

**基于残差挤压激励神经网络的材料分解**

张 然, 孔慧华, 李佳欣, 宋一娇

Dense Sandstone Material Decomposition Based on Improved Convolutional Neural Network

ZHANG Ran, KONG Huihua, LI Jiaxin, and SONG Yijiao

在线阅读 View online: <https://doi.org/10.15953/j.ctta.2024.131>**您可能感兴趣的其他文章****Articles you may be interested in****基于迭代残差网络的双能CT图像材料分解研究**

Research on Material Decomposition of Dual-energy CT Image Based on Iterative Residual Network

CT理论与应用研究. 2022, 31(1): 47–54

基于改进U-Net卷积神经网络的储层预测

Reservoir Prediction Based on Improved U-Net Convolutional Neural Network

CT理论与应用研究. 2021, 30(4): 403–416

基于对抗式残差密集深度神经网络的CT稀疏重建

Sparse CT Reconstruction Based on Adversarial Residual Dense Deep Neural Network

CT理论与应用研究. 2022, 31(2): 163–172

基于卷积神经网络的断层预测方法

Fault Prediction Method Based on Convolutional Neural Network

CT理论与应用研究. 2020, 29(5): 522–533

探讨基于卷积神经网络对颅底骨折CT图像精准诊断的应用价值

The Application Value of Accurate Diagnosis of CT Image of Skull Base Fractures based on Convolutional Neural Network

CT理论与应用研究. 2021, 30(6): 769–776

基于瓶颈残差注意力机制U-net的肝脏肿瘤分割

Segmentation of Liver Tumors Based on Bottleneck Residual Attention Mechanism U-net

CT理论与应用研究. 2021, 30(6): 661–670



关注微信公众号, 获得更多资讯信息

张然, 孔慧华, 李佳欣, 等. 基于残差挤压激励神经网络的材料分解[J]. CT 理论与应用研究 (中英文), 2025, 34(1): 117-128. DOI:10.15953/j.ctta.2024.131.

ZHANG R, KONG H H, LI J X, et al. Dense Sandstone Material Decomposition Based on Improved Convolutional Neural Network[J]. CT Theory and Applications, 2025, 34(1): 117-128. DOI:10.15953/j.ctta.2024.131. (in Chinese).

基于残差挤压激励神经网络的材料分解

张然^{1,2}, 孔慧华^{1,2✉}, 李佳欣^{1,2}, 宋一娇^{1,2}

1. 中北大学数学学院, 太原 030051

2. 信息探测与处理山西省重点实验室, 太原 030051

摘要: 能谱 CT 能够提供扫描对象的定量信息, 实现材料分解。基于神经网络的材料分解方法有效克服了传统迭代算法在分解效果上的局限性, 但是在细节特征恢复方面仍存在不足。为了提高材料分解精度并保留图像的细节信息, 我们提出一种基于残差挤压激励网络 (RS-Net) 的材料分解方法。本方法利用 U-Net 网络的结构, 采用 Resnet-152 作为主干网络提取多尺度特征; 利用并行非对称卷积来完成大核卷积, 减少网络的参数数量和计算量; 在解码器部分引入 HD-SE 注意力机制帮助网络恢复图像特征; 采用混合损失监督网络学习, 提高网络的分解精度。在仿真岩石数据集和人造砂岩数据集上验证该方法的可行性, 仿真和实际实验结果表明, RS-Net 结合混合损失保留更多图像内部细节信息, 分解后的图像边缘更为清晰, 图像质量更高。

关键词: 能谱 CT; 卷积神经网络; 材料分解; 注意力机制

DOI:10.15953/j.ctta.2024.131 中图分类号: O 242; TP 391 文献标识码: A

Dense Sandstone Material Decomposition Based on Improved Convolutional Neural Network

ZHANG Ran^{1,2}, KONG Huihua^{1,2✉}, LI Jiaxin^{1,2}, SONG Yijiao^{1,2}

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

2. Shanxi Key Laboratory of Signal Capturing and Processing, Taiyuan 030051, China

Abstract: Energy spectrum computed tomography can provide quantitative information of scanned objects and realize material decomposition. At present, the material decomposition method based on neural networks overcomes the limited decomposition effect of traditional iterative algorithms. However, the performance of traditional neural networks in feature detail recovery is still not satisfactory. To improve the material decomposition accuracy, a material decomposition method based on a Resnet and Squeeze excitation network (RS-Net) is proposed. The proposed method uses the structure of the U-Net network and Resnet-152 as the backbone network to extract multi-scale features. Parallel asymmetric convolution is used to complete the large kernel convolution, which reduces the number of parameters and computation of the network. The HD-SE attention mechanism is introduced in the decoder part to help the network recover the image features. Hybrid loss supervised network learning is used to improve the decomposition accuracy of the network. The feasibility of this method is verified on simulated rock and artificial sandstone datasets. The simulation and experimental results show that RS-Net combined with mixing loss can retain more internal details of the image, the decomposed image edge is clearer, and the image quality is higher.

Keywords: spectrum CT; convolutional neural network; material decomposition; attention mechanisms

与传统 CT 相比, 能谱 CT 可以通过材料分解 来识别物质成分。材料分解算法是由阿尔瓦雷斯和

收稿日期: 2024-07-10。

基金项目: 山西省基础研究计划 (基于能谱 CT 和深度迁移学习的致密油砂岩组分结构的定量表征方法研究 (202103021224190); 面向碳封存的煤岩盖层孔隙结构 X 射线多谱 CT 多尺度表征方法 (202203021222052)); 国家重点研发计划 (半导体器件封装质量智能检测关键技术研究与应用示范 (2023YFE0205800)); 山西省留学基金 (基于微焦点 CT 多谱序列盲分离的材料组分彩色表征方法 (2023-129))。

第一作者: 张然, 女, 数学专业硕士研究生, 研究方向为 CT 图像处理和图像重建, E-mail: 2779189605@qq.com。

通信作者: 孔慧华[✉], 女, 博士, 教授、硕士生导师, 主要从事 CT 图像重建、工程中的数学问题的研究, E-mail: huihuak@163.com。

马科夫斯基在 1976 年基于双能 CT (dual-energy computed tomography, DECT) 率先提出的^[1]。随着能谱 CT 探测器的发展, 更高精度的多材料分解算法应用而生^[2-5]。

多材料分解 (material decomposition, MD) 算法已被开发用于双能和多能 CT^[6-7]。传统的多材料分解算法主要分为一步法和两步法, 一步法即直接迭代的材料分解方法, 该方法将多能材料分解与图像重建两个过程合并, 降低了计算速度。两步法包括基于投影域和基于图像域的材料分解方法^[8-9]。基于投影域的材料分解方法能够有效消除伪影, 提高分解效果^[10], 但是不同能量区间下投影数据失配会严重影响该方法的分解精度。基于图像域的材料分解方法的分解性能与重建算法密切相关^[11], 图像域分解可以直接应用于商用多能 CT 扫描系统获取的图像。因此, 本文主要研究基于图像域的材料分解方法。

近年来, 神经网络在图像去噪、分割、检测、识别等各种成像应用中受到了广泛关注^[12-14]。许多研究表明, 神经网络通过特征学习和特征提取来解决识别问题, 可有效地提高材料分解的效率和准确性。研究者们通过串联的深度神经网络以及改进的全卷积神经网络实现了双能 CT 的组分分解问题。Incept-Net 提高了 DECT 材料的分解鲁棒性, 克服了对剂量变化的敏感性, 表现出良好的泛化能力^[13]。基于改进的全卷积神经网络 (FCDense-Net) 的方法在多材料分解中表现出良好的性能, 图像对比度和去噪在 MD 中得到了进一步的发展^[14]。SeNAS-Net 将 Ne2Ne 引入多能 CT 材料分解中, 在抑制能谱 CT 材料分解中的噪声和伪影方面具有良好的性能。已经开发的前馈神经网络投影分解技术, 在仿真数据上成功实现了对多种材料的投影分解^[15]。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深度学习方, 验证了神经网络方法具有更好的投影分解效果^[16]。利用联合模型驱动的卷积神经网络进行能谱 CT 图像处理, 可以避免传统重建方法的局限性, 同时降低图像的噪声和伪影, 从而提高了分解的准确性和效率^[17-18]。

注意力机制在图像处理中已经成为一种流行方法, 其独特的能力和优势主要体现在突出关键细节、抑制多余信息, 进而增强表征能力。挤压激励 (squeeze-and-excitation, SE) 注意通过全局平均池化来学习特征关系, 以获取通道维度上的上下文信息^[19]。ECA-Net 采用了一种局部跨通道交互策略, 保

持了通道特征的维度, 有效避免了降维对通道特征的影响^[20]。除了单通道注意机制外, 卷积注意模块 (convolutional block attention module, CBAM) 结合通道注意力模块和空间注意力模块, 充分利用它们之间的互补性, 以获取重要信息并抑制无用信息^[21]。

为了改进多能 CT 图像域材料分解方法, 获得高质量的分解材料图像, 本文提出一种基于卷积神经网络的 RS-Net 材料分解方法。RS-Net 采用并行非对称卷积代替大核卷积提取多尺度特征图中的全局特征信息, 并在多层特征图的融合过程中嵌入注意机制, 利用 HD-SE 模块从图像中提取重要的特征, 避免计算资源的浪费, 引入混合损失监督网络学习, 提高网络的效率。

1 方法论述

1.1 图像域的材料分解模型

材料分解是通过分析 X 射线光子能量的吸收进而可以识别其成分。对于能量为 E 的单能量 X 射线, 在位置 \vec{r} 的线性衰减系数 $\mu(E, \vec{r})$, 可以分解为 k 个基本材料线性组合:

$$\mu(E, \vec{r}) = \sum_{k=1}^K a_k(\vec{r}) \mu_k(E), \quad (1)$$

式中 $a_k(\vec{r})$ 为第 k 种材料在 \vec{r} 位置的体积分数。对于能谱 CT 图像, 式 (1) 可表示为一个矩阵:

$$\begin{pmatrix} \mu(E_1, \vec{r}) \\ \vdots \\ \mu(E_M, \vec{r}) \end{pmatrix} = \begin{pmatrix} \mu_1(E_1) & \cdots & \mu_K(E_1) \\ \vdots & \ddots & \vdots \\ \mu_1(E_M) & \cdots & \mu_K(E_M) \end{pmatrix} \begin{pmatrix} a_1(\vec{r}) \\ \vdots \\ a_K(\vec{r}) \end{pmatrix}, \quad (2)$$

其中, $m(1, 2, \dots, M)$ 表示能量通道。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。但是, 矩阵 (2) 通常是病态的, 轻微扰动会导致分解精度急剧下降。因此, 引入可逆算子 \mathcal{M} , 建立映射关系:

$$\mathcal{M}^{-1} : \mu \mapsto a, \quad (3)$$

这里 \mathcal{M}^{-1} 是图像域中混合算子的反演。在 RS-Net 网络中, 以多通道重建图像作为输入, 以单物质重建图像作为输出。因此, 材料分解可以看作是一个成像逆问题。算子 \mathcal{M}^{-1} 是解决问题的关键。

1.2 基于 RS-Net 的材料分解模型

不同能量通道之间的能谱 CT 图像存在相似的结构特征, 但它们所包含的衰减信息不同。因此,

可以根据能谱 CT 图像的衰减差异和结构相关性构建足够大的数据集，并通过深度学习技术提高能谱 CT 图像中物质分解的精度。深度学习能够有效地进行特征信息的提取与学习，从而挖掘数据集中的内在规律和深层次特征。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，为深度学习框架开辟了一条新的途径。

1.2.1 RS-Net 网络结构

我们在 U-Net 算法的基础上，设计用于能谱 CT 图像材料分解的残差挤压激励网络 (rsenet and squeeze excitation network, RS-Net)。RS-Net 网络的结构如图 1 所示。网络将能谱 CT 图像输入，生成相应的物质分解预测图，同时通过引入边缘损失函数优化网络参数，使得图像边缘更加清晰。

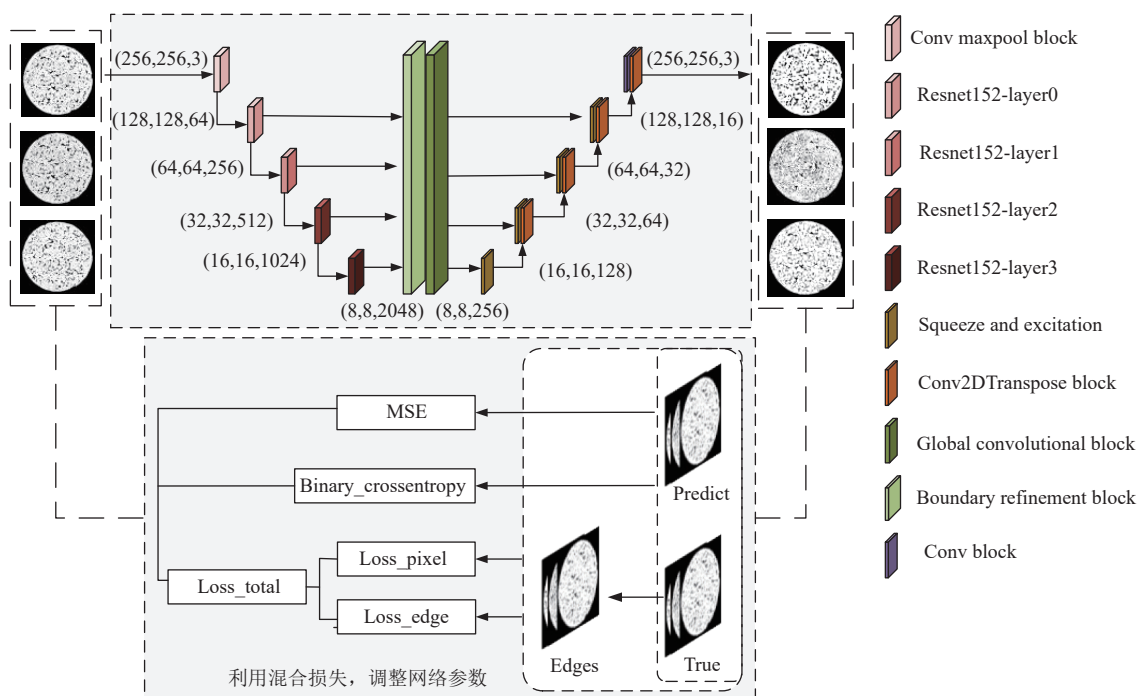


图 1 网络整体结构图

Fig.1 Overall structure of the network

RS-Net 网络为 U 型网络。本研究采用 Resnet-152 作为 RS-Net 的骨干网，骨干网详细信息如表 1 所示。首先，输入图像经过卷积最大池化块 (Convolutional and maxpool block, CMB) 初步提取图像特征，之后从骨干网络的不同阶段提取输入的多尺度特征图。随后，采用全局卷积块 (global convolutional block, GCB) 提取特征图的全局信息，采用边界细化块 (boundary refinement block, BRB) 帮助模型学习特征图的边界信息。GCB 采用大卷积核实现全局卷积，使每一层的特征信息与像素类别紧密相关。然而，较大卷积核的卷积运算在学习过程中会带来过多的计算和存储需求。因此，GCB 采用并行非对称卷积来完成大核卷积，有效地减少了网络的参数数量和计算量。

然后利用 CTB (Conv 2D transpose block) 反卷积上采样块对特征图进行上采样，并与特征图合并生成新的特征图。最后一个 CB (convolutional block) 生成最终的预测图，用于输出 RS-Net 的分

解结果。GCB、BRB、CTB 和 CB 的组成见表 2。

表 1 骨干网络结构
Table 1 Backbone network structure

项目	Conv 2D (kerne_size,out_channels)
CMB	3×3 Conv
	BN
	ReLU
	Maxpool, strid 2
Resnet152-layer0	$\begin{pmatrix} 1 \times 1, 64 \\ 3 \times 3, 64 \\ 1 \times 1, 256 \end{pmatrix} \times 3$
Resnet152-layer1	$\begin{pmatrix} 1 \times 1, 128 \\ 3 \times 3, 128 \\ 1 \times 1, 512 \end{pmatrix} \times 8$
Resnet152-layer2	$\begin{pmatrix} 1 \times 1, 256 \\ 3 \times 3, 256 \\ 1 \times 1, 1024 \end{pmatrix} \times 36$
Resnet152-layer3	$\begin{pmatrix} 1 \times 1, 512 \\ 3 \times 3, 512 \\ 1 \times 1, 2048 \end{pmatrix} \times 3$

表 2 GCB、BRB、CMB 结构
Table 2 GCB, BRB, and CMB structure

GCB	BRB	CTB	CB
$1 \times 16 \text{ Conv}, 16 \times 1 \text{ Conv}$	$3 \times 3 \text{ Conv}$ $3 \times 3 \text{ Conv}$	$3 \times 3 \text{ Conv}$	$3 \times 3 \text{ Conv}$
$16 \times 1 \text{ Conv}, 1 \times 16 \text{ Conv}$	BN ReLU	$3 \times 3 \text{ Conv2 DTranspose}$	$3 \times 3 \text{ Conv}$

1.2.2 HD-SE 模块结构

注意力机制能够赋予特征图不同的权重，从而有助于网络学习关键信息，使其在学习过程中作出更精确的决策。最近，注意力机制已经成为执行深度学习任务的强大工具。我们引入 HD-SE (height dimensional SE) 模块，并将它们整合到网络中^[22]。图 2 显示了 HD-SE 的结构及应用于 RS-Net 的结构。在 RS-Net 残差结构中，将 HD-SE 嵌入于解码器块的第二个卷积操作之后，用来捕获更多的特征图隐藏的信息。

HD-SE 模块将挤压激励操作应用于特征图的高度维度，进而捕获更多有用的信息，增强特征图张量的高度维度信息。在应用 HD-SE 模块之前，首先特征图 U_1 按照高度 \times 宽度 \times 通道输入，之后对 U_1 使用全局平均池化进行挤压操作，得到 $Y \in R^{H \times 1 \times 1}$ 特征向量；接着对 Y 降维得到 $Y_1 \in R^{H/r \times 1 \times 1}$ ，最后采用升维卷积模块对 Y_1 进行升维得到 $Y_2 \in R^{H \times 1 \times 1}$ ；最后，将惩罚系数 β 运用到挤压激励后的 U_1 中，恢复到原来的 $R^{H \times W \times C}$ 维度得到输出的特征图。

1.2.3 损失函数

为了增强网络的材料分解性能，除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。

边缘损失函数优化了重建图像的边缘像素，可以产生更清晰的图像。边缘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^[23]。为了形成边缘损失分量，我们首先将 Canny 边缘检测器（使用 Python 默认参数）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，则被丢弃。基于像素的损失函数提高了重建图像的整体准确性，即像素值与原始图像的像素值直接相似。这确保了图像的颜色、明暗和整体对比度没有重大变化。函数如下：

$$\text{loss}_{\text{pixels}} = \frac{\sum_{i=1}^I \sum_{j=1}^J (|Y_{i,j} - Y'_{i,j}|)}{IJ} \quad (4)$$

结构损失函数确保生成的图像具有清晰的、易于识别的边缘和结构。结构如下：

$$\text{loss}_{\text{edges}} = \frac{\sum_{i=1}^I \sum_{j=1}^J G_{i,j} \cdot (|Y_{i,j} - Y'_{i,j}|)}{IJ} \quad (5)$$

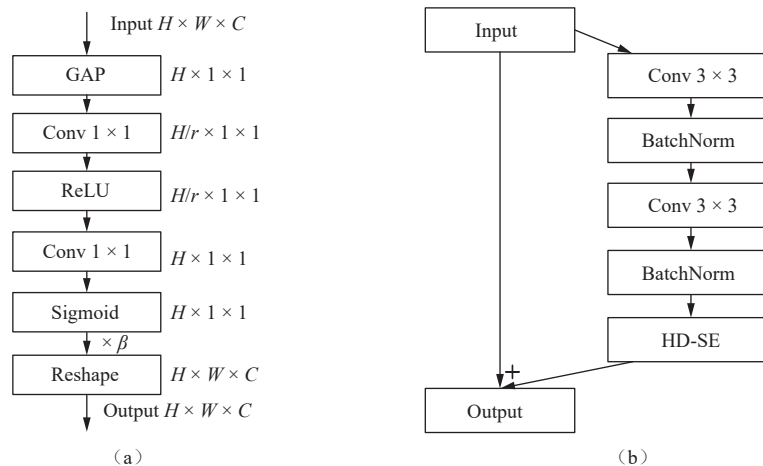


图 2 (a) HD-SE 网络结构, (b) Resnet + HD-SE 结构图

Fig.2 (a) HD-SE network structure, (b) Resnet + HD-SE structure diagram

总体损失为：

$$L_1 = \alpha \cdot \text{loss}_{\text{pixels}} + (1 - \alpha) \cdot \text{loss}_{\text{edges}}, \quad (6)$$

其中 Y 和 Y' 分别是网络输出的图像和真实的图像， $|Y_{i,j} - Y'_{i,j}|$ 表示了输出图像与真实图像的对应像素点的绝对误差 $G_{i,j}$ 为提取的边缘图像， I 和 J 分别为图像的宽度和高度

此外，引入 MSE 和交叉熵损失函数共同监督网络学习。定义混合损失函数为：

$$L_{\text{loss}} = \gamma L_1 + \beta L_2 + \theta L_3, \quad (7)$$

其中， α 、 β 、 γ 和 θ 表示权重。

2 实验设置与结果分析

我们提出的 RS-Net 是使用 Keras 和 TensorFlow 框架在 GPU (NVIDIA RTX A6000) 的计算机平台上实现的，该模型的学习率最初设置为 1×10^{-5} ，在本研究中，使用 Adam 来优化损失函数。

为了评价所提出来的材料分解方法的性能，采用结构相似性指数 (SSIM)，峰值信噪比 (PSNR) 作为评估指标，判断预测结果和真实标签之间的相似性。

2.1 仿真模体实验

多能 X 射线由 Spekpyv2.0 能谱仿真软件生成，仿真的 X 射线源为点源。X 射线源距离旋转中心 100mm，探测器长度为 20mm，探测器共有 256 个单元，每次扫描在 $[0, 2\pi]$ 范围内均匀采集 256 个角

度的投影。

图 3 为该实验设计的仿真模体结构，该模体包含空气 (Air)、石英和钠长石 (SiO_2)、方解石 (CaCO_3) 和黄铁矿 (FeS_2)，图像大小为 256×256 。模体仿真实验在 3 个能量通道中进行，分别为： $[20, 30)$ 、 $[30, 40)$ 和 $[40, 50)$ keV，共生成 800 组数据，其中 700 组用作数据集，100 组用作测试集。




图 3 仿真模体截面图

Fig.3 Cross-sectional diagram of the simulation body

2.1.1 基本算法比较实验

收集测试数据集中的分解结果，比较传统 U-Net，改进 Incept-Net^[13]和 RS-Net 的分解精度。为验证网络的性能，我们采用相同的数据集和训练次数。图 4 显示了 3 种网络的分解结果

第一列图像为输入图像，第二列为真实值，第三~六列图像是每种方法对 SiO_2 、 FeS_2 和 CaCO_3




图 4 不同方法图像域的分解结果，从上到下分别为 SiO_2 、 FeS_2 、 CaCO_3

Fig.4 Decomposition results of image domains using different methods. From top to bottom: SiO_2 , FeS_2 , and CaCO_3

的分解结果。从分解结果来看，U-Net 方法和 Incept_Net 网络都不能得到理想的分解效果；提出的 RS-Net 方法在结合交叉熵损失时分解效果较 U-Net 方法和 Incept_Net 网络有显著提升，但是边缘效果不好，在 SiO₂ 的分解效果中可以很明显的看出；RS-Net 方法结合边缘损失可以更好的恢复边缘信息并提高分解精度。表 3 为定量分析的结果。

定量分析结果显示，改进后的 RS-Net 算法具有

更高的 SSIM 值和 PSNR 值，在 3 种成分的结构相似度分别达到了较高的 0.9550、0.9703 和 0.9656。尤其 FeS₂ 的 PSNR 值达到了 37.7823。改进 RS-Net 在 SiO₂ 上的分解效果次于 FeS₂ 和 CaCO₃ 这可能是因为 SiO₂ 内部结构复杂导致的。定性和定量的评估表明，所提出的 RS-Net 具有优越的性能。这意味着该算法在分解含有 SiO₂、FeS₂、CaCO₃ 的岩石方面表现更佳。

表 3 不同方法下图像域多材料分解的定量测量结果

Table 3 Quantitative measurement results of projection domain multi-material decomposition using different methods

材料	方法	U-Net	Incept-Net	RS-Net 交叉熵损失	RS-Net 混合损失
SiO ₂	SSIM	0.6066	0.4616	0.4823	0.9550
	PSNR	28.0910	27.9885	29.2897	29.8026
FeS ₂	SSIM	0.6924	0.6033	0.7823	0.9703
	PSNR	37.1515	32.9031	36.0319	37.7823
CaCO ₃	SSIM	0.3748	0.5835	0.6381	0.9656
	PSNR	28.1097	30.8245	32.1277	33.8001

2.1.2 衰减系数相似实验

为了验证提出方法对衰减系数相近的材料分解效果，将模体仿真实验在 3 个能量通道中进行，分别为：[60, 80)、[80, 100) 和 [100, 120) keV 中进行。在这 3 个能量段下，石英和钠长石 (SiO₂)、方解石 (CaCO₃) 和黄铁矿 (FeS₂) 这 3 种物质的衰减系数相近 (图 5)。

如图 6 为在 [60, 80)、[80, 100) 和 [100, 120) keV 3 个能量段下的训练集样例。

为验证网络的泛化性能，采用的测试集的数据在训练集中完全没有出现过，即测试集中的数据是完全独立于训练集数据的。实验结果如图 7 所示。

从分解结果来看，当测试集与训练集存在较大差异时，U-Net 方法和 Incept_Net 网络的分解效果较差，尤其是在 SiO₂ 的分解上尤为明显。提出的 RS-Net 方法在结合交叉熵损失后，相较于 U-Net

和 Incept_Net 方法，分解效果有了显著提升。然而，RS-Net 方法在边缘效果方面仍有不足，特别是在




图 5 X 射线线性吸收系数图

Fig.5 Linear X-ray absorption coefficient




图 6 训练集样例

Fig.6 Sample training set




图 7 测试集分解结果

Fig.7 Test set decomposition results

SiO₂ 右侧的圆形区域和 FeS₂ 上侧的椭圆形区域都可以观察到这一点。通过结合边缘损失，RS-Net

方法能够更好地恢复边缘信息，提高分解精度。定量分析结果见表 4。

表 4 测试集分解定量结果
Table 4 Quantitative results of test set decomposition

材料	方法	U-Net	Incept-Net	RS-Net 交叉熵损失	RS-Net 混合损失
SiO ₂	SSIM	0.8875	0.9034	0.9946	0.9989
	PSNR	37.6035	40.3960	48.7807	49.8026
FeS ₂	SSIM	0.9684	0.9553	0.9959	0.9986
	PSNR	45.3823	44.9185	48.1235	49.6732
CaCO ₃	SSIM	0.9879	0.9795	0.9779	0.9970
	PSNR	47.8170	45.0905	44.7654	49.3658

根据表中的数据分析，RS-Net 结合混合损失在所有测试材料中的表现均优于其他方法。在 SiO₂ 的分解中，RS-Net 结合混合损失显示出最佳的分解效果，明显超越了 U-Net 和 Incept-Net。类似地，在 FeS₂ 的分解中，RS-Net 结合混合损失也表现出最优的结果，表明在恢复结构信息方面具有显著优势。总体来说，RS-Net 结合混合损失在各种材料的分解精度上都表现最佳，优于 U-Net 和 Incept-Net，尤其在细节恢复和结构准确性方面具有显著优势。

为了更客观地评估模型的性能，实验中，新建模体如图 8 所示，其中正方形为 SiO₂，长方形为 CaCO₃，三角形为 FeS₂。为值得注意的是，该模体只在测试阶段被使用，并没有被包含在用来训练模型

的数据集中，即测试集中的数据是完全独立于训练集数据的。实验结果如图 9 所示。




图 8 测试集图像样例

Fig.8 Example of test set diagram




图 9 新增测试集分解结果
Fig.9 New test set decomposition results

从分解结果来看，当测试集与训练集之间存在显著差异时，U-Net 方法和 Incept_Net 网络的分解效果表现较差。具体来说，U-Net 方法无法有效分解 FeS₂，而对于 SiO₂，虽然整体框架有所呈现，但效果仍不理想。Incept_Net 网络虽然能整体分解目标，但仍存在一定的分解错误，且边缘效果不佳。相对而言，提出的 RS-Net 方法在结合交叉熵损失函数后，相比 U-Net 和 Incept_Net，显著减少分解

错误，提升分解效果。然而，RS-Net 方法在边缘效果方面仍有不足，尤其是在 FeS₂ 和 CaCO₃ 的直线区域表现较差。结合边缘损失函数后，RS-Net 在恢复边缘信息和提高分解精度方面取得了进展，在直线区域效果较好，但由于训练数据集中只有圆形数据，对测试集中数据的顶点部分效果恢复不佳，例如 SiO₂ 的四个角信息恢复效果不理想。表 5 显示了定量分析的结果。

表 5 新增测试集分解定量结果
Table 5 Added quantitative results of test set decomposition

材料	方法	U-Net	Incept-Net	RS-Net 交叉熵损失	RS-Net 混合损失
SiO ₂	SSIM	0.9353	0.9769	0.9867	0.9987
	PSNR	52.9134	51.7182	55.9413	67.0735
FeS ₂	SSIM	0.8928	0.9340	0.9281	0.9597
	PSNR	51.3739	51.4266	54.9261	57.7916
CaCO ₃	SSIM	0.9304	0.9364	0.9285	0.9806
	PSNR	52.7683	52.9481	53.9886	56.4517

定量分析结果显示，虽然 Incept-Net 的整体表现略优于 U-Net，但差距并不明显。两者在所有材料的 SSIM 与 PSNR 值都低于 RS-Net。RS-Net 在所有材料的分解效果上均表现最佳，尤其在结合混合损失后，进一步提高网络的分解精度。其中，SiO₂ 的分解效果明显优于 FeS₂ 和 CaCO₃，在这表明不同材料的特性对分解效果有直接影响。但是该

实验的效果没有圆形仿真实验的效果好，这可能是因为训练集中没有方形数据造成的，之后的研究要更进一步提高网络的泛化性能。

2.1.3 加噪实验

为了进一步研究所提出的 RS-Net 对噪声是否敏感，将高斯噪声引入到图像中。

$$I' = I + N, \quad (8)$$

其中 I 表示加噪前的图像； I' 表示加噪后的图像； N 服从 $N(0, \delta^2)$ 的高斯分布，0 表示噪声平均值为 0，不偏离原图像亮度， δ^2 表示噪声强度，文中取值为 0.6。

加噪后的图像域图像如图 10 所示。加噪后的图像域分解结果如图 11 所示。

从实验结果来看，本文提出的 RS-Net 在噪声抑制方面有很好的效果，从分解结果来看，在 SiO_2 上效果更好。该网络能有效抑制噪声和伪影。

2.1.4 消融实验

为了判断 HD-SE 模块对网络的影响，引入消融实验，由于 HD-SE 关注模块具有良好的兼容性和稳定性，可以很好地提取图像的全局信息，并在各个方向上提高网络性能。在消融实验中，我们引入 HD-SE 注意机制来修正网络。根据 HD-SE 模块的不同位置，本文提出了 3 种方案：一是在编码器和解码器的对称位置添加 HD-SE 模块；二是在编码器中添加 HD-SE 模块；三是在解码器块中添加 HD-SE 模块。结果如图 12 所示。

实验结果表明，在编码器和解码器的对称位置添加 HD-SE 模块，由于对称位置 HD-SE 模块会产

生对消效应，这种方案效果并不理想。在编码器中添加 HD-SE 模块，虽然该方案避免了模块间的抵消效应，但 HD-SE 模块在下采样过程中图像特征缩小而加速了特征信息的丢失。在解码器中添加 HD-SE 模块，该解决方案可以发挥出关注模块的优势，有效提高基材料分解的准确性和质量。

图 13 展示了 RS-Net 经过 700 次迭代后的损失变化情况。

从图中可以观察到，在大约进行了 175 次迭代后，损失值开始趋于稳定。尽管在训练过程中，损失值存在轻微波动，但总体上呈现出持续下降的趋势。此外，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。

2.2 人造砂岩样品实验

为评估所提出的 RS-Net 在图像域的分解效果，实验采用人造砂岩样品，样品由碳酸钙和石英制作而成，CT 实验所用设备为天津三英精密仪器股份有限公司的 NanoVoxel-3000HX 射线三维高分辨成像系统，70kVp 的管电压，在两个能量通道中进行，分别为：[25, 35) keV，[45, 55) keV。射线源到物




图 10 加噪后的 3 个能量段下的图像域的图像

Fig.10 Images in the image domain under three energy levels after adding noise




图 11 加噪后的 3 个能量段下的图像域分解的图像

Fig.11 Decomposed images in the image domain under three energy levels after adding noise




图 12 消融实验结果图

Fig.12 Results of ablation experiment




图 13 训练损失函数

Fig.13 Training loss function

体的距离为 14.6mm, 射线源到探测器的距离为 648.9mm。

模型假设孔隙、碳酸钙和二氧化硅 3 种组分在人造砂岩样品的 CT 体元中以不同体积分数存在, 并且人造砂岩中每一体元对 X 射线的吸收与该体

元中孔隙、碳酸钙和二氧化硅对 X 射线吸收之和相等^[24]。选取第 200 ~ 349 层共 150 张 CT 切片训练网络, 选取第 400 ~ 419 层共 20 张 CT 切片测试网络。图 14 展示了不同能量段下训练数据样本示例。图 15 展示了不同方法的分解结果。

实验中, 只分解 CaCO_3 和 SiO_2 , 空白部分作为孔隙。比较传统 U-Net, 改进 Incept-Net 和 RS-Net 的分解精度不同方法的分解结果彩色表示如图 15 所示。

图 15 第 1 列为实际的 CaCO_3 、 SiO_2 , 第 2 列和第 3 列分别为传统 U-Net 方法和 Incept-Net 方法分解结果, 实验表明在 CaCO_3 、 SiO_2 上分解结果都不准确, 在 Incept-Net 方法融合图像中可以很明显看到有重合部分。第 4 列为采用提出的 RS-Net 网络结合交叉熵损失函数的分解结果, 在边缘部分分解精度不高。第 5 列为采用提出的 RS-Net 网络结




图 14 不同能量段下训练数据样本示例

Fig.14 Examples of training data samples under different energy segments

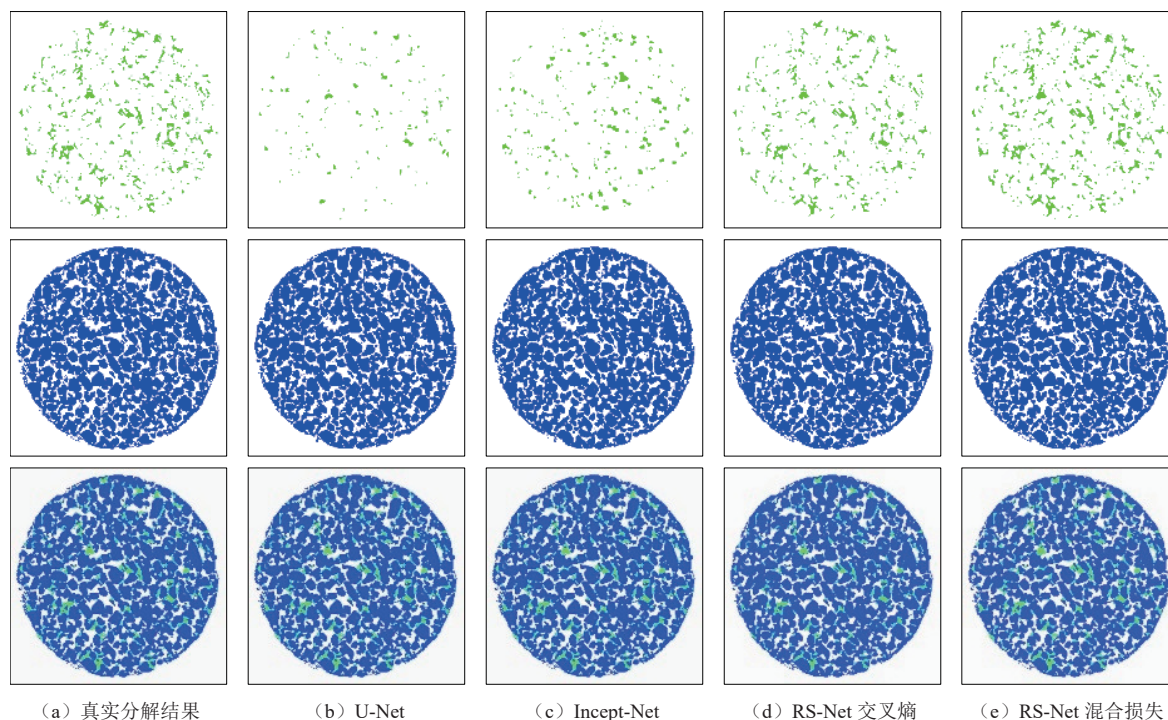


图 15 人造砂岩样品实验结果。从上到下分别为 CaCO_3 、 SiO_2 、融合后的图像

Fig.15 Experimental results of artificial sandstone samples. From top to bottom: CaCO_3 , SiO_2 , and pores

合混合损失函数的分解结果分解精度，从整体上看，效果更好，边缘和内部信息更加清晰完整，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 6 所示。

表 6 不同方法分解效果的定量分析结果
Table 6 Quantitative analysis results of decomposition effect of different methods

材料	方法	U-Net	Incept-Net	RS-Net 交叉熵损失	RS-Net 混合损失
CaCO_3	SSIM	0.4979	0.5859	0.8216	0.9590
	PSNR	30.8033	32.2043	33.4598	33.9354
SiO_2	SSIM	0.9073	0.8653	0.9638	0.9790
	PSNR	31.9615	31.1594	32.7502	33.2538

表 6 展示了使用不同方法进行图像分解后的定量分析结果，比较 U-Net 网络、Incept-Net 网络、RS-Net 网络结合交叉熵损失函数和 RS-Net 网络结合混合损失函数的性能，结果显示，U-Net 网络和 Incept-Net 网络在分解内部结构较复杂的人造砂岩时，SSIM 和 PSNR 值都偏低，RS-Net 结合交叉熵损失函数分解精度在一定程度上有提高，但是整体效果没有 RS-Net 结合混合损失的效果好，在分解结构较复杂的人造砂岩时， SiO_2 的 SSIM 值也可达 0.979。

3 结论

本文提出了一种基于卷积神经网络的深度学习策略 (RS-Net)，用于解决在材料分解算法中，材

料分解精度不高问题。该方法采用全局卷积块和边界细化块来实现全局卷积。在解码器部分增加 HD-SE 模块，对每个高度维度的同一位置赋予不同的权重，提取不同高度维度的特征信息。对比了 U-Net、Incept-Net 网络、RS-Net 网络结合交叉熵损失函数和 RS-Net 网络结合混合损失函数的物质分解效果，结果表明，本文提出的 RS-Net 算法在 SSIM 值和 PSNR 值上均表现出更好的性能，能有效抑制噪声。但是，对于内部结构较为复杂的材料，分解精度还有待提升，本文后续会针对该问题做进一步研究。

综上所述，RS-Net 算法在提高材料分解精度方面具有很大的潜力，可为相关研究和应用提供有力支持。

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. DOI:10.1088/0031-9155/21/5/002.
- [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. DOI:10.1109/TMI.2020.3031617.
- [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. DOI:10.1088/1361-6560/ac0afd.
- [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. DOI:10.1088/1361-6560/ab196d.
- [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. DOI:10.1088/0031-9155/61/10/3784.
- [6] LEHMANN L A, ALVAREZ R E, MACOVSKI A, et al. Generalized image combinations in dual kVP digital radiography[J]. *Medical Physics*, 1981, 8(5): 659-667. DOI:10.1118/1.595025.
- [7] LI Z, LENG S, YU L, et al. Image-based material decomposition with a general volume constraint for photon-counting CT[A]. *Proceedings of SPIE the International Society for Optical Engineering*, 2015, 94120T.
- [8] 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. DOI:10.1109/42.896783.
- [9] HEISMANN B J, LEPPERT J, STIERSTORFER K. Density and atomic number measurements with spectral X-ray attenuation method[J]. *Journal of Applied Physics*, 2003, 94(3): 2073-2079. DOI:10.1063/1.1586963.
- [10] SCHLOMKA J P, ROESSL E, DORSCHIED R, et al. Experimental feasibility of multi-energy photon-counting K-edge imaging in pre-clinical computed tomography[J]. *Physics in Medicine and Biology*, 2008, 53(15): 4031-4047. DOI:10.1088/0031-9155/53/15/002.
- [11] CARMÍ R, NAVEH G, ALTMAN A. Material separation with dual-layer CT[A]. *IEEE Nuclear Science Symposium Conference Record*, 2005, 1876-1878. DOI:10.1109/NSSMIC.2005.1596697.
- [12] WANG G. A perspective on deep imaging[J]. *IEEE Access*, 2016, 4: 8914-8924. DOI:10.1109/ACCESS.2016.2624938.
- [13] GONG H, TAO S, RAJENDRAN K, et al. Deep-learning-based direct inversion for material decomposition[J]. *Medical Physics*, 2020, 47(12): 6294-6309. DOI:10.1002/mp.14523.
- [14] 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. DOI:10.3233/XST-190500.
- [15] 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 on Computational Imaging*, 2024, 10: 677-689. DOI:10.1109/TCI.2024.3394772.
- [16] 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. DOI:10.15953/j.1004-4140.2022.31.01.05. WANG C X, CHEN P, PAN J X, et al. Research on material decomposition of dual-energy CT images based on iterative residual network[J]. *CT Theory and Applications*, 2022, 31(1): 47-54. DOI:10.15953/j.1004-4140.2022.31.01.05. (in Chinese).
- [17] ZIMMERMAN K C, SCHMIDT T G. Experimental comparison of empirical material decomposition methods for spectral CT[J]. *Physics in Medicine and Biology*, 2015, 60(8): 3175-3191. DOI:10.1088/0031-9155/60/8/3175.
- [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. DOI:10.1088/1361-6560/ac7d34.
- [19] HU J, SHEN L, SAMUEL A, et al. Squeeze-and-excitation networks[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2020, 42(8): 2011-2023.
- [20] WANG Q L, WU B G, ZHU P F, et al. ECA-Net: Efficient channel attention for deep convolutional neural networks[C]// 2020 IEEE Transaction on Pattern Analysis and Machine Intelligence. 2020: 11531-11539. DOI:10.1109/TPAMI.2019.2913372.
- [21] WOO S, PARK J, LEE J Y, et al. CBAM: Convolutional block attention module[C]//Lecture Notes in Computer Science, 2018: 3-19. DOI: 10.1007/978-3-030-01234-2_1.
- [22] 吕振虎, 许新征, 张芳艳. 基于挤压激励的轻量化注意力机制模块[J]. *计算机应用*, 2022, 42(8): 2353-2360. DOI:10.11772/j.issn.1001-9081.2021061037. LV Z H, XU X Z, ZHANG F Y. Lightweight attention mechanism module based on squeeze incentive[J]. *Computer Applications*, 2022, 42(8): 2353-2360. DOI:10.11772/j.issn.1001-9081.2021061037. (in Chinese).
- [23] 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. DOI: 10.1109/ICASSP.2018.8461664.
- [24] 王晋麻, 王海鹏, 刘锐, 等. 人造砂岩样品多尺度微观结构表征和流体流动模拟[J]. *山西大学学报 (自然科学版)*, 2023, 46(6): 1378-1385. DOI:10.13451/j.sxu.ns.2023030. WANG J X, WANG H P, LIU R, et al. Multi-scale microstructure characterization and fluid flow simulation of artificial sandstone samples[J]. *Journal of Shanxi University (Natural Science Edition)*, 2023, 46(6): 1378-1385. DOI:10.13451/j.sxu.ns.2023030. (in Chinese).