



MADS-Net: 面向乳腺筛查电阻抗断层成像重建的多尺度注意力与动态稀疏掩码融合网络*

俞成涛^{1)**} 王佳卉^{1)**} 胡松佩²⁾ 陈怀瑾^{3)***} 丁力¹⁾ 叶霞¹⁾ 姚佳烽^{4)***}

(¹⁾ 江苏理工学院机械工程学院, 常州 213001; (²⁾ 南京航空航天大学机电学院, 南京 210016;

(³⁾ 华南理工大学未来技术学院, 广州 510641; (⁴⁾ 暨南大学物理与光电工程学院, 广州 510632)

摘要 目的 针对电阻抗断层成像 (electrical impedance tomography, EIT) 在乳腺筛查应用中因逆问题的严重病态性导致的重建精度不足、小目标检测能力弱, 以及现有深度学习方法训练效率低、缺乏物理一致性问题, 提出一种面向乳腺筛查场景的多尺度注意力与动态稀疏掩码融合网络 (multi-scale attention and dynamic sparse mask network, MADS-Net), 以实现高分辨率 EIT 图像重建。**方法** 网络采用“先定位、后重建”策略, 通过动态掩码模块实现计算资源自适应分配, 利用多尺度注意力机制缓解映射过程中的信息丢失, 并嵌入物理约束提升结果合理性。通过系统仿真、琼脂体模与猪肉组织实验验证方法性能, 与高斯-牛顿、卷积神经网络、U-Net、Deep D-Bar 等主流方法开展对比, 以图像相关系数 (image correlation coefficient, ICC)、均方根误差 (root mean square error, RMSE)、峰值信噪比 (peak signal-to-noise ratio, PSNR) 为定量评价指标。**结果** MADS-Net 在全测试场景中性能优于对比方法, 平均 ICC 达 0.9176 ± 0.0488 , RMSE 低至 0.0606 ± 0.0316 , PSNR 达 (23.8939 ± 2.6853) dB; 可在直径 100 mm 的传感场内成功检出 5 mm 小目标, 训练时长缩短 23.5%, 同时具备优异的噪声鲁棒性。**结论** MADS-Net 在仿真、琼脂体模和离体猪肉组织实验中表现出较好的 EIT 重建性能, 为 EIT 技术在乳腺筛查相关场景及其他医学功能成像任务中的进一步研究提供了方法学参考。需要指出的是, 本研究尚未使用真实临床乳腺数据进行验证, 其临床适用性仍需进一步研究。

关键词 电阻抗断层成像, 动态掩码网络, 多尺度注意力机制

中图分类号 R318, Q6-3, TP391.41

DOI: 10.3724/j.pibb.2026.0197

CSTR: 32369.14.pibb.20260197

电阻抗断层成像 (electrical impedance tomography, EIT) 是一种无创、无辐射的功能成像技术^[1]。该技术通过向被测对象边界施加安全的交变电流, 测量对应的边界电压, 进而重建被测对象内部的阻抗分布^[2]。在过去数十年间, EIT 的应用潜力得到了广泛认可, 其应用场景涵盖工业过程监测^[3-5]与临床诊断^[6-8]两大领域, 在两类场景中, 其便携适配性均是核心优势。特别是在乳腺检测领域^[9-10], EIT 凭借无创、无辐射、便携、低成本的特性, 成为传统成像方式的重要补充, 尤其适用于高频次筛查与医疗资源有限的场景。

然而, EIT 逆问题固有的严重病态性^[11], 使得高斯-牛顿法^[12]、Tikhonov 正则化^[13]及其改进算法^[14]等传统算法在成像精度、稳定性与计算效率上均存在显著局限。近年来, 深度学习方法在 EIT

成像领域取得了突破性进展^[15-17]。Tan 等^[16]将基于卷积神经网络 (convolutional neural networks, CNN) 的深度学习方法应用于 EIT 重建, 有效提升了成像质量; Hamilton 等^[18]提出采用 U-Net 对 D-bar 算法的初始重建结果进行精修, 显著提升了图像分辨率, 但其性能仍依赖于传统算法的初始输出; Wu 等^[19]提出了一种灵敏度引导的 EIT 无监督

* 江苏省国际合作项目 (BZ2024036), 江苏省高校自然科学重大项目 (24KJA460003), 江苏省常州市应用基础研究计划 (CJ20241070) 和江苏理工学院研究生实践创新计划项目 (XSJCX25_14) 资助。

** 并列第一作者。

*** 通讯联系人。

陈怀瑾 Tel: 15195871108, E-mail: c1013756286@126.com

姚佳烽 Tel: 17715275835, E-mail: jfyao@jnu.edu.cn

收稿日期: 2026-04-15, 接受日期: 2026-06-24

学习方法, 在无需电导率真实标签的情况下实现了 EIT 图像重建, 提升了模型的泛化能力。

尽管已有研究取得了诸多进展, 主流的基于深度学习的 EIT 方法仍面临诸多实际挑战, 包括训练效率偏低、模型可解释性有限、微小异常区域的分辨能力不足等。其中, 小目标检测能力对于该技术的临床转化尤为关键, 早期检测出小体积钙化灶对降低浸润性癌风险至关重要^[20]。针对上述局限, 本研究提出一种多尺度注意力与动态稀疏掩码融合网络 (multi-scale attention and dynamic sparse mask network, MADS-Net), 旨在实现高质量、高分辨率的 EIT 图像重建。本研究的主要贡献如下:

a. 针对传统方法计算冗余度高、训练效率低、模型泛化能力有限的问题, 基于“先定位-后重建”的两阶段策略, 提出了一种稀疏感知的动态掩码网络。该方法有效降低了计算冗余, 使整体训练时长缩短 23.5%; 并且, 通过在损失函数中嵌入物理先验, 既提升了关键区域的定位精度, 也增强了重建结果的可信度, 在实测实验中表现出一定的跨场景稳定性。

b. 针对低维测量数据到高维电导率分布直接映射过程中信息丢失严重、小目标重建困难的问题, 引入了多尺度注意力机制。该机制有效缓解了映射过程中的信息丢失。在直径 100 mm 的传感器仿真模型中, MADS-Net 显著提升了对 5 mm 高电导率异常目标的重建与分辨能力, 在受控条件下的小目标分辨性能优于各类对比方法。需要强调的是, 该结果主要用于验证模型对小尺寸电导率异常区域的重建能力, 并不直接等同于真实临床乳腺微钙化检出能力。

1 材料与方法

1.1 EIT 数学模型和 MADS-Net 框架

EIT 问题包含正问题与逆问题两部分^[21]。其中, 正问题是指在给定内部电导率分布 σ 与边界激励条件 (本研究采用 16 电极激励) 的前提下, 求解边界测量电压 U , 其控制方程基于麦克斯韦方程组^[22]的准静态近似 (低频交变电流激励下忽略位移电流) 构建:

$$\nabla \cdot (\sigma \nabla \phi) = 0 \quad (1)$$

式中, ∇ 为哈密顿算子, ϕ 为电势分布。由于实际被测对象的几何结构与电导率分布具有复杂性, 通常采用有限元法 (finite element method, FEM) 求解正问题^[23]。

逆问题的目标是通过边界测量电压变化 Δu 反演内部电导率变化 $\Delta \sigma$, 其映射关系可表示为:

$$\Delta \sigma = F(\Delta u) \quad (2)$$

EIT 逆映射的核心挑战在于其严重的病态性^[11], 由此带来了高噪声敏感性、解的非唯一性与固有的非线性问题。为克服上述问题, 本研究提出了新型 MADS-Net 算法, 旨在实现稳定、高分辨率的图像重建。

1.1.1 MADS-Net 网络架构

MADS-Net 的端到端 EIT 图像重建流程如图 1 所示, 通过多尺度注意力机制^[24]实现特征的提取与融合, 生成基础电导率分布预测。动态掩码生成器基于基础预测生成稀疏掩码^[25], 识别重建区域内的关键区域; 同时, 基础预测作为双路径处理模块的输入, 其中轻量化路径处理非关键区域以保持计算效率, 精细化路径处理则专注于关键区域以提升重建精度。两条路径的输出通过动态掩码进行自适应融合, 最终经过细化网络进一步优化, 输出高精度的电导率分布图。网络整体遵循“特征提取-掩码生成-双路径优化-图像细化”的流程, 各模块在功能上相互协同, 结构上紧密衔接, 实现了从边界电压到电导率分布的端到端映射。

1.1.2 特征提取模块

特征提取的完整流程如图 2 所示, 该模块作为模型的特征提取核心, 负责将 16 电极 EIT 系统在相邻激励模式^[26]下采集的 208 个一维边界电压数据转换为初步的二维电导率图像特征。其关键设计在于引入多尺度注意力机制, 旨在从不同尺度捕捉电压信号中的空间依赖关系, 从而增强模型对复杂电导率分布的感知能力。具体实现上, 模块通过多个并行的线性投影层处理输入电压, 将其映射至不同尺度的特征空间, 进而强化对不同尺度下关键电压特征的关注与提取。

具体实现上, 本研究采用 3 个并行尺度分支构成多尺度注意力特征提取模块, 输入为 16 电极相邻激励模式下采集得到的 208 维边界电压向量。每个尺度分支均由独立的线性投影层、可学习位置编码和多头自注意力模块组成, 且不同尺度分支之间不共享参数。各尺度分支均将输入电压向量映射为 512 维特征表示, 并采用 8 个注意力头进行特征相关性建模。随后, 将 3 个尺度分支的输出特征沿通道维度进行拼接, 得到 512×3 维多尺度融合特征, 再通过特征融合层映射回 512 维高级特征, 最终经输出投影层生成 64×64 的初步电导率分布。




Fig. 1 Overall architecture of MADS-Net




Fig. 2 Workflow of the feature extraction module

设输入电压向量为 $U \in \mathbb{R}^{B \times D_u}$, 其中 B 为批次大小, $D_u = 208$ 为电压维度。对于每个尺度 $s_i \in 1, 2, 3$, 特征投影过程可表示为:

$$H_i = \text{LeakyReLU}(UW_i^{\text{proj}}), i = 1, 2, 3 \quad (3)$$

其中, $W_i^{\text{proj}} \in \mathbb{R}^{D_u \times (D_h/3)}$ 为可学习的投影权重矩阵, $D_h = 512 \times 3$ 为隐藏层维度, LeakyReLU 为激活函数 [27]。

为保留序列的位置信息, 模块引入了可学习的位置编码:

$$H_i^{\text{pos}} = H_i + P_i \quad (4)$$

其中, $P_i \in \mathbb{R}^{1 \times 1 \times (D_h/3)}$ 为尺度特定的位置编码参数,

通过训练过程自适应学习空间位置关系。

每个尺度的特征经过独立的多头自注意力机制处理, 以建立不同电压测量点之间的长程依赖关系。对于第 i 个尺度的特征 $H_i^{\text{pos}} \in \mathbb{R}^{B \times 1 \times (D_h/3)}$ 注意力计算过程如下:

首先通过线性变换生成查询 (Query, Q)、键 (Key, K) 和值 (Value, V) 向量:

$$Q_i = H_i^{\text{pos}} W_i^Q, K_i = H_i^{\text{pos}} W_i^K, V_i = H_i^{\text{pos}} W_i^V \quad (5)$$

其中, $W_i^Q, W_i^K, W_i^V \in \mathbb{R}^{(D_h/3) \times (D_h/3)}$ 为可学习的权重矩阵。缩放点积注意力计算为:

$$\text{Attention}(Q_i, K_i, V_i) = \text{softmax}\left(\frac{Q_i K_i^T}{\sqrt{d_k}}\right) V_i \quad (6)$$

其中, $d_k = D_h / (3 \times N_h)$ 为每个注意力头的维度, $N_h = 8$ 为注意力头数量。

各尺度的注意力输出通过通道维度拼接进行融合, 最终通过输出投影层将高级特征映射到图像空间:

$$\hat{\sigma}_0 = \text{Reshape}(H_{\text{output}} W^{\text{out}}) \quad (7)$$

其中, $W^{\text{out}} \in \mathbb{R}^{D_h \times 4096}$ 为输出权重矩阵, $\hat{\sigma}_0 \in \mathbb{R}^{B \times 1 \times 64 \times 64}$ 为初步重建的电导率分布图像。

1.1.3 动态掩码模块

动态稀疏掩码的核心功能是自适应识别重建图像中需要精细化处理的关键区域。该模块以基础预测电导率为输入, 生成 64×64 的动态稀疏掩码, 可基于输入特征自适应区分关键区域与非关键区域, 为后续的双路径处理提供引导。该掩码机制能够实现计算资源的动态分配, 从而提升计算效率。

掩码生成器采用三层全连接网络, 从基础预测电导率中提取高级特征。为生成稀疏度适中的掩码, 模块引入了自适应阈值预测机制。基于提取的高级特征 H_3 , 阈值预测计算为:

$$t = 0.1 + 0.4 \cdot \text{Sigmoid}(H_3 W^t + b) \quad (8)$$

其中, $W^t \in \mathbb{R}^{(D_h/2) \times 1}$ 为阈值预测权重, Sigmoid 是激活函数, b 为偏置项。这种设计确保阈值 t 始终在 $[0.1, 0.5]$ 范围内, 避免因稀疏度过高导致特征丢

失, 同时防止稀疏度过低造成计算资源浪费。

同时, 基础掩码 M_{base} 通过独立的预测网络生成, 最终稀疏掩码通过阈值化操作生成:

$$M_{\text{sparse}} = \mathbb{I}[M_{\text{base}} > t] \odot M_{\text{base}} \quad (9)$$

其中, $\mathbb{I}[\cdot]$ 为指示函数, $\odot$ 表示逐元素乘法。将基础掩码与自适应阈值进行对比, 当掩码值大于阈值时保留原始值, 否则置 0, 生成初始稀疏掩码。此外, 在训练过程中, 若掩码密度超过预测阈值, 则采用“Top-K 筛选”^[28] 进行进一步稀疏化, 将掩码非零区域比例主要控制在 10%~35% 范围内, 确保掩码稀疏度处于合理区间, 同时保留差异化处理的有效性, 模型稳定后, 该比例通常集中在 15%~25%。

1.1.4 双路径处理模块

图 3 展示了双路径处理模块的网络架构, 清晰呈现了精细化路径 (refined pathway) 与轻量化路径 (lightweight pathway) 的并行结构, 其中精细化路径重点捕捉边界电压信号中的微小目标特征与空间依赖关系, 轻量化路径在保证基础特征提取能力的前提下, 有效降低模型计算复杂度、减少推理耗时。二者协同工作, 既有助于提高 EIT 图像重建精度, 又兼顾了模型计算效率, 为乳腺筛查等潜在临床应用场景中的快速成像提供了方法基础。考虑到本研究尚未使用真实临床乳腺数据进行验证, 相关临床适用性仍需在后续研究中进一步评估。




Fig. 3 Dual-path processing module guided by the dynamic mask

a. 面向非关键区域的轻量化路径。该路径对应掩码值较低的区域, 采用轻量化 CNN 架构, 在保

证足够特征表征能力的同时, 实现对简单区域的快速优化, 有效避免了计算冗余。

b. 面向关键区域的精细化路径。该路径针对掩码值较高的区域, 采用U-Net^[29]架构, 利用跳跃连接保留细节并实现特征融合。

编码器: 包含3个编码单元, 每个单元由两组带LeakyReLU激活的3×3卷积, 以及用于特征下采样的2×2最大池化层组成。该设计可逐步扩大感受野, 使深层网络捕捉关键区域的全局上下文特征。

解码器: 包含三级解码单元, 通过2×2上采样恢复空间分辨率, 结合两级3×3卷积进行特征优化, 并利用跳跃连接实现编码器与解码器间的多尺度特征融合, 确保细节信息的准确重建。

对轻量化处理结果与精细处理结果进行自适应融合, 基于动态稀疏掩码 M_{sparse} , 通过加权融合生成电导率:

$$\hat{\sigma} = (1 - M_{\text{sparse}}) \odot \hat{\sigma}_{\text{light}} + M_{\text{sparse}} \odot \hat{\sigma}_{\text{refined}} \quad (10)$$

式中, $\hat{\sigma}_{\text{light}}$ 为轻量化路径的输出, 专门针对非关键区域优化; $\hat{\sigma}_{\text{refined}}$ 为精细化路径的输出, 聚焦于关键区域的细节恢复。

为进一步提升图像重建的精细度与空间连续性, 将两条路径输出融合后得到的电导率数据送入由多层线性映射与激活函数构成的小型全连接网络进行全局特征规整与细节优化。通过对融合特征的非线性拟合与全局信息整合, 有效抑制伪影与噪声干扰, 同时修正局部电导率分布偏差, 最终输出空间结构完整、边界清晰、数值稳定的电导率重建分布。

1.1.5 物理约束模块与网络训练

由于逆问题通常存在“多解性”和“噪声敏感性”, 单纯通过数据驱动模型可能会学到不符合物理规律的伪相关特征, 导致重建的电导率分布在物理上不合理。本研究引入物理约束, 确保模型预测的电导率分布满足电压与电导率之间的物理关系^[30], 从而提高重建结果的可靠性与泛化能力。

在EIT中, 小扰动假设下, 边界电压变化与电导率变化之间的关系可通过线性近似表征, 该关系由灵敏度矩阵 S 描述^[31]。从物理意义上, S 量化了单个像素内电导率的单位变化对边界电压测量值的影响程度, 其数学表达式为:

$$\Delta u \approx S \cdot \Delta \sigma \quad (11)$$

其中, 矩阵元素 $S = [i, j]$ 表示第 j 个像素的电导率变化对第 i 个边界电压的影响。

为了确保重建电导率分布符合物理规律, 引入基于灵敏度矩阵的物理约束项。设模型预测的电导

率分布为 $\hat{\sigma}$, 实际测量的电压为 U_{meas} , 则物理一致性损失为:

$$L_{\text{physics}} = \frac{1}{B \cdot D_u} \sum_{i=1}^B \|U_{\text{meas}}^{(i)} - S \cdot \hat{\sigma}\|_2^2 \quad (12)$$

该约束项强制模型预测的电导率分布, 通过正问题映射后得到的电压值与实测电压保持一致。

本研究采用均方误差 (mean squared error, MSE) 作为主要损失函数, 量化重建电导率分布与真实分布之间的差异。其数学表达式定义如下:

$$L_{\text{MSE}} = \frac{1}{B \times H \times W} \sum_{b=1}^B \sum_{i=1}^H \sum_{j=1}^W (\sigma_{ijk} - \hat{\sigma}_{ijk})^2 \quad (13)$$

其中, B 为批次大小, H 和 W 分别为图像的高度和宽度。

综合以上各项, 总损失函数定义为:

$$L_{\text{total}} = L_{\text{MSE}} + \lambda \cdot L_{\text{physics}} \quad (14)$$

其中, $\lambda = 0.05$ 为物理约束权重系数, 用于平衡数据拟合和物理一致性。

模型训练采用AdamW优化器, 学习率设置为0.001, 批次大小为16, 训练总轮次为200个训练轮次 (epoch)。实验平台配置如下: 所有模型基于PyTorch框架 (Python 3.9) 实现。实验所用计算机配备Intel Core i7-13620H CPU、32 GB内存以及NVIDIA RTX 4060 Ti (8 GB显存) GPU。

2 仿真设置与分析

所有仿真数据均通过电阻抗层析成像与扩散光学层析成像重建软件 (electrical impedance tomography and diffuse optical tomography reconstruction software, EIDORS) 工具包生成^[32]。仿真模型设置如下: 测量区域为直径100 mm的圆形域, 边界等间距布置16个铜电极构成传感器, 激励方式为相邻激励^[26]; 背景电导率设置为0.2 S/m, 近似正常乳腺组织的典型电导率, 在背景中嵌入电导率为1 S/m的非均匀目标, 模拟肿瘤组织^[33]。数据集涵盖圆形、三角形、矩形3种基础目标形状, 具体仿真参数为: 激励电流幅值 $I = 1$ mA, 频率为 $f = 100$ kHz。每个样本随机包含1~3个异常目标, 目标形状包括圆形、矩形和三角形, 目标的位置、尺寸、形状及数量均随机组合生成。目标被约束在直径100 mm的圆形成像区域内, 并避免目标之间明显重叠。其中, 圆形目标直径为5~25 mm, 矩形目标边长为6~22 mm, 三角形目标外接圆直径为6~25 mm。数据集生成完成后, 按照10 000、500和500的数量划分为训练集、验证集和测试集。划

分过程中保证3种目标形状及不同目标数量在3个子集中的比例基本一致,以减少数据分布偏差对模型评估结果的影响。

本研究对输入边界电压和输出电导率进行了统一的预处理。对于输入数据,首先将16电极相邻激励模式下采集得到的边界电压整理为208个一维向量,同时剔除了其中的冗余测量值。随后,采用训练集电压数据的均值和标准差对所有输入电压进行标准化处理。验证集、测试集以及实测实验数据均采用训练集统计得到的归一化参数进行处理。为便于网络学习,电导率标签在训练过程中进行线性归一化处理,网络输出结果在可视化和定量分析时再转换回实际电导率范围。所有对比方法均采用相同的数据预处理方式和图像尺寸设置,以保证实验结果具有可比性。

为定量评价MADS-Net的性能,计算3项核心评价指标:图像相关系数(image correlation coefficient, ICC)^[34]、均方根误差(root mean square error, RMSE)^[35]与峰值信噪比(peak signal-to-noise ratio, PSNR)^[35],上述指标可全面反映重建电导率分布与真实分布的一致性与准确性,具体计算公式如下:

$$ICC = \frac{\sum_{i=1}^N (\sigma_i - \bar{\sigma})(\hat{\sigma}_i - \bar{\hat{\sigma}})}{\sqrt{(\sum_{i=1}^N (\sigma_i - \bar{\sigma})^2)(\sum_{i=1}^N (\hat{\sigma}_i - \bar{\hat{\sigma}})^2)}} \quad (15)$$

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (\sigma_i - \hat{\sigma}_i)^2} \quad (16)$$

$$PSNR = 10 \lg \left(\frac{\max(\sigma)^2}{MSE} \right) \quad (17)$$

式中, N 为图像的总节点数; σ_i 、 $\hat{\sigma}_i$ 分别为真实与预测电导率值; $\bar{\sigma}$ 、 $\bar{\hat{\sigma}}$ 分别为真实与预测电导率的均值; $\max(\sigma)$ 为真实电导率的最大值。

除ICC、RMSE和PSNR等图像级评价指标外,本研究进一步引入病灶级评价指标,以评价不同方法对异常目标边界和小尺寸目标区域的重建能力。首先,对真实电导率图像和预测电导率图像进行阈值分割,分别得到真实异常区域 G 和预测异常区域 P 。在此基础上,提取二者的边界像素集合,分别记为 B_g 和 B_p 。边界Dice系数用于评价预测异常区域边界与真实异常区域边界之间的重叠程度,其定义为:

$$Dice_{boundary} = \frac{2|B_p \cap B_g|}{|B_p| + |B_g|} \quad (18)$$

式中, B_p 表示预测异常区域的边界像素集合, B_g 表示真实异常区域边界像素集合。

小目标召回率用于评价模型对小尺寸异常目标区域的保留能力,其定义为:

$$Recall_{small} = \frac{|P \cap G_{small}|}{|G_{small}|} \quad (19)$$

式中, P 表示预测异常区域, G_{small} 表示真实小目标区域, $|P \cap G_{small}|$ 表示预测结果中成功覆盖真实小目标的像素数量。在本研究中,我们将目标直径(d_{eq}) ≤ 8 mm的归为小目标。

为保证不同重建方法之间的公平比较,本研究对所有方法采用统一的数据划分、预处理流程、评价指标和测试样本。全部11 000组样本本划分为训练集10 000组、验证集500组和测试集500组,其中验证集用于超参数选择和最优模型筛选,测试集用于最终性能评估。CNN、U-Net、Deep D-Bar后处理网络以及本研究提出的MADS-Net均在相同数据集上训练与测试,输入数据采用一致的归一化方式,输出均为64×64电导率分布图像,评价指标统一采用ICC、RMSE和PSNR。

本研究选取高斯-牛顿算法(Gauss-Newton, GN)、CNN、U-Net和Deep D-Bar作为对比方法。GN作为典型传统迭代型EIT重建算法,采用基于灵敏度矩阵的Gauss-Newton框架;CNN作为基础端到端深度学习模型,由全连接映射和多层卷积结构组成;U-Net采用编码器-解码器结构,并通过跳跃连接增强图像细节恢复能力;Deep D-Bar作为EIT专用混合式重建方法,首先利用D-Bar算法生成初始电导率,再通过U-Net型后处理网络修正初始重建结果中的边界模糊、伪影和细节缺失问题。

为进一步保证训练公平性,CNN、U-Net、Deep D-Bar后处理网络和MADS-Net均采用AdamW优化器,学习率固定为0.001,批次大小为16,训练轮次为200 epoch。训练过程中基于验证集进行超参数调节和最优模型选择。所有模型均在相同硬件环境和相同测试集上进行定量及定性比较,以保证实验结果的一致性和可重复性。

2.1 基础几何图像对比

为验证所提方法的图像重建性能,本研究采用基于圆形、矩形、三角形3种基础几何形状的测试

目标开展实验。图4展示了不同方法的EIT仿真重建结果可视化对比。其中，第一列为真实电导率分布，其余列依次为GN、CNN、U-Net、Deep D-Bar和MADS-Net的重建结果。由图可见，在同时包含大、小目标的复杂场景中，MADS-Net重建结果与真实基准分布贴合度最高，目标边界清晰、无明显伪影，小目标的轮廓、尺寸均能精准还原，

Deep D-Bar方法在整体轮廓上优于传统GN算法和CNN，但其对复杂形状的重建能力有限，小目标的恢复精度不及MADS-Net，CNN、U-Net方法存在目标边缘模糊、局部细节丢失等问题，无法精准捕捉小目标的细微特征，而GN的表现能力较差，对于多目标的重建容易出现较多伪影，无法有效还原目标的真实形态。




Fig. 4 Visual comparison of EIT reconstruction results from simulation data using different methods

表1进一步汇总了所有对比方法在仿真数据集上的定量评价指标，所有结果均基于5次独立重复训练（每次使用不同随机种子）的均值±标准差表示。为进一步评估不同方法之间性能差异的统计可靠性，本研究采用配对 t 检验对MADS-Net与各对比方法进行比较。实验结果显示，在所有仿真测试案例中，MADS-Net对异常目标实现了稳定检出，说明该方法能够较好地保留异常区域的有效响应。从图像级指标来看，不同算法在重建性能上存在一定差异。具体而言，GN算法表现出明显的局限性，虽能实现目标物的近似定位，但其形态还原能力较差，难以准确重建目标的几何细节。CNN方法的重建结果在整体上优于传统算法，但仍存在不足，例如背景区域出现较多电导率伪影，且对尖锐棱角的重建存在钝化现象。U-Net网络获得了更优的整体重建质量，能有效抑制伪影并更精确地还原目标结构。Deep D-Bar方法能够较准确地定位基础

目标形状，且背景区域伪影较少，但对三角形等尖锐边界结构的重建能力有限，小目标召回率也相对较低。其原因可能在于，D-bar方法为保证重建稳定性通常会抑制高频信息，使小目标边界和局部细节被平滑化，从而影响尖锐角及小尺寸异常区域的恢复效果。本研究提出的MADS-Net在所有测试案例中均展现出最佳性能，其定量评估指标优于其他对比方法。定性分析显示，重建误差主要集中于目标物边缘，背景区域则几乎无失真。综上所述，定性与定量结果均证实，本研究所提出的MADS-Net方法在EIT图像重建的精度与整体质量方面具有一定优势。

2.2 噪声鲁棒性分析

为评估各重建算法在实际应用中的噪声鲁棒性，本研究通过向边界电压数据中注入不同强度的高斯白噪声，模拟真实测量环境。鉴于抗噪性能评价的核心在于重建精度与图像一致性，选取ICC与

Table 1 Quantitative reconstruction results of different methods on the simulation dataset


Method	ICC	RMSE	PSNR	Boundary Dice	Small-target recall
GN	0.743 4±0.105 6	0.208 8±0.096 7	13.564 6±3.565 9	0.642 0±0.118 5	0.583 0±0.142 0
CNN	0.820 2±0.099 2	0.149 1±0.077 2	16.613 8±3.488 5	0.815 7±0.163 3	0.799 3±0.173 9
U-Net	0.860 2±0.041 8	0.086 4±0.057 5	19.756 8±3.227 8	0.892 7±0.060 1	0.829 2±0.093 5
Deep D-Bar	0.897 1±0.067 3	0.083 5±0.048 7	17.853 5±3.877 5	0.851 0±0.071 5	0.762 8±0.105 0
MADS-Net	0.917 6±0.048 8	0.060 6±0.031 6	23.893 9±2.685 3	0.910 9±0.052 1	0.904 7±0.062 8

Paired *t*-test shows that MADS-Net outperforms all other methods on every metric ($P<0.05$).

RMSE作为核心评价指标。

不同信噪比下各算法的重建性能结果如图5所示。可以观察到,随着噪声强度增大,即信噪比(signal-to-noise ratio, SNR)降低,所有算法的重建性能均出现整体下降。与之相对,MADS-Net方法在所有噪声水平下均保持了最优性能,展现出较

强的抗干扰优势。具体而言,当SNR高于40 dB时,MADS-Net的ICC与RMSE指标几乎不受噪声影响;即使当SNR降至30 dB时,其性能衰减幅度也远小于对比算法,重建图像仍能保持较高的精度与一致性。

**Fig. 5** ICC and RMSE of different reconstruction algorithms under different SNR conditions

(a) Image correlation coefficient (ICC) versus SNR. (b) Root mean square error (RMSE) versus SNR.

2.3 消融实验

为验证MADS-Net中各关键模块的有效性,本研究分别对动态稀疏掩码模块、多尺度注意力机制和物理约束模块开展消融实验。所有消融模型均采用相同的数据集划分、训练参数和评价指标,以保证不同模型之间的公平比较。其中,动态稀疏掩码模块主要用于提高模型训练与推理效率,多尺度注意力机制主要用于增强小目标和弱扰动特征的表达能力,物理约束模块主要用于提升重建结果的物理合理性、精度和噪声鲁棒性。

2.3.1 动态稀疏掩码模块消融实验

为定量评估动态掩码模块对训练效率、推理性能的贡献,在完整模型中移除该模块后进行对比实验,结果汇总于表2。在完全相同的训练设置下,动态掩码的引入缩短了训练时长,同时提升了处理速度和推理速度,明确证实了该模块通过规避非关键区域的有效计算,有效消除了计算冗余,实现了整体训练过程的优化。

2.3.2 多尺度注意力机制消融实验

为评估多尺度注意力机制对网络小目标重建性能的贡献,从完整模型中移除该模块后,与基准模

Table 2 Ablation study on training efficiency

Method	Total training time/min	Average processing speed/(samples·s ⁻¹)	Average test inference time per sample/ms
MAS-Net	88.11	378.34	0.70
MADS-Net	77.93	427.76	0.64

型进行系统对比。图6展示了各模型对不同尺寸 d_0 (5~8 mm) 目标的重建结果可视化对比。仅采用动态掩码网络的模型(第二行), 缺乏对弱特征的捕捉能力, 对小目标的还原能力有限; 在基准模型基础上引入物理约束后(第三行), 重建质量得到部

分改善, 但对5 mm的小目标的还原能力表现不足; 而集成完整多尺度注意力机制的模型(第四行) 展现出最优的重建性能, 可更清晰、精准地还原小目标的形状与位置, 即使是5 mm的小目标也能实现高质量重建。




Fig. 6 Ablation study on reconstruction performance for small targets of varying sizes

2.3.3 物理约束模块消融实验

为评估物理约束模块对重建精度的独立贡献, 本研究构建了去除物理约束模块的消融模型 MADS-Net w/o PC。该模型与完整 MADS-Net 采用相同网络结构、训练数据、优化器和训练参数, 唯

一区别在于训练过程中是否引入物理一致性损失。通过在相同仿真测试集上比较 ICC、RMSE、PSNR、Boundary Dice 和小目标召回率, 评估物理约束模块对重建精度和病灶灶级结构恢复能力的影响, 实验结果如表3所示。

Table 3 Ablation study of the physical constraint module on reconstruction accuracy

Method	ICC	RMSE	PSNR/dB	Boundary Dice	Small-target recall
MADS-Net w/o PC	0.896 3±0.057 4	0.073 8±0.039 2	22.176 4±3.021 7	0.884 6±0.061 8	0.812 5±0.075 4
MADS-Net	0.917 6±0.048 8	0.060 6±0.031 6	23.893 9±2.685 3	0.910 9±0.052 1	0.904 7±0.062 8

Paired *t*-test shows that MADS-Net outperforms all other methods on every metric ($P<0.05$).

从表3中可以看出, 与 MADS-Net w/o PC 相比, 完整 MADS-Net 在所有评价指标上均表现更优。具体而言, 引入物理约束模块后, ICC 由 0.896 3 提高至 0.917 6, 相对提升 2.38%, RMSE 由 0.073 8 降低至 0.060 6, 相对降低 17.89%, PSNR 由 22.176 4 dB 提高至 23.893 9 dB, 相对提升 7.74%。同时, Boundary Dice 和 Small-target recall 也分别由 0.884 6 和 0.812 5 提高至 0.910 9 和 0.904 7, 相对提

升 2.97% 和 11.35%。上述结果表明, 物理约束模块能够有效提高重建图像与真实电导率分布之间的一致性, 并改善异常目标边界和小目标区域的恢复效果。

为进一步分析物理约束模块对噪声鲁棒性的影响, 本研究在不同信噪比条件下分别测试 MADS-Net w/o PC 和完整 MADS-Net 的重建性能。结果如表4所示, 去除物理约束后, 模型在低信噪比条件

下的性能下降更加明显, 表现为 ICC 降低、 $RMSE$ 升高以及标准差增大。相比之下, 完整 MADS-Net 在不同噪声条件下均保持更高的 ICC 和更低的 $RMSE$, 说明物理约束模块能够抑制噪声引起的不合理电导率波动, 提高模型在噪声扰动下的稳定性。

Table 4 Ablation study of the physical constraint module under different SNR levels

SNR levels/dB	ICC		RMSE	
	MADS-Net w/o PC	MADS-Net	MADS-Net w/o PC	MADS-Net
30	0.856 9±0.039 8	0.881 6±0.032 5	0.096 7±0.033 9	0.083 5±0.027 6
40	0.889 2±0.031 5	0.912 4±0.024 7	0.078 6±0.025 4	0.067 8±0.020 5
50	0.903 6±0.025 7	0.922 1±0.019 8	0.069 4±0.020 8	0.060 9±0.016 8
60	0.908 7±0.023 1	0.924 2±0.017 5	0.065 1±0.018 9	0.058 1±0.014 7
70	0.910 5±0.022 4	0.925 3±0.016 8	0.064 2±0.018 1	0.056 9±0.013 9

Paired t -test shows that MADS-Net outperforms all other methods on every metric ($P<0.05$).

3 实验分析

3.1 琼脂体模实验

为验证 MADS-Net 在实际测量条件下的性能, 本研究搭建了 EIT 实验系统, 系统组成与工作流程如图 7 所示。该系统主要由 16 电极传感器阵列 [26]、数据采集硬件与上位处理机组成。场域为圆柱形容器, 内径 100 mm, 高度 50 mm; 容器内填充生理盐水 (电导率 0.2 S/m) 作为背景介质, 内部放置琼脂体模 (电导率 1.0 S/m) 作为成像目标。系统

以 STM32H743 微控制单元 (microcontroller unit, MCU) 为核心, 激励信号由数模转换器 (digital-to-analog converter, DAC) 生成并注入被测域, 产生的边界电压经电极传输至信号调理模块进行放大与滤波, 随后由 MCU 内置的模数转换器 (analog-to-digital converter, ADC) 采集并数字化。测量通道通过通用输入输出 (general-purpose input/output, GPIO) 控制的多路复用器自动切换, 电压数据逐通道采集后上传至上位机, 最终拼接为完整的电压测量数据集 [36]。




Fig. 7 Experimental setup and hardware architecture
(a) Measurement workflow. (b) Portable EIT system hardware.

图 8 为应用琼脂体模进行实验的重建图像效果, 与仿真实验相比, 在实际测量条件下, 所有方法的性能均出现不同程度的衰减。从图 8 中可以看

出, GN 算法在单目标场景中可实现有效定位, 但在多目标场景中出现严重的畸变与混淆, CNN 方法虽能定位目标, 但重建图像存在大量伪影, 背景

噪声抑制效果较差。Deep D-Bar方法在实测数据中表现出较好的背景伪影抑制能力，目标位置也能够较稳定地反映出来，说明其具有一定的抗噪性和稳定性，然而，该方法对三角形等尖锐边界结构的细节还原能力有限。U-Net对于尖锐目标形状畸变较明显。本研究提出的MADS-Net模型，虽受实测场景非理想因素的影响，相比仿真结果也出现了一定的性能衰减，但其整体衰减幅度远低于所有对比算

法，在多组实测数据中均展现出优异的综合表现。在目标定位精度、边界还原度、伪影抑制能力与噪声鲁棒性方面均全面优于对比方法，无论是单目标还是多目标场景，都能精准还原目标物的真实形状、尺寸与空间位置，目标边界清晰，背景无明显伪影，且在所有实测数据中均保持了稳定一致的重建效果，展现出更优异的整体重建性能与稳定性。




Fig. 8 Reconstructed images from agar phantom experiments

为进一步将定性的视觉对比转化为客观、量化的性能评价，采用ICC与RMSE作为评价指标，对所有对比方法的重建性能进行了系统的定量统计与对比分析，相关结果如图9所示。结果表明，本研究提出的MADS-Net模型在所有测试中均实现了最优且最稳定的性能，ICC值稳定保持在0.88~0.95之间，RMSE稳定处于0.03~0.10区间。更重要的是，相比其他方法在不同测试用例中出现的指标大幅波动，MADS-Net的两项核心指标均保持了极窄的波动范围，进一步证实了模型在实测环境下较好的鲁棒性与稳定性。

3.2 猪肉组织实验

为进一步验证MADS-Net在真实复杂生物组织介质中的成像性能，模拟肿瘤与正常组织区分等临床相关成像场景，本研究设计了基于猪脂肪与瘦肉组织的对比实验。选取猪脂肪与瘦肉作为实验材料，核心原因在于二者电导率存在明显差异，可在一定程度上模拟低电导率背景组织与高电导率异常组织之间的电学对比关系。需要指出的是，该实验仅为离体生物组织条件下的模型验证，不能完全代表真实乳腺组织中脂肪、腺体、结缔组织及微钙化等复杂结构的电学分布。因此，相关结果主要用于




Fig. 9 Quantitative evaluation of reconstruction performance for agar phantom experiments

(a) Image correlation coefficient (*ICC*) of all comparative methods across all cases. (b) Root mean square error (*RMSE*) of all comparative methods across all cases.

评估 MADS-Net 在复杂生物组织背景下的重建能力, 而不能直接外推为真实临床乳腺筛查性能。

本实验旨在系统评估各类算法对不同电导率组织、小目标与多异质目标的重建能力。采用与 3.1 节完全相同的 EIT 硬件系统与测量参数, 以均质新鲜猪脂肪组织 (低电导率) 作为背景介质, 以新鲜猪瘦肉组织加工而成的规则圆柱体 (高电导率) 作为目标, 通过改变目标的尺寸与数量, 探究其对重建性能的影响。

具体实验设置如下, 将直径 $d_1=10$ 、15、25 mm 的瘦肉组织分别单独放置于猪脂肪背景中, 以评估各算法对不同尺寸单目标的定量重建能力; 随后, 将不同尺寸的圆柱体以一定间距并排放置, 以检验多目标场景下算法的分辨能力。

在猪肉组织实验中, 各算法的重建结果如图 10 所示, GN 算法因性能过差未纳入对比。定性分析表明, CNN 方法虽能定位目标, 但重建图像存在显著的背景噪声, 目标边缘模糊, 尺寸估计偏差较大, U-Net 在目标定位与背景抑制方面优于 CNN, 但仍无法完整还原 10 mm 小目标的形状。Deep D-Bar 方法能够较准确地定位基础目标形状, 且背景区域伪影较少, 说明其具有一定的稳定性和抗噪能力。然而, 该方法对小尺寸目标的细节还原能力仍有限, 小目标响应相对较弱。与之相对, MADS-Net 在所有实验案例中均表现最优: 重建目标形状规则、边界清晰, 背景均匀干净, 重建尺寸

与实际目标高度吻合; 即使在难度最高的 10 mm 小目标检测中, MADS-Net 仍能重建出清晰、独立的异常信号, 展现出对小目标的优异检测能力。

为了直观展示各算法在单目标与多目标场景下的定量重建性能, 对各方法重建图像的 *ICC* 与 *RMSE* 进行了统计 (图 11)。在所有实验配置中, MADS-Net 均实现了最高的 *ICC* 值与最低的 *RMSE* 值, 表明其重建结果与真实分布的一致性最高、误差最小。尤其在多目标场景中, 其 *ICC* 值仍保持在 0.90 以上, 优于其他算法。上述结果定量证实, 在真实生物组织的复杂成像任务中, MADS-Net 兼具高重建精度与优异的多目标分辨能力。

4 结 论

针对 EIT 图像重建中逆问题严重病态性与小目标检测瓶颈的核心挑战, 本研究提出了一种融合多尺度注意力机制与动态稀疏掩码的 MADS-Net 重建网络。经系统的数值仿真与物理实验验证, 得出以下结论。

a. 基于“先定位、后重建”策略的动态稀疏掩码双路径架构, 可实现计算资源的自适应分配, 使模型总训练时长缩短 23.5%, 单样本推理时间低至 0.64 ms, 结合物理约束进一步提升了模型的泛化能力与重建结果的物理合理性, 在全测试场景下, 模型平均 *ICC* 达 0.917 6、*RMSE* 低至 0.060 6、*PSNR* 达 23.893 9 dB, 所有核心指标均全面优于高




Fig. 10 Reconstructed images from pork tissue experiments




Fig. 11 Quantitative evaluation of reconstruction performance for porcine tissue experiments

(a) Image correlation coefficient (*ICC*) of CNN, U-Net, Deep D-Bar and MADS-Net across all cases. (b) Root mean square error (*RMSE*) of CNN, U-Net, Deep D-Bar and MADS-Net across all cases.

斯-牛顿算法、CNN、U-Net、Deep D-Bar 等主流对比方法。

b. 多尺度注意力机制有效缓解了低维测量数据到高维电导率分布映射过程中的信息丢失问题，显著增强了模型对小目标的重建能力。该机制可在直

径 100 mm 的传感场内稳定检出最小 5 mm 的异常目标，即使在 30 dB 低信噪比环境下仍保持优异的成像性能，噪声鲁棒性优于所有对比方法。

本研究目前仅基于仿真、琼脂体模和离体猪肉组织实验进行验证，尚未使用真实临床乳腺数据，

在复杂生物背景下的泛化能力仍有提升空间。未来工作将聚焦于模型优化, 进一步构建包含分层组织、非规则解剖边界、多组织电导率扰动以及复杂背景噪声的模型, 并对临床乳腺组织数据进行采集与验证, 推动该技术在乳腺无创筛查领域的临床转化与落地应用。此外, 本方法解决了 EIT 重建中的通用性问题, 因此可推广至肺功能成像、脑水肿监测、肝脂肪定量等其他医学 EIT 应用场景。未来工作将开展跨领域的迁移实验, 进一步验证 MADS-Net 的通用性。

参 考 文 献

- [1] Cheney M, Isaacson D, Newell J C. Electrical impedance tomography. *SIAM Rev*, 1999, **41**(1): 85-101
- [2] Yang L, Wu H, Liu K, *et al.* An image reconstruction algorithm for electrical impedance tomography using measurement estimation of virtual electrodes. *IEEE Sens J*, 2022, **22**(13): 13012-13022
- [3] Tan C, Li F, Lv S, *et al.* Gas-liquid two-phase stratified flow interface reconstruction with sparse batch normalization convolutional neural network. *IEEE Sens J*, 2021, **21**(15): 17076-17084
- [4] Yang X, Chen H, Ma G, *et al.* Real-time monitoring multi-phase flow using electrical impedance tomography//IEEE. 2022 IEEE International Conference on Sensing, Diagnostics, Prognostics, and Control (SDPC). Chongqing, China: IEEE, 2022: 306-311
- [5] Yao J, Takei M. Application of process tomography to multiphase flow measurement in industrial and biomedical fields: a review. *IEEE Sens J*, 2017, **17**(24): 8196-8205
- [6] 李芳, 陈柏, 吴阳, 等. 基于电阻抗断层成像的慢性阻塞性肺疾病诊断方法研究. *生物化学与生物物理进展*, 2025, **52**(7): 1866-1877
- [6] Li F, Chen B, Wu Y, *et al.* *Prog Biochem Biophys*, 2025, **52**(7): 1866-1877
- [7] Halter R J, Hartov A, Poplack S P, *et al.* Real-time electrical impedance variations in women with and without breast cancer. *IEEE Trans Med Imaging*, 2015, **34**(1): 38-48
- [8] Li Z, Wu Y, Liu K, *et al.* DSFNet: Dual-source and spatiotemporal-feature fusion network for bedside diagnosis of lung injuries with electrical impedance tomography. *Med Image Anal*, 2026, **110**: 104003
- [9] Murphy E K, Mahara A, Wu X, *et al.* Phantom experiments using soft-prior regularization EIT for breast cancer imaging. *Physiol Meas*, 2017, **38**(6): 1262-1277
- [10] Xu F, Li M, Li J, *et al.* Diagnostic accuracy and prognostic value of three-dimensional electrical impedance tomography imaging in patients with breast cancer. *Gland Surg*, 2021, **10**(9): 2673-2685
- [11] Song Y, Wang Y, Liu D. A nonlinear weighted anisotropic total variation regularization for electrical impedance tomography. *IEEE Trans Instrum Meas*, 2022, **71**: 4010713
- [12] Adler A, Boyle A. Electrical impedance tomography: tissue properties to image measures. *IEEE Trans Biomed Eng*, 2017, **64**(11): 2494-2504
- [13] Jin B, Maass P. An analysis of electrical impedance tomography with applications to tikhonov regularization. *ESAIM: Control, Optimisation and Calculus of Variations*, 2012, **18**(4): 1027-1048
- [14] Jauhainen J, Kuusela P, Seppanen A, *et al.* Relaxed Gauss-Newton methods with applications to electrical impedance tomography. *SIAM J Imaging Sci*, 2020, **13**(3): 1415-1445
- [15] 叶明, 李晓丞, 刘凯, 等. 一种基于 U2-Net 模型的电阻抗成像方法. *仪器仪表学报*, 2021, **42**(2): 235-243
- [15] Ye M, Li X C, Liu K, *et al.* *Chin J Sci Instrum*, 2021, **42**(2): 235-243
- [16] Tan C, Lv S, Dong F, *et al.* Image reconstruction based on convolutional neural network for electrical resistance tomography. *IEEE Sens J*, 2019, **19**(1): 196-204
- [17] Wu Y, Chen B, Liu K, *et al.* Shape reconstruction with multiphase conductivity for electrical impedance tomography using improved convolutional neural network method. *IEEE Sens J*, 2021, **21**(7): 9277-9287
- [18] Hamilton S J, Hauptmann A. Deep D-bar: real-time electrical impedance tomography imaging with deep neural networks. *IEEE Trans Med Imaging*, 2018, **37**(10): 2367-2377
- [19] Wu Y, Han J, Bai X, *et al.* A sensitivity-guided unsupervised learning method for image reconstruction of electrical impedance tomography. *IEEE Trans Instrum Meas*, 2025, **74**: 4507512
- [20] Mordang J J, Gubern-Mérida A, Bria A, *et al.* The importance of early detection of calcifications associated with breast cancer in screening. *Breast Cancer Res Treat*, 2018, **167**(2): 451-458
- [21] Dimas C, Alimisis V, Uzunoglu N, *et al.* Advances in electrical impedance tomography inverse problem solution methods: from traditional regularization to deep learning. *IEEE Access*, 2024, **12**: 47797-47829
- [22] Maxwell J C. A Treatise on Electricity and Magnetism. 3rd ed. Oxford: Clarendon Press, 1998
- [23] Schullcke B, Krueger-Ziolek S, Gong B, *et al.* Compensation for large thorax excursions in EIT imaging. *Physiol Meas*, 2016, **37**(9): 1605-1623
- [24] Vaswani A, Shazeer N, Parmar N, *et al.* Attention is all you need//Bengio S, Wallach H, Larochelle H, *et al.* *Advances in Neural Information Processing Systems*: 30. Red Hook: Curran Associates, Inc., 2017: 5998-6008
- [25] He K, Gkioxari G, Dollár P, *et al.* Mask R-CNN. *IEEE Trans Pattern Anal Mach Intell*, 2018, **42**(2): 386-397
- [26] Djajaputra D. Electrical impedance tomography: methods, history and applications. *Med Phys*, 2005, **32**(8): 2731
- [27] Maas A L, Hannun A Y, Ng A Y. Rectifier nonlinearities improve neural network acoustic models//Dasgupta S, McAllester D. *Proceedings of the 30th International Conference on Machine Learning*. Atlanta: JMLR Workshop and Conference Proceedings, 2013: 1-8
- [28] Jayakumar S M, Pascanu R, Rae J W, *et al.* Top-KAST: Top-k always sparse training//Larochelle H, Ranzato M A, Hadsell R, *et al.* *Advances in Neural Information Processing Systems*. Red

- Hook: Curran Associates, Inc., 2020: 20744-20754
- [29] Ronneberger O, Fischer P, Brox T. U-Net: convolutional networks for biomedical image segmentation//Navab N, Hornegger J, Wells W, *et al.* Medical Image Computing and Computer-Assisted Intervention-MICCAI 2015. Cham: Springer International Publishing, 2015: 234-241
- [30] Raissi M, Perdikaris P, Karniadakis G E. Physics-informed neural networks: a deep learning framework for solving forward and inverse problems involving nonlinear partial differential equations. J Comput Phys, 2019, **378**: 686-707
- [31] Brandstatter B. Jacobian calculation for electrical impedance tomography based on the reciprocity principle. IEEE Trans Magn, 2003, **39**(3): 1309-1312
- [32] Adler A, Lionheart W R. Uses and abuses of EIDORS: an extensible software base for EIT. Physiol Meas, 2006, **27**(5): S25-S42
- [33] Setyawan G, Sejati P A, Ogawa R, *et al.* Detection of invasive ductal carcinoma in quadrant breast areas by electrical impedance tomography implemented with Gaussian relaxation-time distribution (EIT-GRTD). Biomed Phys Eng Express, 2024, **10**(5): 055007
- [34] 赵子涵, 孙博, 黄晶石, 等. 基于区域聚类三维电阻抗成像的胃出血检测方法. 生物化学与生物物理进展, 2026, **53**(4): 1062-1075
- Zhao Z H, Sun B, Huang J S, *et al.* Prog Biochem Biophys, 2026, **53**(4): 1062-1075
- [35] 刘涛, 史曙生, 刘俊峰, 等. 基于TK-Noser正则化算法的警察极限训练肌肉疲劳电阻抗检测方法. 生物化学与生物物理进展, 2025, **52**(12): 3165-3174
- Liu T, Shi S S, Liu J F, *et al.* Prog Biochem Biophys, 2025, **52**(12): 3165-3174
- [36] Xu Z, Yao J, Wang Z, *et al.* Development of a portable electrical impedance tomography system for biomedical applications. IEEE Sens J, 2018, **18**(19): 8117-8124

MADS-Net: a Multi-scale Attention and Dynamic Sparse Mask Fusion Network for Electrical Impedance Tomography Image Reconstruction in Breast Screening*

YU Cheng-Tao^{1)**}, WANG Jia-Hui^{1)**}, HU Song-Pei²⁾, CHEN Huai-Jin^{3)***}, DING Li¹⁾,
YE Xia¹⁾, YAO Jia-Feng^{4)***}


¹⁾College of Mechanical Engineering, Jiangsu University of Technology, Changzhou 213001, China;

²⁾College of Mechanical and Electrical Engineering, Nanjing University of Aeronautics and Astronautics, Nanjing 210016, China;

³⁾School of Future Technology, South China University of Technology, Guangzhou 510641, China;

⁴⁾College of Physics and Optoelectronic Engineering, Jinan University, Guangzhou 510632, China)

Graphical abstract



* This work was supported by grants from the International Cooperation Project of Jiangsu Province (BZ2024036), the Major Research Project of Natural Science for Universities in Jiangsu Province (24KJA460003), the Applied Basic Research Program of Changzhou, Jiangsu Province (CJ20241070), and the Postgraduate Practice Innovation Program of Jiangsu University of Technology (XSJCX25_14).

** These authors contributed equally to this work.

*** Corresponding author.

CHEN Huai-Jin. Tel: 86-15195871108, E-mail: c1013756286@126.com

YAO Jia-Feng. Tel: 86-17715275835, E-mail: jfyao@jnu.edu.cn

Received: April 15, 2026 Accepted: June 24, 2026

Abstract Objective To address the key challenges in breast electrical impedance tomography (EIT) reconstruction including the severe ill-posedness of the inverse problem, limited measurement information from the electrodes, low contrast of small lesions, as well as the common drawbacks of traditional reconstruction methods such as boundary blurring, low spatial resolution, and weak small-target detection capability, and to overcome the limitations of existing deep learning approaches namely low training efficiency, insufficient physical consistency, and substantial information loss during the low-to-high dimensional mapping process, this study proposes a multi-scale attention and dynamic sparse mask fusion network (MADS-Net). The proposed method aims to enhance high-resolution reconstruction accuracy, small-lesion detectability, noise robustness, and computational efficiency in breast-screening-oriented EIT, thereby providing a feasible solution for the application of EIT in breast functional imaging. **Methods** The proposed network adopts a strategy of “locate first, reconstruct later”. It realizes adaptive allocation of computational resources through a dynamic mask module, alleviates information loss in the low-to-high dimensional mapping process *via* a multi-scale attention mechanism, and embeds physical constraints to improve the physical rationality of reconstruction results. The performance of the proposed method was validated through systematic numerical simulations, agar phantom experiments, and porcine tissue experiments. Comparisons were made with mainstream methods including the Gauss-Newton algorithm, convolutional neural networks, U-Net, and Deep D-Bar. The image correlation coefficient (ICC), root mean square error (RMSE), and peak signal-to-noise ratio (PSNR) were adopted as quantitative evaluation metrics. Furthermore, lesion-level evaluation metrics were introduced to assess the capability of different methods in reconstructing abnormal target boundaries and small-sized target regions. **Results** Experimental results demonstrate that MADS-Net outperforms all comparison methods across all test scenarios. In numerical simulations, it achieves higher accuracy in target morphology and spatial location recovery as well as better background suppression. In agar phantom experiments, its detection and imaging reliability for small targets is significantly superior to the comparison methods. In porcine tissue experiments, the model maintains good generalization performance and can adapt to complex biological tissue imaging scenarios. Quantitative results show that MADS-Net achieves an average *ICC* of 0.9176 ± 0.0488 , an *RMSE* as low as 0.0606 ± 0.0316 , and a *PSNR* of (23.8939 ± 2.6853) dB. It successfully detects tiny targets as small as 5 mm within a 100 mm diameter sensing field, reduces the total training duration by 23.5% compared with the baseline method, and maintains stable reconstruction performance even under strong noise interference. **Conclusion** The results demonstrate that MADS-Net achieves favorable EIT reconstruction performance in numerical simulations, agar phantom experiments, and porcine tissue experiments, even under common practical imaging challenges including low signal-to-noise ratio and blurred tissue boundaries. This study provides a methodological reference for further research on EIT in breast-screening-related scenarios and other medical functional imaging tasks, and also offers a low-cost, radiation-free alternative for breast lesion screening that aligns with the clinical demand for non-invasive diagnostic tools. It should be noted that real clinical breast data have not yet been used for validation in this study, and the clinical applicability of the proposed method requires further investigation. Future work will prioritize collecting multi-center real clinical breast datasets, and further optimize the model’s generalization ability to adapt to individual differences in breast tissue composition to promote its clinical application.

Key words electrical impedance tomography, dynamic mask network, multi-scale attention mechanism

DOI: 10.3724/j.pibb.2026.0197

CSTR: 32369.14.pibb.20260197