



天津科技大学学报

Journal of Tianjin University of Science & Technology

ISSN 1672-6510, CN 12-1355/N

《天津科技大学学报》网络首发论文

题目：融合大窗口 Mamba 块的双 U 形网络电阻抗层析成像重建算法
作者：赵航宇，苏静，李佳
DOI：10.13364/j.issn.1672-6510.20250102
网络首发日期：2026-01-30
引用格式：赵航宇，苏静，李佳. 融合大窗口 Mamba 块的双 U 形网络电阻抗层析成像重建算法[J/OL]. 天津科技大学学报.
<https://doi.org/10.13364/j.issn.1672-6510.20250102>



网络首发：在编辑部工作流程中，稿件从录用到出版要经历录用定稿、排版定稿、整期汇编定稿等阶段。录用定稿指内容已经确定，且通过同行评议、主编终审同意刊用的稿件。排版定稿指录用定稿按照期刊特定版式（包括网络呈现版式）排版后的稿件，可暂不确定出版年、卷、期和页码。整期汇编定稿指出版年、卷、期、页码均已确定的印刷或数字出版的整期汇编稿件。录用定稿网络首发稿件内容必须符合《出版管理条例》和《期刊出版管理规定》的有关规定；学术研究成果具有创新性、科学性和先进性，符合编辑部对刊文的录用要求，不存在学术不端行为及其他侵权行为；稿件内容应基本符合国家有关书刊编辑、出版的技术标准，正确使用和统一规范语言文字、符号、数字、外文字母、法定计量单位及地图标注等。为确保录用定稿网络首发的严肃性，录用定稿一经发布，不得修改论文题目、作者、机构名称和学术内容，只可基于编辑规范进行少量文字的修改。

出版确认：纸质期刊编辑部通过与《中国学术期刊（光盘版）》电子杂志社有限公司签约，在《中国学术期刊（网络版）》出版传播平台上创办与纸质期刊内容一致的网络版，以单篇或整期出版形式，在印刷出版之前刊发论文的录用定稿、排版定稿、整期汇编定稿。因为《中国学术期刊（网络版）》是国家新闻出版广电总局批准的网络连续型出版物（ISSN 2096-4188，CN 11-6037/Z），所以签约期刊的网络版上网络首发论文视为正式出版。



DOI:10.13364/j.issn.1672-6510.20250102

融合大窗口 Mamba 块的双 U 形网络电阻抗层析成像重建算法

赵航宇¹, 苏静¹, 李佳^{1,2,3}

(1. 天津科技大学人工智能学院, 天津 300457; 2. 先进计算与关键软件海河实验室, 天津 300450;
3. 南开大学软件学院, 天津 300457)

摘要: 电阻抗层析成像是一种快速、无损的检测技术, 但其逆问题的非线性和病态性严重影响了成像质量。为提高重建图像的精度, 本文提出了一种融合大窗口 Mamba 块的双 U 形网络模型。首先, 通过共轭梯度算法由边界电压值得到电导率分布, 获得重建图像的初值; 然后, 使用融合大窗口 Mamba 块的双 U 形网络模型对重建图像进行后处理, 通过并行计算策略对每个 Mamba 块的特征通道进行处理, 以降低模型的参数数量。仿真实验和真实实验结果表明, 本文方法有效降低了重建图像的伪影, 能获得更接近真实分布的重建图像。

关键词: 电阻抗层析成像; 双 U 形网络; 图像重建算法; 视觉状态空间模型

中图分类号: TP391 文献标志码: A

Dual U-Net with Large-Window Mamba for Electrical Impedance Tomography Reconstruction

ZHAO Hangyu¹, SU Jing¹, LI Jia^{1,2,3}

(1.College of Artificial Intelligence, Tianjin University of Science and Technology, Tianjin 300457, China; 2. Haihe Lab of ITAI, Tianjin, 300450 China; 3.College of Software, Nankai University, Tianjin 300457,China)

Abstract: Electrical Impedance Tomography is a rapid and non-destructive detection technique, but the nonlinearity and ill-posedness of its inverse problem significantly degrade imaging quality. To improve the accuracy of reconstructed images, this paper proposes a dual U-shaped network model incorporating large-window Mamba blocks. First, the initial reconstructed image is obtained by deriving the conductivity distribution from boundary voltage values using the conjugate gradient algorithm. Then, the dual U-shaped network model with large-window Mamba blocks is employed for post-processing the reconstructed image, while a parallel computation strategy processes feature channels in each Mamba block to reduce the model's parameter size. Simulation and experimental results demonstrate that the proposed method effectively suppresses artifacts in reconstructed images and yields reconstructions that more closely approximate the true distribution.

Keywords: electrical impedance tomography; double U-shaped neural network; image reconstruction algorithms; visual state space model

电阻抗层析成像 (electrical impedance tomography, EIT) 是一种快速、无损的成像技术, 凭借价格低、安全简便、无辐射等优点, 在工业、医学等领域中有着广泛应用^[1-3]。在 EIT 图像重建中, 传统的求解算法, 如线性迭代^[4]、非线性逼近法^[5-6]

等算法, 常因电场的软场效应、线性近似等问题, 导致重建图像质量较低, 图像往往包含一定程度的伪影^[7]。

近年来, 深度学习不断发展, 在解决 EIT 成像问题中取得了大量的成功先例, 解决方法一般可分

为两类，第一类是纯粹基于学习的方法，以端到端的方式直接学习 EIT 重建问题中的非线性关系^[8-9]；第二类是将学习算法与基于模型的算法相结合，将深度学习作为一种后处理方式^[10-11]。Adler 等^[12]应用人工神经网络对 EIT 图像进行重构，证明了“智能”方法的速度高于线性背投影（LBP）算法。Li 等^[13]提出了由堆栈自编码器和逻辑回归层组成的深度神经网络，用于 EIT 重建，成像质量明显高于常用的传统重建方法。

U-Net 作为深度学习领域的重要模型架构，广泛应用于医学图像的后处理过程中^[14-15]。在电容层析成像领域，Yang 等^[16]采用全连接神经网络架构实现无监督的初始图像重建，并引入 U-Net 网络对重建结果进行后处理，有效提升了 ECT 图像的空间分辨率。也有研究^[8]对经典的 33 层 U-Net 框架进行改进，通过优化网络结构和训练策略，在一定程度上缓解了传统深度重建网络训练难度大、收敛速度慢等问题。Ye 等^[17]使用多通道连接方式的 U²-Net 重建 ET 图像，通过引入新的特征拼接运算有效地降低了深度网络的过拟合现象。Antholzer 等^[18]将 D-bar 算法与 U-Net 相结合，显著提高了图像质量。然而，由于 U-Net 本质上基于 CNN 构建，在处理远距离依赖关系方面存在一定的局限性，在一定程度上会导致目标边界模糊、电导率估算偏差，并且边界伪影还会扭曲目标形态与位置，这些局限性使其重建过程进一步放大了成像技术的伪影问题。因此，需要针对性改进 U-Net，以提升重建精度。

基于以上问题，本研究将视觉状态空间（visual state space, VSS）模块^[19]引入到 EIT 图像重建当中，提出了一种融合大窗口 Mamba 模块的双 U 形网络模型。首先，通过共轭梯度（conjugate gradient, CG）算法进行图像重建，获得重建图像的初始分布；然后，再使用融合大窗口级 Mamba 块的双 U 形网络对含有大量伪影的初始分布进行后处理，以去掉伪影提高图像质量。此外，为提高 EIT 成像速度，本研究还提出了一种适用于 Mamba 块的分割并行计算策略，以降低模型参数量。

1 算法原理

1.1 U²-Net 网络结构

双 U 形网络是一种改进的 U 形结构深度学习模型，通过串联 2 个 U-Net 架构增强特征提取能力，优势在于能更精细地捕获局部细节与全局上下文，提升小目标分割精度。

本文网络模型包括 Patch 嵌入层、编码器、解码器、最终投影层、残差跳跃连接各 1 个。整体上是 2 个 U 型网络构成的特征空间编码模块和图像重建解码模块进行图像中的边界特征学习，如图 1 所示。

U 型编码器（U-Encoder）如图 1 中 N1—N8 层所示，作用是对输入图像的空间分布特征提取，本模型共设置 8 个路径，每个路径的具体描述为：N1—N3 为编码器的压缩路径，在每个编码器的末尾应用 PATCH 合并操作，以减少输入特征的高度和宽度，同时增加通道数；N4—N5 为瓶颈块，不改变特征的通道数和分辨率，2 个连续的瓶颈块在不增加过多计算开销的情况下，在一定程度上提升网络对图像深层特征的捕捉和提取能力；N6—N8 为编码器的扩展路径，在每个编码器的末尾应用 PATCH 扩展操作，以增加输入特征的高度和宽度，同时减少通道数，经过扩展路径后，U-Encoder 的输出为与其输入特征具有相同尺寸大小的高维抽象特征映射。

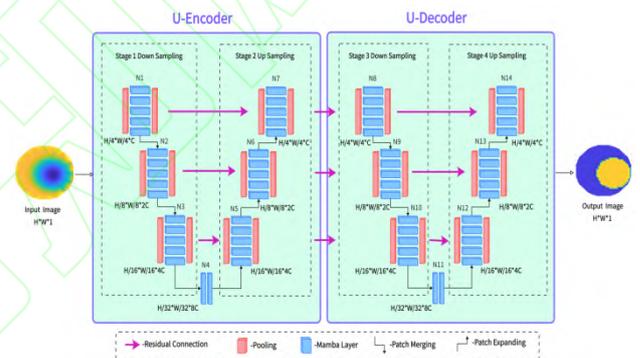


图 1 本文网络模型结构

Fig. 1 Network structure proposed in this paper

U 型解码器（U-Decoder）同样设置 8 个路径，如图 1 中的 N9—N18 层所示，其作用是对 U-Encoder 模块的每一个特征进行边界特征的提取并重构。与 U-Encoder 模块的拓扑结构相似，U-Decoder 负责逐步恢复特征图分辨率，融合来自编码器的信息，最终重构出目标图像。

1.2 大窗口级 Mamba

Mamba 是一种基于视觉状态空间模块（visual state space, VSS）的序列建模方法^[20]。Mamba 具有高效处理视觉任务中的序列建模能力，与 CNN 相比，其具有优秀的长距离建模能力，与 Transformer 相比，其保持了线性的计算复杂度，其结构和工作原理如图 2 所示。视觉状态空间模块中的 SS2D 如图 3 所示，由 3 个部分组成：扫描扩展操作、S6 模块和扫描合并操作，通过这 3 个过程将特称图展开为序列完成对特征的重构。

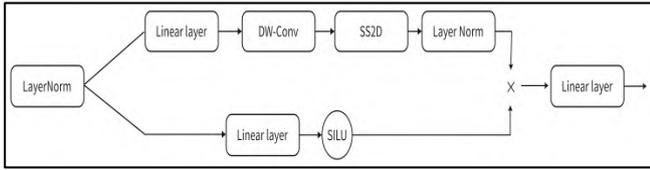


图 2 视觉状态空间模块结构图

Fig. 2 Core module of VSS

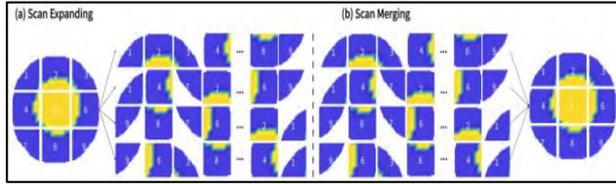


图 3 SS2D 扫描扩展合并工作图

Fig. 3 Core module of SS2D

在 EIT 图像重建问题中, 为了构造重建图像像素的空间分布特征, 往往将测量场域划分为 $N \times N$ 的逆问题网格, 每一个网格相当于一个像素, 本文采用的是 32×32 的网格。以往使用 CNN 进行局部像素级建模和 Transformer 进行远程 patch 依赖建模的方法, 无法设置较大规模的窗口。

为了解决上述问题, 本实验将 Mamba 模块融合到双 U 形网络中, 基于纯 VSS 架构, 在 U-Net 网络的编码器和解码器中嵌入 SS2D 模块, 将 U-Net 的 2D 特征图按特定维度 (如 $H \times W$ 展开为序列长度) 转换为 Mamba 兼容的序列格式, 经 Mamba 处理后再重构为空间特征图, 完成“空间→序列→空间”的形态闭环。在多尺度交互机制中, 编码器各层 Mamba 块按尺度递进处理特征, 浅层 Mamba 捕捉短距离局部关联, 深层 Mamba 建模大范围全局依赖, 形成多尺度特征金字塔, 最后解码器通过上采样与跳跃连接, 将不同尺度的 Mamba 特征融合。

为了针对大像素级别的特征尺度学习, 本文设计了大窗口捕获块 (large windows mamba, LWM) 将每一个编码器解码器的特征映射分割为多个大的子窗口, 在每个子窗口上执行 Mamba 操作。受益于线性复杂性的 Mamba, 其较低的复杂度允许设置更大的窗口, 以获得更大的接受域, 这将提高局部建模的效率, 其工作流程图如图 4 所示。

大窗口捕获块将整个特征图平均划分为互不重叠的 2D 子窗口, 对于给定的 $H \times W$ 分辨率的输入, 将特征图划分为 $m \times n$ 的子窗口, 共得到 $HW/(mn)$ 个子窗口, 当这些子窗口被送入 Mamba 层时, 局部相邻像素会连续输入 SSM, 因此可以更好的建模局部领域像素之间的关系, 使模型能够获得更多的局部像素细节。最后, 先后通过 2 个大小为 $m \times n$ 的池化

层完成不同子窗口之间的远程依赖关系建模, 该过程可以表示为下述公式。

$$W_1 = \text{Pooling}(F_1') \quad (1)$$

$$W_1' = \text{Mamba}(W_1) \quad (2)$$

$$F_1'' = \text{UnPooling}(W_1') \quad (3)$$

其中: Pooling 和 Unpooling 分别表示池化层和非池化层, Mamba 表示 Mamba 块处理。

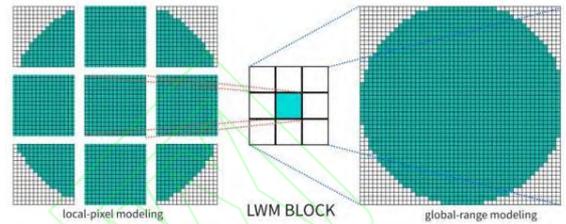


图 4 LWM BLOCK 流程图

Fig. 4 Moder flow chart of LWM BLOCK

1.3 分割并行计算策略

分割并行计算将总任务分解为多个独立或半独立子任务, 然后在对应的多个处理单元上同时执行的策略。Mamba 块中对参数量影响最大的模块是 SS2D。在 SS2D 中, 输入通道的数量、内部卷积核的大小、投影扩张倍数以及投影矩阵的秩都影响着参数的数量。其中, 输入通道数量对参数量影响最为显著, 具体如下。

$$d_{inner} = E * d_{model} \quad (4)$$

$$I_{pro} = 2 * d_{inner} * d_{model} \quad (5)$$

$$O_{pro} = d_{inner} * d_{model} \quad (6)$$

其中: E 为投影扩张系数, d_{inner} 为投影通道数量, d_{model} 为输入通道数量, I_{pro} 为输入投影层参数, O_{pro} 为输出投影层参数。式中, 若设定投影扩张系数 E 为 2 时, 当通道数量减少为原来的 1/4 时, 最终的投影层参数量将降低 75%, 因此在网络结构的每一个编码器和解码器层中, 使用了分割并行计算策略, 减少通道数量以降低模型的参数量。

对于每一个 LWM 块, 输入特征首先通过 LayerNorm 层进行归一化, 然后按通道将其分割成 4 个部分, 每部分的通道数为原始通道数的四分之一。这 4 个部分分别通过 LWM 块进行处理, 然后通过拼接合并通道, 最后再通过残差连接和调整因子进行优化并返回原始通道数的特征, 其结构如图 5 所示。

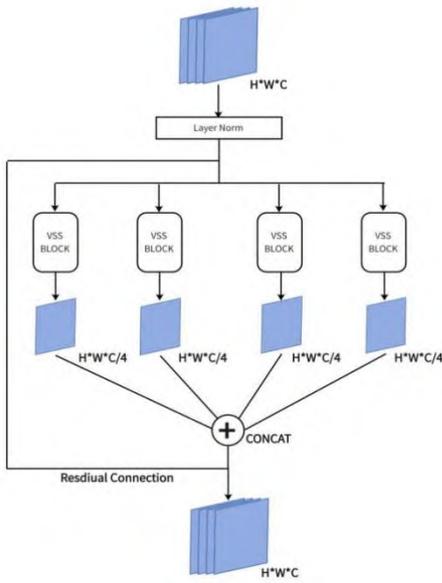


图 5. 并行处理策略设计图

Fig. 5 Moder flow chart of LWM BLOCK

分割并行计算在保持处理通道数不变的情况下，显著降低了模型的参数数量和计算负载，即

$$Y_i^{C/4} = \text{Seg}[\ln(X^C)], \quad i = 1, 2, 3, 4 \quad (7)$$

式中：Seg 表示分割操作，LN 为归一化层，Cat 为拼接操作， θ 为残差连接的调整系数。

1.4 其他方法介绍

为对比本文方法的成像效果，本文还选用了 NN-Unet, Swin-Unet 和 VM-Unet 网络作为对比成像方法。其中，NN-Unet 基于 U-Net 架构，在多种医学影像任务中实现高性能，成为医学图像分析的基准模型之一；Swin-Unet 是基于 Transformer 的图像分割网络，在图像分割任务中表现优异，具有高精度图像重建性能；VM-Unet 结合了 Vision Mamba 和 U-Net，在减少计算量的同时提升全局上下文感知能力，在图像重建任务中兼顾效率和精度。

2 仿真实验

2.1 数据集建模

仿真模型通过多物理场仿真软件 COMSOL Multiphysics 和 Matalab 获得，创建 16 电极 EIT 仿真模型，并采用相邻电极激励方式，每个模型可获得 208 个电压值。

在仿真模型构建过程中，背景介质为水，电导率设置为 0.04S/m，内含物的电导率范围设置为 0.05~0.1S/m，设计了包含 1~5 个随机分布圆形内含物的多种场域模型，将初始分布作为样本数据集的

标签。通过传统共轭梯度算法对逆问题进行求解，获得的重建图像作为初始样本集。最终构建的仿真数据库包含 50000 个训练样本，按 4 : 1 的比例划分为训练集和测试集，其中训练集确保不同内含物数量的样本分布均衡。测试集用于评估训练模型的鲁棒性和泛化性能。图 6 展示了部分已构建的数据集样本。

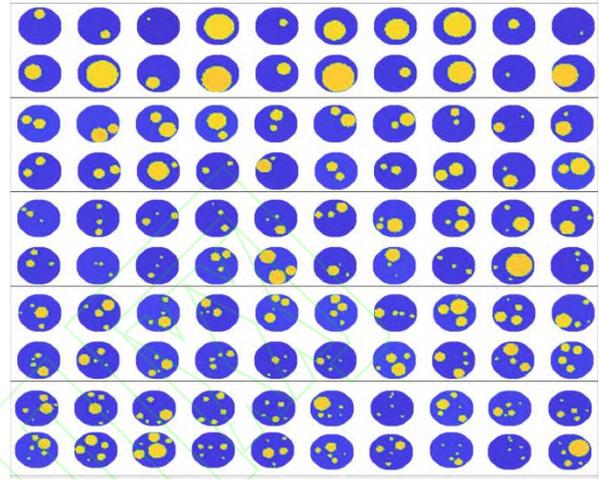


图 6. 部分数据集展示

Fig. 6 Partial data set of image reconstruction

2.2 评价指标

为了直观说明本文模型的电阻抗重建能力，使用形变程度 (DT) 和结构相似系数 (SSIM) 指标对模型进行评价。其中 DT 描述了重建图像中的介质与真实电导率图像中的介质之间的形状差异程度。SSIM 用于衡量重建结果和实际像素之间对比度和结构之间的相似程度。

$$DT = \frac{\sum_{x,y} |x_{\text{seg}}(x,y) - x_{\text{gro}}(x,y)|}{S_{\Omega}} \quad (8)$$

其中： x_{seg} 和 x_{gro} 分别表示分割图像的电导率分布和真实图像的电导率分布， S_{Ω} 表示场域的整体面积。

$$SSIM = \frac{(2\mu_{\sigma}\mu_{\omega} + C_1)(2std(\sigma, \omega) + C_2)}{(\mu_{\sigma}^2 + \mu_{\omega}^2 + C_1)(std(\sigma)^2 + std(\omega)^2 + C_2)} \quad (9)$$

其中： μ_{σ} 和 μ_{ω} 分别表示重建像素 σ 和实际像素 μ 的均值，std 表示变量的标准差。

2.3 仿真环境配置

模型实现基于 PyTorch 1.9.0，所有实验均在 NVIDIA GeForce RTX 3060 GPU 上进行。训练批次设置为 2，优化器选用 Adam 优化器，初始学习率为 0.01，权重衰减设置为 3e-5，使用 Binary Cross Entropy Loss 损失函数进行模型训练。最大的训练轮次为 1000，对于每个阶段的矩形窗口大小设置为 40×40。

2.4 仿真实验结果与分析

在表 1 中展示了本文提出模型对各目标的图像重建指标, 针对单目标的图像重建本文网络模型表现出了优异的性能, 形变程度为 0.191, 结构相似系数为 95.94%。并且随着场域内目标增加, 其指标下降速度并不高, 说明即使在多目标重建中, 本文模型也具有优秀的表现。

表 1 本文网络模型的图像重建指标

Tab. 1 Image Reconstruction Metrics of our Network

目标数量	DT	SSIM
单目标	0.191	95.94
双目标	0.204	92.26
三目标	0.209	92.07
四目标	0.215	91.56
五目标	0.217	91.39

将本文模型与经典的电阻抗层析成像网络进行对比训练, 选取其他 3 种网络进行对比实验, 结果如图 7—图 9 所示。

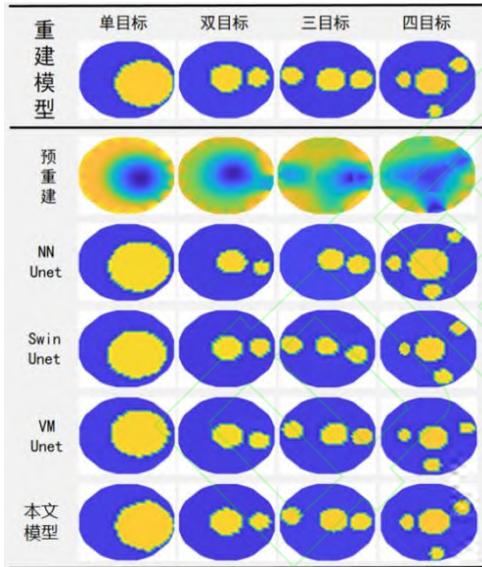


图 7. 仿真结果对比

Fig. 7 Simulation results comparison

直观上看, 对于待测场域中只包含一个目标的分布情况, 4 种模型都表现出了最好的重建性能, 其中本文网络模型效果最佳, DT 在 0.2 以下, SSIM 达到了 95.94%, 说明本文模型可以准确地还原目标位置并且保证了重建图像的边界形状准确率。总体上看, 随着目标的数量增加, 4 种模型的重建指标均出现了一定程度的下降。以 NN-Unet 和 Swin-Unet 下降速度最快, 在五目标图像重建任务中, SSIM 均小于 90%。而本文模型在五目标重建任务中 SSIM 仍保持在了 91.39%, 说明本文模型相对于其他模型

不易受到场域内目标数量的影响。

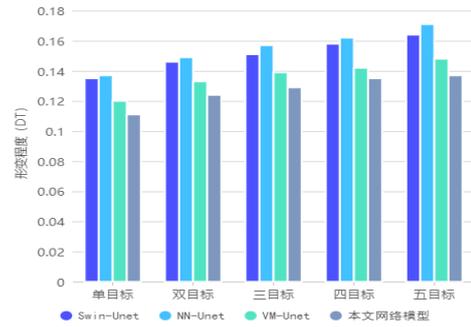


图 8. 本文模型在形变程度上与其他网络的对比

Fig. 8 Comparison of paper net with other models in degree of deformation

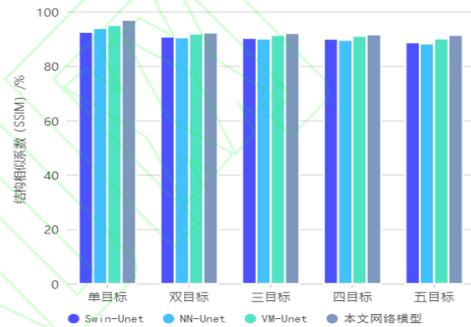


图 9. 本文模型在结构相似系数上与其他网络的对比

Fig. 9 Comparison of paper net with other models in structural similarity

由图 8 和图 9 可知, 本文模型和同样基于视觉 Mamba 的 VM-Unet 在两种指标上均优于其他的 UNet 网络模型。在 DT 指标上, 本文模型相比较与 Swin-Unet 在单目标图像重建中降低了 17.78%, 在五目标图像重建中降低了 16.52%; 在 SSIM 指标上, 本文模型相比较与 Swin-Unet 在单目标图像重建中提升了 2.60%, 在五目标图像重建中提升了 1.92%。性能的提高很大程度上归功于视觉 Mamba 的全局建模能力, 相较于传统神经网络和 transformer, 它可以同时提取多尺度的局部特征并捕获远程依赖关系, 还保持线性计算复杂度。

本文模型相较于基于视觉 Mamba 的 VM-Unet 在两种指标上也得到了一定的提升。在 DT 指标上, 本文模型相比较与 VM-Unet 在单目标图像重建中降低了 7.50%, 在五目标图像重建中降低了 7.43%; 在 SSIM 指标上, 本文模型相比较与 VM-Unet 在单目标图像重建中提升了 0.97%, 在五目标图像重建中提升了 0.77%。该结果说明了针对 EIT 这种大像素级别的特征尺度学习任务提出的大窗口捕获块的有效性, 这种大窗口提取方法可以更好地学习局部像

素特征, 获得更高地重建性能。

2.5 特殊分布的 EIT 实验

在 EIT 重建任务中, 目标物体的分布 (如两目标相邻或目标靠近边缘) 会显著影响成像质量和反演算法的性能。特殊分布下的仿真实验结果如图 10 所示, 小目标的仿真实验结果如图 11 所示。

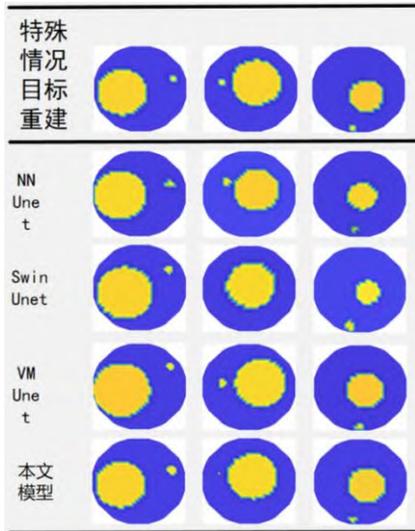


图 10. 特殊分布下的仿真实验结果

Fig. 10 Simulation results under special distribution

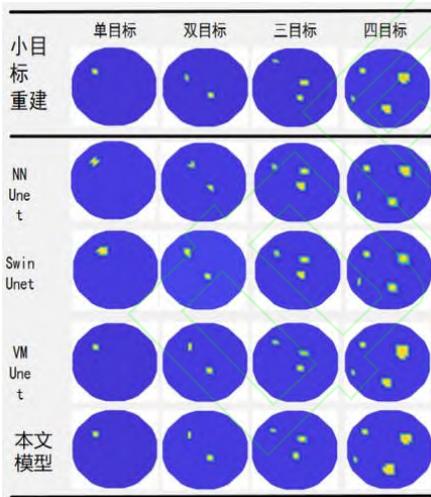


图 11. 小目标的仿真实验结果

Fig. 11 Results of simulation experiments with small targets

由图 10 可知, 针对一个大目标加一个小目标的特殊分布, 几种模型只出现了较小的失真, 说明基于深度学习的方法均可有效地克服模糊效应带来的影响。在针对一个目标在场域边缘另一个目标在场域中心的分布, 本文模型在中心区域成像质量和边缘区域成像质量均优于其他模型, 验证了本文所提模型的鲁棒性。

由图 11 可知, 针对不同个数的小目标图像重建, 4 种模型都取得了不错的效果, 虽然 NN-Unet 和 Swin-Unet 都没有出现目标丢失的情况, 但受限于 Transformer 的像素级建模能力, 其重建结果中一些几何尺寸较小的目标电导率参数结果并不是全部准确, 说明其针对其小目标的图像重建能力较为一般。两种基于视觉 Mamba 的模型相较于前两种模型取得了不错的成像效果。

2.6 消融实验

为了验证本文提出的大窗口 Mamba 块和通道并行处理策略的影响, 进行了消融实验, 结果见表 2。使用大窗口划分策略的 2 个模型的参数量小幅提升, 针对于逆网格特点设置的窗口大小, 使其对目标物体的轮廓特征学习能力更强, 其对应的性能指标均获得了一定的提升。此外, 使用分割并行计算 Mamba 层的 2 个网络在性能方面保持不变甚至提升的前提下, 模型参数量显著下降。最后, 同时使用大窗口 Mamba 块和通道并行处理策略的网络获得了最小的参数量和最佳的性能。

表 2 消融实验结果

Tab. 2 Ablation Study Results

模型	DT	SSIM	Parameters(M)
VM-Unet	0.133	91.87	28.926
LWM-Unet	0.127	92.21	36.457
CVM-Unet	0.133	91.78	1.240
本文模型	0.124	92.26	1.570

窗口维度的设计目的是平衡大像素特征捕获与局部细节保留以提升边界精度, 窗口大小的选择是基于输入特征图的分辨率和逆网格的大小决定的, 为验证所设计的大窗口捕获块在窗口维度大小选择上是否影响成像效果, 设计了不同尺寸大小的消融实验结果见表 3。40×40 窗口在大像素特征捕获与局部细节保留间取得最优平衡, 当窗口过大时, 会因感受野过大导致小目标漏检; 窗口过小时, 无法有效建模大像素区域的长程依赖, 成像出现语义断裂。针对电导率分布复杂度的影响, 后续研究将引入动态窗口生成机制, 根据电导率分布复杂度实时调整窗口维度与感受野范围, 避免复杂度带来的负面影响。

表 3 窗口尺寸消融实验结果

Tab. 3 Window Size Ablation Study Results

窗口大小	DT	SSIM
80×80	0.126	92.19
60×60	0.127	92.21

40×40	0.124	92.26
20×20	0.128	91.89
无	0.133	91.87

3 物理模型实验

为验证模型在实际物理系统中的性能,进行了水槽实验,实验采用自主开发的 16 电极电阻抗成像系统进行物理模型实验验证。该系统包括一台 PC 机、一套数据采集系统以及一个装有电极传感器阵列的圆桶。该实验装置成像速度约为 40 帧/s,平均信噪比约为 70dB。在实验过程中,激励电流的幅值设置为 5mA,频率设置为 100kHz;圆桶的内径约为 32cm,桶中盐水的电导率约为 0.01S/m;有机玻璃棒的直径约为 3.5 cm,电导率趋近于 0S/m。

实验使用不同个数的圆形无机玻璃棒作为待测区域内的介质,模拟实际应用中测量区域内的不同介质分布,其部分实验结果如图 12 所示。使用本文网络模型所获得的重建结果可以清晰地表征场域内介质的位置信息和形状特征,随着介质数量的增加,其他 3 种方法的性能明显下降,而本文网络模型仍能保持较为清晰的形状识别,这为其在复杂场景中的应用提供了技术保障。

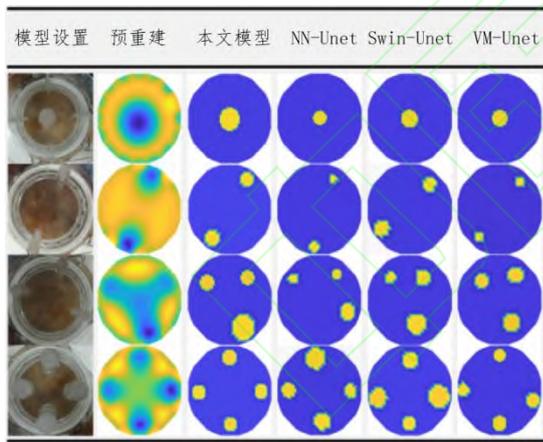


图 12. 与其他模型的实验结果对比

Fig. 12 Comparison of paper net with other models in degree of deformation

表 4 和表 5 分别列出了 4 种模型对应的重建图像的形变程度 DT 和结构相似系数 SSIM, 4 种模型在单目标重建任务中均获得了较高的指标。在形变程度中,选用的对比网络相比本文网络模型差值分别为 0.06、0.044 和 0.02。在结构相似系数中,本文模型平均结构相似系数为 89.99%,单目标和双目标重建任务的结构相似系数仍保持在 90% 以上,而 NN-Unet 和 Swin-Unet 在单目标的重建任务中结构

相似系数已不足 90%。这与在仿真实验章节中分析得到的结论一致,说明相较于传统重建方法和其他深度学习模型,本文基于大窗口 Mamba 块的双 U 形网络可更好地重构出场域内介质的位置信息和形状特征。

表 4 实验重建图像形变程度 DT

Tab. 4 DT of Experimentally Reconstructed Images

模型	单目标	双目标	三目标	四目标
Swin-Unet	0.236	0.276	0.324	0.355
VM-Unet	0.212	0.248	0.288	0.324
本文模型	0.192	0.228	0.248	0.292

表 5 实验重建图像结构相似系数 SSIM

Tab. 5 SSIM of Experimentally Reconstructed Images

模型	单目标	双目标	三目标	四目标
NN-Unet	89.41	86.38	85.24	83.27
Swin-Unet	89.77	87.67	86.37	85.48
VM-Unet	91.59	90.12	89.16	87.33
本文模型	92.39	90.16	89.54	87.86

综上所述,这种优异的成像性能验证了“预重建—后处理”两阶段方法的有效性:预重建阶段通过深度特征提取初步定位介质分布,后处理阶段则利用上下文信息优化边界细节,二者协同工作显著提升了重建精度。

4 结论

本研究提出了一种基于大窗口 Mamba 块和双 U 形网络的电阻抗层析成像方法。该方法具有以下两方面显著优势:一方面,通过基于大窗口的 Mamba 块获得更大的有效感受野进而加强模型的局部建模能力;另一方面,使用并行计算策略分割输入特征,再使其输入到 LWM 块中,在减少模型参数数量的同时,能够有效地保持模型性能。最后,在多个仿真实验和真实水槽实验中验证本文提出模型的有效性,实验结果证明了本文模型在 EIT 图像重建领域的优越性能和应用潜力。

未来工作中可考虑在训练过程中引入目标分布的先验知识作为约束条件,或者设计多任务学习框架来同时优化图像质量和物理一致性。此外在数据集的构建上,可以增加更多不同几何形状或电导率分布复杂的目标物体,以提升模型对复杂情况的适应能力,使仿真环境更接近实际应用场景。

参考文献:

- [1] 王化祥. 电学层析成像技术[J]. 自动化仪表, 2017(5): 1-6.
- [2] 邹瞿, 超金, 锦江, 等. 生物电阻抗技术在皮肤创伤研究中的应用进展[J]. 传感器与微系统, 2021, 40(11): 1-3.
- [3] SHI Y, YANG Z, XIE F, et al. The research progress of electrical impedance tomography for lung monitoring[J]. *Frontiers in bioengineering and biotechnology*, 2021, 9: 726652.
- [4] 左从磊, 李静. 基于混合全变差正则化算法的电阻抗成像技术研究[J]. 传感器与微系统, 2021, 40(11): 40-43.
- [5] BORSIC A, ADLER A. A primal-dual interior-point framework for using the L1 or L2 norm on the data and regularization terms of inverse problems[J]. *Inverse problems*, 2012, 28(9): 095011.
- [6] KNUDSEN K, LASSAS M, MUELLER J L, et al. D-bar method for electrical impedance tomography with discontinuous conductivities[J]. *SIAM Journal on applied mathematics*, 2007, 67(3): 893-913.
- [7] WANG H, CAO Z. An investigation on the nonlinearity of 'soft' field in electrical impedance tomography system based on statistical methods[C]//IEEE. *Proceedings of IEEE Instrumentation and Measurement Technology Conference*. Piscataway: IEEE, 2005: 1392-1396.
- [8] LI F, TAN C, DONG F. Electrical resistance tomography image reconstruction with densely connected convolutional neural network[J]. *IEEE Transactions on instrumentation and measurement*, 2020, 70: 1-11.
- [9] CHEN Z, YANG Y, JIA J, et al. Deep learning based cell imaging with electrical impedance tomography[C]//IEEE. *2020 IEEE International Instrumentation and Measurement Technology Conference (I2MTC)*. Piscataway: IEEE, 2020: 1-6.
- [10] CAPPS M, MUELLER J L. Reconstruction of organ boundaries with deep learning in the D-Bar method for electrical impedance tomography[J]. *IEEE Transactions on biomedical engineering*, 2020, 68(3): 826-833.
- [11] SMYL D, TALLMAN T N, LIU D, et al. An efficient quasi-newton method for nonlinear inverse problems via learned singular values[J]. *IEEE Signal processing letters*, 2021, 28: 748-752.
- [12] ADLER A, GUARDO R. A neural network image reconstruction technique for electrical impedance tomography[J]. *IEEE Transactions on medical imaging*, 1994, 13(4): 594-600.
- [13] LI X, ZHOU Y, WANG J, et al. A novel deep neural network method for electrical impedance tomography[J]. *Transactions of the institute of measurement and control*, 2019, 41(14): 4035-4049.
- [14] 付荣, 张新宇, 王子辰, 等. 基于 V-ResNet 的电阻抗层析成像方法[J]. 仪器仪表学报, 2021, 42(9): 279-287.
- [15] 叶明, 李晓丞, 刘凯, 等. 一种基于 U²Net 模型的电阻抗成像方法[J]. 仪器仪表学报, 2021, 42(2): 235-243.
- [16] YANG X, ZHAO C, CHEN B, et al. Big data driven U-Net based electrical capacitance image reconstruction algorithm[C]//IEEE. *2019 IEEE International Conference on Imaging Systems and Techniques (IST)*. Piscataway: IEEE, 2019: 1-6.
- [17] YE M, ZHOU T, LI, et al. U²Net for 3D electrical impedance tomography with combined electrodes[J]. *IEEE Sensors journal*, 2022, 23(5): 4327-4335.
- [18] ANTHOLZER S, HAL TMEIER M, SCHWAB J. Deep learning for photoacoustic tomography from sparse data[J]. *Inverse problems in science and engineering*, 2018: 1-19.
- [19] GOEL K, SMITH R, JOHNSON L. State space models for sequence modeling: a structured overview[J]. *Journal of machine learning research*, 2023, 24(1): 1-45.
- [20] GU A, DAO T. Mamba: Linear-time sequence modeling with selective state spaces[EB/OL]. [2025-06-01]. <https://arxiv.org/abs/2312.00752>.