大的模型表达能力, 常用于图像域的基材料分解, 流程图如图 1 所示。对获取的高低能量通道的原始数据采用 CT 图像重建方法进行重建, 分别生成高低能 CT 图像, 通过卷积和池化等操作对重建后的数据进行处理, 以生成高精度的水和骨图像分解结果。

### 1.2 改进 U-Net 网络的双能 CT 材料分解模型

#### 1.2.1 传统的 U-Net 网络

传统的 U-Net 是专为语义分割而设计的, 其结构包括收缩路径和扩张路径, 为了保留高层语义信息, U-Net 将扩张路径的每个步骤的特征映射与收缩路径的对应特征映射连接起来, 传统 U-Net 网络结构如图 2 所示。

#### 1.2.2 IU-Net 网络

IU-Net 是一种改进的 U-Net 网络, 由编码器和解码器组成。网络将 140 kVp 和 80 kVp 下的多能 CT 图像作为输入, 通过  $3 \times 3$  的卷积层后, 图像数据进入 In-

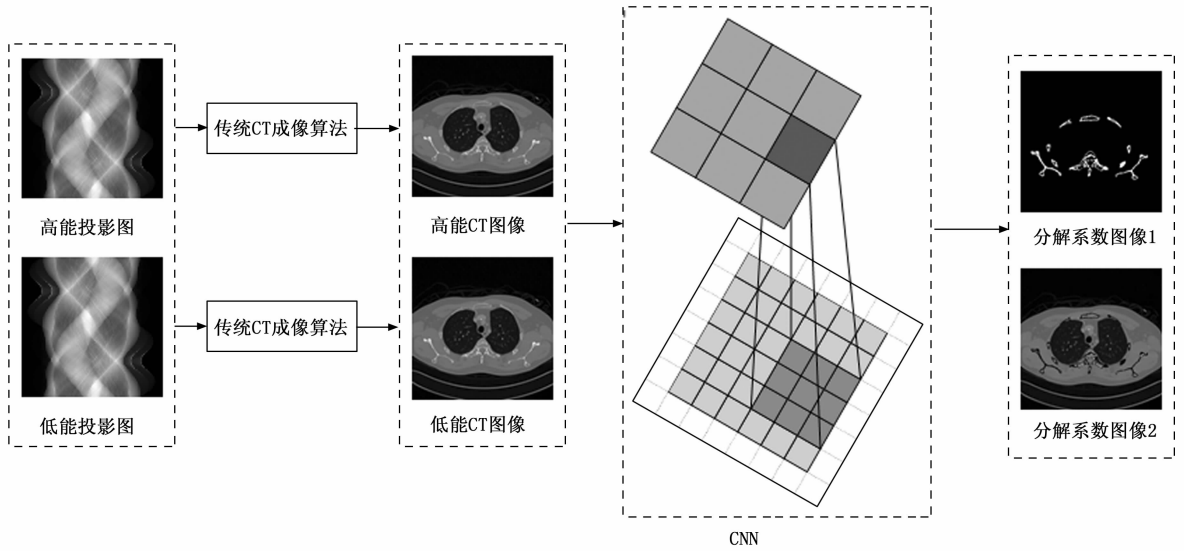


图 1 基于图像域的基材料分解流程图




图 2 传统 U-Net 网络结构图

ception\_B 模块和 Decoder Block 模块。Inception\_B 模块旨在增强图像的特征表示能力，提取更丰富的特征信息；而 Decoder Block 模块则对称放置在网络的更深层次，通过逐步降低特征维度，将图像特征转换为针对特定材料的图像。在网络的学习过程中，采用混合损失函数来优化网络训练，确保训练过程的高效性和准确性。相关流程图如图 3 所示。

网络结构图如图 4 所示。网络保留了 U-Net 的解码器，并提出了新的编码器，引入边缘损失函数来强调图像边缘，为了同时生成骨图和水图，修改后的 U-Net 结构的输入和输出通道设置为两个。此外，IU-Net 用反卷积层替换了上采样层，以更好地保留空间信息，并

引入了批归一化层以缩短训练时间和解决梯度消失问题。

网络进行了一次  $3 \times 3$  的卷积操作后，利用 Inception\_B 模块<sup>[14]</sup>提取更丰富的特征信息。在编码器部分，由 4 个 Inception\_B 模块构建，通道数分别为 64、128、256 和 512，采用最大池化进行下采样，池化大小和步幅为 2。通过堆叠的卷积层不断减小特征图的尺寸和通道数，提取图像的高级特征。在解码器部分，使用核大小为 2、步长为 2 的反卷积操作和跳跃连接将特征图尺寸逐渐恢复到原始输入的尺寸，并且保留了来自编码器中相应尺寸的特征图，用于更好地恢复细节信息。解码器块由两个卷积层组成，核大小为  $3 \times 3$ ，步幅为 1，通道数分别为 256、128、64，与编码器通道数相对应。最后，使用  $1 \times 1$  核的卷积层对特征图进行线性变换，得到了两个输出 output\_mask1 和 output\_mask2，它们代表了模型对输入图像的两个不同材料的预测。

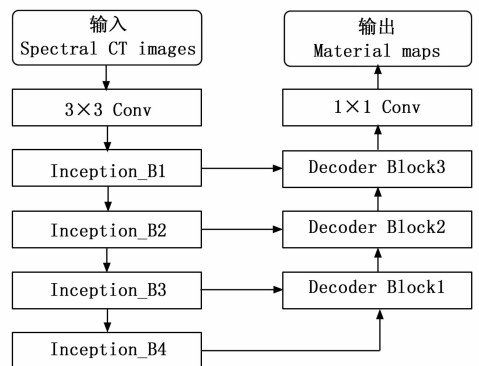


图 3 网络流程图

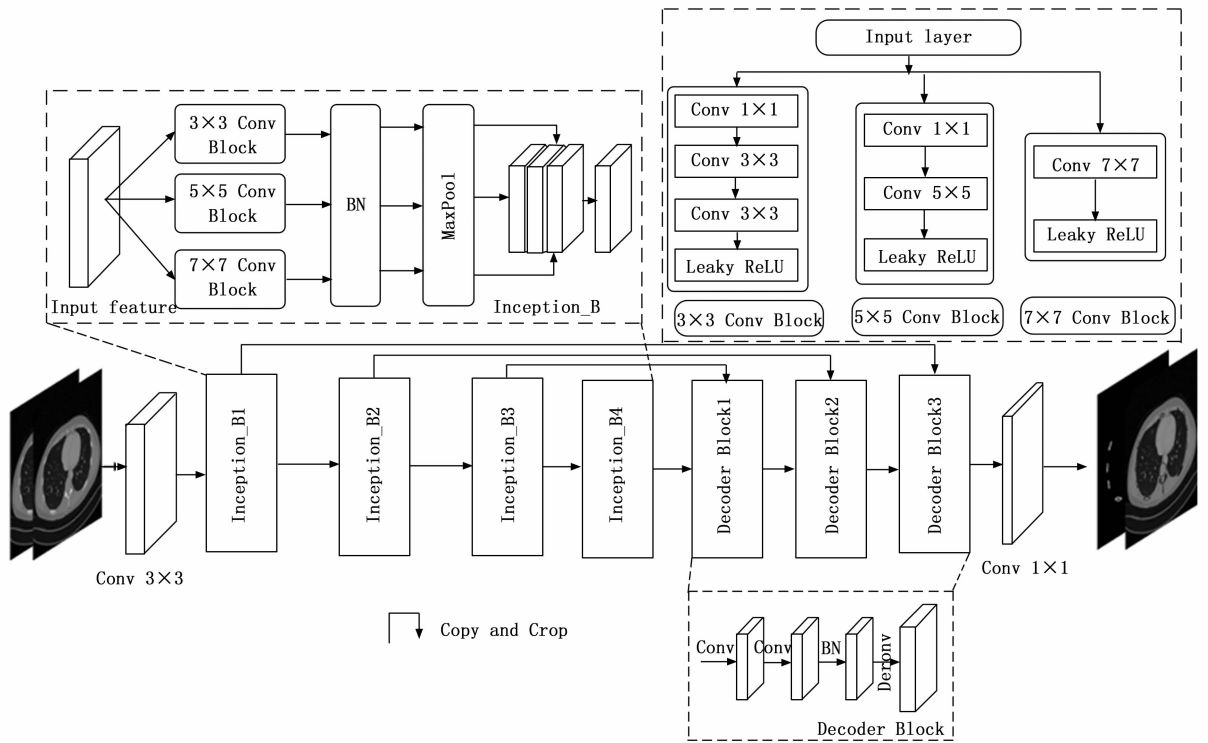


图 4 网络整体结构图

Inception\_B 模块由多分支组成, 通过多尺度特征表示来提高图像的细节保留能力。工作流程如图 5 所示。在 Inception\_B 模块中, 输入特征经过 3 个不同的

分支:  $3 \times 3$  卷积核、 $5 \times 5$  卷积核、 $7 \times 7$  卷积核, 这些分支提取不同尺度特征信息, 卷积核较大的分支提取和聚合分布更广泛的非局部特征信息, 卷积核较小的分

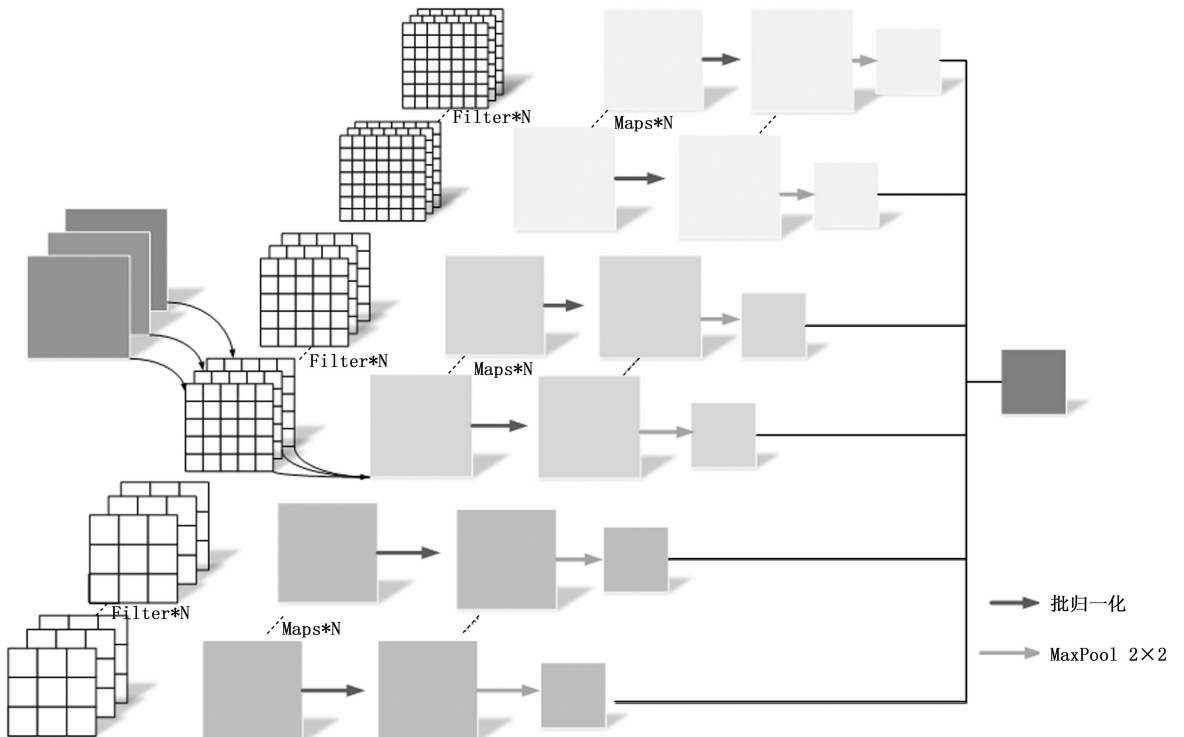


图 5 Inception\_B 工作流程图

支可以减少信息的损失。每个分支都包括卷积和 Leaky ReLU (leaky rectified linear unit) 激活操作, LeakyReLU 通过使部分神经元的输出接近 0, 增加网络的稀疏性, 减少参数之间的相互依赖性, 可以缓解过拟合问题并加快网络训练速度。引入了批量归一化层和  $2 \times 2$  的最大池化层, 并行组合三条路径中的特征数据, 以抑制内部协变量移位。采用  $1 \times 1$  的卷积层合并来自每条路径的信息, 得到 Inception\_B 的输出。

### 1.2.3 损失函数

为了增强网络的材料分解性能, 除了考虑预测图像与标签图像在像素值上的对应外, 还需要考虑基材料图像的边缘信息和纹理细节。鉴于此, 提出使用混合损失函数监督网络学习。

MSE 衡量了预测值与真实值之间的平方差的平均值, 公式如下:

$$L_1(y, \hat{y}_i) = \frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2 \quad (5)$$

其中:  $N$  表示样本的数量,  $y_i$  表示真实标签中第  $i$  个样本的值,  $\hat{y}_i$  表示神经网络输出的预测值中第  $i$  个样本的值。

交叉熵损失函数通常用于衡量两个概率分布之间的差异。公式如下:

$$L_2 = - \sum_{c=1}^C y_c \log(p_c) \quad (6)$$

其中:  $C$  表示类别的数量,  $y_c$  表示真实标签中第  $c$  个元素,  $p_c$  表示样本属于类别  $c$  的预测概率。

边缘损失函数通过优化重建图像的边缘像素, 提升了图像的清晰度。该损失函数分为基于像素的损失函数与基于结构的损失函数<sup>[19]</sup>。基于像素的损失提高了重建图像的整体精度, 确保图像的颜色、光线和整体对比度与原图保持一致。基于结构的损失引导网络产生显著的图像结构, 使得图像具有更清晰、易于识别的边缘和结构。

为了计算边缘损失, 将 Canny 边缘检测器应用于原始训练图像  $Y$  以获得边缘图  $G$ 。Python 默认 Canny 边缘检测器使用 Sobel 梯度算子来计算图像中每个像素点的梯度强度和方向。梯度强度表示像素值变化的幅度, 方向则表示变化的方向。算法使用两个阈值来判断边缘像素是否是真正的边缘。如果边缘像素的梯度值超过高阈值, 则被认为是强边缘; 如果位于高低阈值之间, 则被认为是弱边缘; 如果低于低阈值, 则被认为是“非边缘”。算法通过连接弱边缘与强边缘来确定最终的边缘图。任何与强边缘相连的弱边缘都会被保留, 而孤立的弱边缘将被抑制。

在网络学习过程中, 提取骨组织和水组织的像素矩阵, 并通过统计分析确定其像素值范围。设定初始阈值

为骨组织 (100, 250) 和水组织 (5, 20)。通过二分法和控制变量法对阈值进行优化: 固定低阈值后调整高阈值, 再固定高阈值后优化低阈值。最终, 确定骨组织的阈值为 (150, 255), 水组织的阈值为 (0, 10), 以获得最佳的分解效果。边缘损失是边缘映射与重建误差的乘积的平均值, 其计算公式如下:

$$loss_{edges} = \frac{\sum_{h=1}^H \sum_{w=1}^W G_{h,w} (|y_{h,w} - \hat{y}_{h,w}|)}{HW} \quad (7)$$

像素损失分量为原始图像与重建图像之间的平均绝对误差 (MAE), 函数如下:

$$loss_{pixels} = \frac{\sum_{h=1}^H \sum_{w=1}^W (|y_{h,w} - \hat{y}_{h,w}|)}{HW} \quad (8)$$

由于 MSE 对较大误差进行严重惩罚, 而对较小误差影响较小, 这导致 MSE 在计算边缘损失时会过度强调边缘误差, 进而忽视图像在感知上重要的特征, 如整体明暗程度和对比度。因此, 选择使用平均绝对误差作为像素损失。为了得到最终的损失, 将边缘损失分量与像素损失分量相加:

$$L_3 = \alpha \cdot loss_{pixels} + (1 - \alpha) \cdot loss_{edges} \quad (9)$$

其中:  $\alpha$  用于控制每个损失分量的权重,  $Y$  和  $Y'$  分别是网络输出的图像和真实的图像,  $|y_{h,w} - \hat{y}_{h,w}|$  表示了输出图像与真实图像的绝对误差,  $G_{h,w}$  为提取的边缘图像,  $H$  和  $W$  分别为图像的宽度和高度。

为提升网络的分解效果, 将 MSE、交叉熵损失函数、边缘损失函数线性组合, 混合损失函数公式如下:

$$L_{loss} = \gamma L_1 + \beta L_2 + \theta L_3 \quad (10)$$

其中:  $\beta$ 、 $\gamma$  和  $\theta$  表示权重。

## 2 实验结果

### 2.1 实验数据集和设置

#### 2.1.1 数据集获取

基于神经网络的方法性能与用于训练的数据集的数量高度相关。为了评估所提出的 IU-Net 在图像域的分解效果, 本研究使用了杜克大学的 4DXCAT 仿真人体模型数据来获取双能 CT 图像进行训练和测试。实验中, 利用 GE LightSpeed X-ray CT 扇形系统对 XCAT 体模进行扫描和重建, 模拟该模体在 140 kVp 和 80 kVp 下的投影。采用滤波反投影重建算法 (FBP, filtered back projection) 对投影数据进行重建, 得到双能 CT 图像, 其大小为  $512 \times 512$ 。本文使用专业的标记软件 LabelMe<sup>[20]</sup> 对每张能谱 CT 图像进行手工标记。将原始 XCAT 的每个  $512 \times 512$  切片分离为水和骨图像。手动将脂肪、肌肉、水和血液分组到水密度图像中, 将肋骨分组到骨密度图像中。每个标签图像与原始能谱 CT 图像具有相同的分辨率。最终数据集中的一些原始能谱

CT 图像和标记的参考图像如图 6 所示。




图 6 网络数据集示例

从 XCAT 中选择了 70 片, 其中 50 片用于训练提出的 IU-Net, 其余 20 片用于测试。测试图像与训练图像是完全不同的。

### 2.1.2 网络设置

所提出的 IU-Net 在 GPU (NVIDIA RTX A6000), 设备上使用 Keras 和 TensorFlow 框架实现, 该模型的学习率最初设置为  $1 \times 10^{-5}$ , 在本研究中, 使用适应性矩估计 Adam 来优化损失函数, 迭代 800 次。Leaky ReLU 的  $\alpha$  值为 0.1, 损失函数中  $\alpha$  值为 0.3,  $\gamma$  值为 0.3,  $\beta$  值为 1,  $\theta$  值为 0.3。

### 2.1.3 评价指标

为了定量分析网络的分解效果, 在分解精度方面, 使用结构相似度 (SSIM, structural similarity index measure) 来评价图像质量。SSIM 可以有效地捕获输出图像与真实值之间的差异。在图像质量方面, 采用峰值信噪比 (PSNR, peak signal to noise ratio) 判断。PSNR 值越大越好, 图像质量越好, 计算公式如下。

$$SSIM(X, X') = \frac{(2\mu_x\mu_{x'} + C_1)(2\delta_{xx'} + C_2)}{(\mu_x^2\mu_{x'}^2 + C_1)(\delta_x^2\delta_{x'}^2 + C_2)} \quad (11)$$

其中:  $X$  和  $X'$  分别表示真实值和预测值,  $\mu_x$  和  $\mu_{x'}$  分别表示  $X$  和  $X'$  的平均值;  $\delta_x^2$  和  $\delta_{x'}^2$  分别表示  $X$  和  $X'$  的方差;  $\delta_{xx'}$  表示  $X$  和  $X'$  的协方差。  $C_1, C_2$  为常数。

$$MSE = \frac{1}{n} \sum_{i=1}^n (X_i - X'_i)^2 \quad (12)$$

$$PSNR = 10 \times \log_{10} \left( \frac{MAX_I^2}{MSE} \right) \quad (13)$$

$MAX_I$  表示图像颜色的最大数值。

## 2.2 实验结果

图 7 显示了训练过程中损失函数的变化曲线。

从损失函数来看, 定义的混合损失在经过 120 左右次迭代后损失降为 1 以下, 经过 400 次迭代, 损失下降

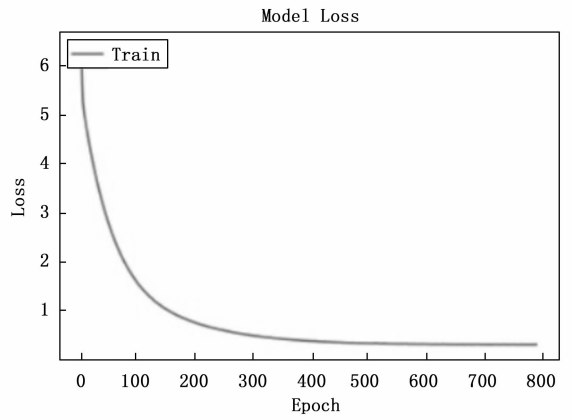



图 7 损失函数曲线

缓慢。随着训练的进行, 模型参数的更新幅度逐渐减小, 表明模型的学习过程逐渐收敛。这种现象使得模型能够更快地收敛到最优解, 同时避免了由于学习率过大而引起的权重更新误差。

网络对比分解结果如图 8 所示。



(a) 为真实值; (b) 为传统 U-Net 方法分解结果; (c) 为 Incept-Net 方法采用交叉熵损失函数分解结果; (d) 为 IU-Net 方法采用交叉熵损失函数分解结果; (e) 为 IU-Net 方法采用混合损失函数分解结果。

图 8 胸部不同方法的骨图和水图分解结果

图 8 第一列为实际的骨和水图, 第二列采用传统 U-Net 方法结合交叉熵损失函数的分解结果, 传统 U-Net 方法在骨的上半部分分解不准确, 并且存在较多伪影, 在水的部分, 伪影和噪声也很严重; 第三列为采用

Incept-Net 网络结合交叉熵损失函数的分解结果, Incept-Net 网络在骨的分解过程中, 边缘不是很清楚, 但从水和骨的整体效果来看, 要好于 U-Net 的分解效果; 第四列为 IU-Net 方法采用交叉熵损失函数的结果。整体来看, 效果要优于前两种方法, 伪影更少, 但是在骨图中间部分的效果还是不够好; 第五列为采用 IU-Net 网络结合交叉熵损失的分解结果。IU-Net 网络结合混合损失函数整体效果更好, 边缘更加清晰, 从骨的效果来看, 整体更接近真实值, 提供了更多重要的细节信息和更好的视觉效果。定量分析结果如表 1 所示。

表 1 不同方法分解效果的定量分析结果


方法		U-Net	Incept-Net	IU-Net 交叉熵损失	IU-Net 混合损失函数
骨	SSIM	0.920 4	0.972 2	0.985 2	0.996 7
	PSNR	40.728 4	43.423 7	44.529 5	46.648 1
水	SSIM	0.805 8	0.923 8	0.941 7	0.952 4
	PSNR	31.398	35.519 5	36.802 9	37.605 7

表 1 展示了使用不同方法进行图像分解后的定量分析结果, 通过比较 U-Net 网络结合交叉熵损失函数、Incept-Net 网络结合交叉熵损失函数、IU-Net 网络结合交叉熵损失函数和 IU-Net 网络结合混合损失函数的性能指标, 可以看出在骨和水方面, IU-Net 混合损失函数的表现最佳, 其 SSIM 值和 PSNR 值均高于其他 3 种方法。具体来说, 在骨的分解中, IU-Net 边缘损失函数的 SSIM 和 PSNR 分别达到了 0.996 7 和 46.648 1, 而在水的分解中, 分别达到了 0.952 4 和 37.605 7, 客观上说明其视觉效果更好。3 种方法的水的分解结果都略次于骨的分解结果, 这可能是由于水的结构复杂导致的。整体来说, 使用 IU-Net 边缘损失函数可以获得更准确和清晰的分解效果。

为进一步验证网络的泛化性能, 本文在肺部数据集上进行训练, 在腹部和腿部数据集上进行验证。结果如图 9、图 10 所示。

图 9 为腹部分解结果。从分解结果来看, 传统 U-Net 网络只能分解部分信息, 并不能很好的分解出水图和骨图。Incept-Net 大体上可以分解出骨图和水图, 虽然分解的比较完整, 但是存在很多分解错误的地方。IU-Net 方法采用交叉熵损失函数分解结果比前两种方法稍好, 但是从骨图分解结果来看, 在骨图中间部分分解不够完整。IU-Net 方法采用混合损失函数在骨图的分解效果较好, 虽然边缘不太光滑, 但整体效果更好。

图 10 显示了腿部分解结果。从分解结果来看, 尽管传统的 U-Net 网络和 Incept-Net 方法都能实现水图和骨图的分解, 但在实际应用中, 这些方法存在一定的分解不准确性。U-Net 网络在处理复杂的腿部结构时, 可



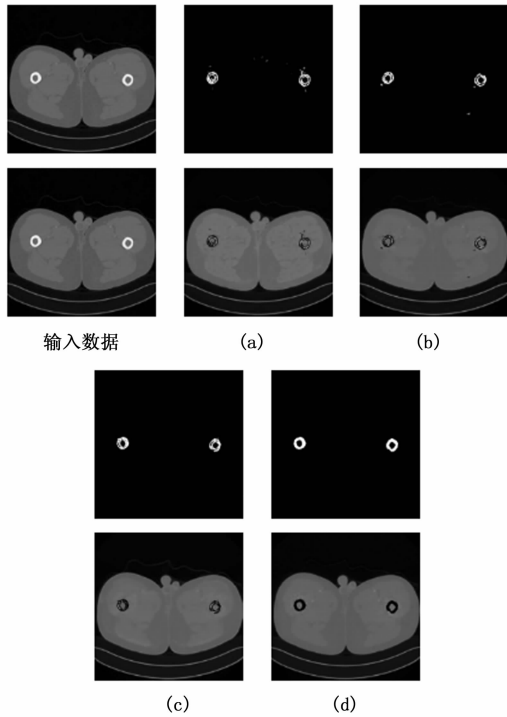
(a) 为传统 U-Net 方法分解结果;  
(b) 为 Incept-Net 方法采用交叉熵损失函数分解结果;  
(c) 为 IU-Net 方法采用交叉熵损失函数分解结果;  
(d) 为 IU-Net 方法采用混合损失函数分解结果。

图 9 腹部分解结果

能会导致水图和骨图的边缘不够精细, 影响最终的分解效果。Incept-Net 虽有改进, 但依然存在类似的问题。IU-Net 方法结合交叉熵损失函数, 相比于传统的 U-Net 和 Incept-Net, 其分解效果有所提升, 尤其在水图的准确性上表现更好。然而, 从骨图的分解结果来看, 骨图内部的细节处理上仍显不足, 部分区域的分解结果不够准确, 显示出一定的缺陷。IU-Net 方法结合混合损失函数的结果显示, 混合损失函数在骨图的分解上表现得更加出色, 尽管边缘细节可能不如理想的光滑, 但整体的分解效果明显优于之前的方法。这表明, 采用混合损失函数的模型在处理复杂结构的分解任务时, 具有更好的鲁棒性和泛化能力。

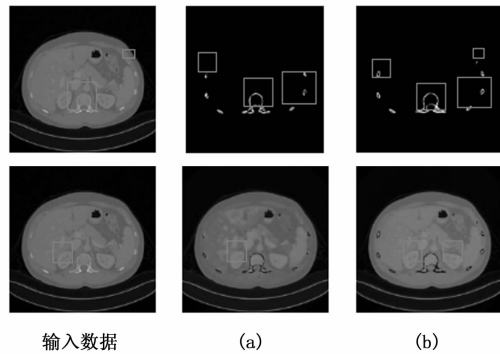
为了更客观的评估模型的性能, 对比在包含肺部、腹部、腿部的数据集上进行训练, 以及只在肺部数据集上进行训练, 在腹部和腿部数据集上进行验证, 结果如图 11、图 12 所示。需要注意的是, 测试集中的数据在训练集中都没有出现过。

图 11 显示了腹部在不同训练集上训练得到的分解结果。结果显示, 在骨组织的分解图中, 当数据集中包含腹部数据时, 可以提取到更完整的骨部数据信息, 同时骨部分解后的图像边缘信息更加完整; 在水图方面,



(a) 为传统 U-Net 方法分解结果;  
 (b) 为 Incept-Net 方法采用交叉熵损失函数分解结果;  
 (c) 为 IU-Net 方法采用交叉熵损失函数分解结果;  
 (d) 为 IU-Net 方法采用混合损失函数分解结果。

图 10 腿部分解结果




(a) 为肺部数据集上训练, 腹部数据集测试分解结果;  
 (b) 为包含肺部、腹部、腿部数据集上训练, 腹部数据集测试分解结果。

图 11 腹部分解结果

当训练集包含腹部数据时, 内部细节信息更加清晰和完整, 而训练集中不含腹部数据时, 内部信息较为模糊。整体来看, 当数据集中包含腹部数据时, 分解精度更高。

图 12 显示了腿部在不同训练集上训练得到的分解结果。结果显示, 当数据集中包含腿部数据时, 分解效果显著提高。具体而言, 在骨组织的分解图中边缘更加



(a) 为肺部数据集上训练, 腿部数据集测试分解结果;  
 (b) 为包含肺部、腹部、腿部数据集上训练, 腿部数据集测试分解结果。

图 12 腿部分解结果

完整和光滑; 在水图方面, 当训练集包含腿部数据时, 能够更清晰地恢复出更多的内部细节信息。

### 3 结束语

本文提出了一种改进 U-Net 网络的双能 CT 材料分解策略来解决 DECT 中图像域材料分解问题。提出的 IU-Net 网络保留了 U-Net 的解码器, 提出了新的编码器。编码器部分采用了一种类似于 Inception 网络的结构, 同时结合了不同大小的卷积核来提取特征。进而网络可以在不同尺度上捕获图像的特征, 提高了特征提取的多样性和丰富性, 提高图像的细节保持能力。网络引入批量归一化和  $L_2$  正则化, 有效地减少了模型的过拟合风险, 增强了模型的泛化能力。实验证明, 新提出的编码器能够有效地综合和平衡从不同采样路径提取的局部和非局部特征。此外, 定义了新的混合函数, 边缘损失函数保证图像边缘不受损, MSE 损失对于离群值比较敏感, 而交叉熵损失在处理问题时对离群值相对不那么敏感, 通过将它们结合, 可以减少模型对离群值的敏感度, 提高模型的泛化能力。但是, 对于内部结构较为复杂的材料, 分解结果还有待提高, 总之, IU-Net 网络产生了更准确的分解结果, 获得了更高质量的材料图, 有一定的应用价值。未来的工作将针对内部结构较为复杂的材料进行网络调整, 进一步改进所提方法。此外还需要更先进的网络架构来提高能谱 CT 中基材料分解的精度。

#### 参考文献:

[1] ALVAREZ R E, MACOVSKI A. Energy-selective reconstructions in X-ray computerised tomography [J]. Physics in Medicine and Biology, 1976, 21 (5): 733 - 744.  
 [2] GENG M, TIAN Z, JIANG Z, et al. PMS-GAN: Parallel Multi-Stream Generative Adversarial Network for Multi-



- Material Decomposition in Spectral Computed Tomography [J]. IEEE Transactions on Medical Imaging, 2021, 40 (2): 571–584.
- [3] FANG W, WU D, KIM K, et al. Iterative material decomposition for spectral CT using self-supervised Noise2Noise prior [J]. Physics in Medicine and Biology, 2021, 66 (15): 155013.
- [4] YAO Y, LI L, CHEN Z. Dynamic-dual-energy spectral CT for improving multi-material decomposition in image-domain [J]. Physics in Medicine and Biology, 2019, 64 (13): 135006.
- [5] BARBER R F, SIDKY E Y, SCHMIDT T G, et al. An algorithm for constrained one-step inversion of spectral CT data [J]. Physics in Medicine and Biology, 2016, 61 (10): 3784–3818.
- [6] CHEN B, ZHANG Z, SIDKY E Y, XIA D, PAN X. Image reconstruction and scan configurations enabled by optimization-based algorithms in multispectral CT [J]. Physics in Medicine and Biology, 2017, 62 (22): 8763–8793.
- [7] TILLEY S, ZBIJEWSKI W, STAYMAN J W. Model-based material decomposition with a penalized nonlinear least-squares CT reconstruction algorithm [J]. Physics in Medicine and Biology, 2019, 64 (3): 035005.
- [8] 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.
- [9] GONG H, TAO S, RAJENDRAN K, et al. Deep-learning-based direct inversion for material decomposition [J]. Medical Physics, 2020, 47 (12): 6294–6309.
- [10] NIU T, DONG X, PETRONGOLO M, ZHU L. Iterative image-domain decomposition for dual-energy CT [J]. Medical physics, 2014, 41 (4): 041901.
- [11] SUKOVIC P, CLINTHORNE N H. Penalized weighted least-squares image reconstruction for dual energy X-ray transmission tomography [J]. IEEE Transactions on Medical Imaging, 2000, 19 (11): 1075–1081.
- [12] CHEN B, ZHANG Z, XIA D, SIDKY E Y, PAN X. Dual-energy CT imaging with limited-angular-range data [J]. Physics in Medicine and Biology, 2021, 66 (18): 185020.
- [13] STENNER P, BERKUS T, KACHELRIESS M. Empirical dual energy calibration (EDEEC) for cone-beam computed tomography [J]. Medical physics, 2007, 34 (9): 3630–3641.
- [14] ZAHANGIR M A, MAHMUDUL H, CHRIS Y, et al. Inception recurrent convolutional neural network for object recognition [J]. Machine Vision and Applications, 2021, 32 (1): 28.
- [15] WU X, HE P, LONG Z, et al. Multi-material decomposition of spectral CT images via fully convolutional denseNets [J]. Journal of X-Ray Science and Technology, 2019, 27 (3): 461–471.
- [16] JI X, LU Y, ZHANG Y, et al. SeNAS-Net: self-supervised noise and artifact suppression network for material decomposition in spectral CT [J]. IEEE Transactions Computational Imaging, 2024, 10: 677–689.
- [17] 王冲旭, 陈平, 潘晋孝, 等. 基于迭代残差网络的双能 CT 图像材料分解研究 [J]. CT 理论与应用研究, 2022, 31 (1): 47–54.
- [18] NADKARNI R, ALLPHIN A, CLARK D P, et al. Material decomposition from photon-counting CT using a convolutional neural network and energy-integrating CT training labels [J]. Physics in Medicine and Biology, 2022, 67 (15): 155003.
- [19] SEIF G, ANDROUTSOS D. Edge-Based Loss Function for Single Image Super-Resolution [A]. 2018 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP), 2018: 1468–1472.
- [20] RUSSELL B C, TORRALBA A, MURPHY K P, et al. LabelMe: A database and Web-based tool for image annotation [J]. International Journal of computer vision, 2008, 77 (1): 157–173.
- [21] 李明明, 卢鸿谦, 王振凯, 等. 基于偏振光及重力的辅助定姿方法研究 [J]. 宇航学报, 2012, 33 (8): 1087–1095.
- [22] 黄靖, 任延超, 尹文, 等. 仿生偏振光定向技术发展现状 [C] //2023 年全国智能导航学术论文集, 2023: 25–30.
- [23] DIMITRIOS LAMBRINOS, RALF MÖLLER, THOMAS LABHART, et al. A mobile robot employing insect strategies for navigation [J]. Robotics and Autonomous Systems, 2000, 30 (1): 39–64.

(上接第 251 页)

- [17] 范宁生. 基于 POL-神经元的仿生偏振光导航传感器研究 [D]. 合肥: 合肥工业大学, 2011.
- [18] 程珍, 梅涛, 梁华为, 等. 一种偏振光自定位方法的分析及实现 [J]. 光电工程, 2015 (6): 33–38.
- [19] 刘俊, 唐军, 申冲. 大气偏振光导航技术 [J]. 导航定位与授时, 2015, 2 (2): 1–6.
- [20] 王晨光, 唐军, 杨江涛, 等. 仿生偏振光检测系统的设计与实现 [J]. 光电技术应用, 2016, 37 (2): 260–265.