

DOI: 10.19650/j.cnki.cjsi.J2514602

# 基于多尺度密集注意力网络的肺部 EIT 重建算法\*

张函瑜<sup>1,2</sup>, 李楠<sup>1</sup>

(1. 西安电子科技大学高性能电子装备机电集成制造全国重点实验室 西安 710071;  
2. 西北工业大学自动化学院 西安 710129)

**摘要:**针对肺部电阻抗层析成像(EIT)在图像重建中存在的失真与精度不足的问题,提出了一种多尺度密集注意力网络(MsDA-Net)用于提升基于EIT技术的肺部通气与病变的重建精度。MsDA-Net属于直接估计模型,通过融合扩张卷积、多尺度密集连接与注意力机制,构建了具有强特征表征与复用能力的端到端图像重建架构,旨在充分挖掘电压测量数据中的深层非线性特征用于提升肺部成像精度。开展仿真及映射模型实验全面评估MsDA-Net的性能,仿真结果表明MsDA-Net能够精准重建肺部轮廓与病变结构,相较于传统成像算法,重建图像在视觉质量及定量评价指标上均取得显著提升,平均相关系数(CC<sub>s</sub>)、结构相似性(SSIM<sub>s</sub>)、均方根误差(RMSE<sub>s</sub>)及峰值信噪比(PSNR<sub>s</sub>)分别可达到0.987 1、0.903 5、0.060 5及31.671 6 dB。模型精度与前沿重建模型双分支超卷积U-Net和基于注意力的深度卷积神经网络相近,进一步证实了MsDA-Net的有效性。同时,MsDA-Net展现了良好的噪声鲁棒性,在20 dB高斯白噪声干扰下,图像仍然保持基本可用性。参考肺部CT图像在圆形域内构建映射模型以验证MsDA-Net的实用性,实验结果表明MsDA-Net能够有效重建测量域内目标物的形状与尺寸,随着场域内电导率分布变得复杂,重建精度呈现下降趋势,但重建图像的平均CC<sub>s</sub>、SSIM<sub>s</sub>、RMSE<sub>s</sub>及PSNR<sub>s</sub>仍分别可达到0.943 1、0.857 5、0.109 6及19.392 1 dB。

**关键词:**肺部电阻抗层析成像;图像重建;多尺度密集注意力网络

中图分类号: TH772 文献标识码: A 国家标准学科分类代码: 510.40

## A lung EIT reconstruction algorithm based on multi-scale dense attention network

Zhang Hanyu<sup>1,2</sup>, Li Nan<sup>1</sup>

(1. State Key Laboratory of Electromechanical Integrated Manufacturing of High-performance Electronic Equipments, Xidian University, Xi'an 710071, China; 2. School of Automation, Northwestern Polytechnical University, Xi'an 710129, China)

**Abstract:** To address the challenges of distortion and insufficient accuracy in image reconstruction of lung electrical impedance tomography (EIT), a multi-scale dense attention network (MsDA-Net) is proposed in this study to improve the reconstruction accuracy of lung ventilation and lesions based on EIT technology. As a direct estimation framework, MsDA-Net integrates dilated convolution, multi-scale dense connection, and attention mechanism to establish the end-to-end image reconstruction architecture with strong feature representation and reuse capabilities, aimed at fully exploiting deep nonlinear features from voltage measurements to improve the accuracy of lung EIT imaging. Both simulation and mapping model experiments are implemented to comprehensively evaluate the performance of MsDA-Net. Simulation results show that the lung contours and lesion structures can be effectively reconstructed by MsDA-Net. Compared with traditional imaging algorithms, the reconstructed images achieve significant improvement in visual quality and quantitative indicators. The average correlation coefficients (CC<sub>s</sub>), structure similarity index measures (SSIM<sub>s</sub>), root mean square errors (RMSE<sub>s</sub>), and peak signal-to-noise ratios (PSNR<sub>s</sub>) can reach 0.987 1, 0.903 5, 0.060 5, and 31.671 6 dB, respectively. The accuracy of MsDA-Net is similar to that of the frontier model (two-branch hyper-convolution U-Net and attention-based deep convolution neural network), which further confirms the effectiveness and progressiveness of MsDA-Net. Meanwhile, MsDA-Net shows excellent noise robustness, and the images can still maintain basic usability under 20 dB Gaussian white noise interference. Constructing the

收稿日期: 2025-10-20 Received Date: 2025-10-20

\* 基金项目: 国家自然科学基金(52275545)、广东省基础与应用基础研究基金(2023B1515120080)项目资助

mapping models within a circular domain based on lung CT images to validate the practicality of MsDA-Net, the results indicate that the shapes and sizes of targets within the field are more accurately reconstructed by MsDA-Net. As the conductivity distribution within the field becomes more complex, the reconstruction accuracy shows a decreasing trend. However, the average CCs, SSIMs, RMSEs, and PSNRs of the reconstructed images can still reach 0.943 1, 0.857 5, 0.109 6, and 19.392 1 dB, respectively.

**Keywords:** lung electrical impedance tomography; image reconstruction; multi-scale dense attention network

## 0 引 言

作为近几十年发展起来的一种基于电导率分布的可视化无损检测技术,电阻抗层析成像(electrical impedance tomography, EIT)的主要工作流程包括:激励电流注入、边界电压反馈测量及图像反演重建<sup>[1]</sup>。由于该技术具有非侵入、无辐射和实时成像等优点,被广泛应用于工业多相流检测<sup>[2-3]</sup>。此外,作为一种功能成像技术, EIT 技术在肺部监测方面也具有广阔的应用前景,如肺通气成像和肺阻塞监测<sup>[4-5]</sup>。

受软场特性影响,将 EIT 技术应用于肺部监测存在图像失真的问题,提高重建算法的精度是当前研究的热点<sup>[6]</sup>。传统基于模型算法通常将非线性逆问题转化为线性问题求解,并搭配正则化或先验提升稳定性<sup>[7]</sup>。然而,传统基于模型算法仅能提供最优解的近似,因此重建精度较低。受深度学习特征挖掘能力吸引,许多研究中将各种深度学习网络与 EIT 图像重建任务结合,提出了一系列基于学习算法提升图像重建精度。

主流的基于学习算法可以分为直接估计模型和两步估计模型。直接估计模型,即利用深度学习网络构建测量电压和电导率分布之间的非线性映射。Li 等<sup>[8]</sup>将堆叠式编码器与逻辑回归相结合,实现稳定的尺寸和形状重建。Wu 等<sup>[9]</sup>将视觉几何组模型与径向基函数网络结合并应用到肺部成像,胸廓变形和肺不张可以被有效重建。Wang 等<sup>[10]</sup>提出了双分支超卷积 U-Net 成像架构,引入可变形卷积、注意力机制和隐式卷积强化模型的空间信息表征能力,提供了更好的重建鲁棒性。Lou 等<sup>[11]</sup>提出了基于注意力的深度卷积神经网络,可实现不规则及低导电性区域的精准成像。两步估计模型,即利用深度学习网络去除伪影和噪声来优化初始重建图像。Ren 等<sup>[12]</sup>开发了两阶段深度学习架构,使用多级特征分析策略消除预重建图像中的建模误差。Zhang 等<sup>[13]</sup>设计了密集去噪网络,采用去噪块和密集块获取感兴趣区域内的清晰电导率分布特征。Li 等<sup>[14]</sup>提出了一种条件生成对抗网络用于优化传统算法图像,模型集成自注意力机制与残差结构实现肺部病变的精准重建。Ko 等<sup>[15]</sup>开发了由共享编码器和双解码器构成的深度学习模型,旨在独立分割肺部和心脏区域,模型具备良好的泛化能力。

尽管基于学习算法显著提升了 EIT 重建精度,但由

于呼吸过程的动态性,电压测量数据呈现复杂时变特性,增加了重建的复杂性。对于直接估计模型,学习低维测量数据到高维电导率分布的映射是困难的,增强模型的特征表征与复用能力是提升精度的关键;对于两步估计模型,分步优化策略会导致误差在传递过程中累积,模型精度严重依赖于初始重建图像的质量。

针对上述问题,前期工作中设计了一种密集注意力网络(dense attention network, DA-Net)获取肺部通气以及病变信息<sup>[16]</sup>。为了进一步提升模型特征表征与复用能力,在 DA-Net 的基础上提出了多尺度密集注意力网络(multi-scale dense attention network, MsDA-Net),主要创新点与贡献包括:1) MsDA-Net 创新地将扩张卷积、多尺度密集连接与注意力机制进行融合,构建了兼具强大特征提取能力、高效特征复用和精准特征筛选的端到端直接估计模型;2) 通过并行多尺度卷积提取多尺度特征,并借鉴密集连接机制强化特征在模型中的流动与复用;3) 引入注意力转换层自适应校准特征图,抑制背景噪声与非关键特征,捕获通气与病变关键特征。相较于 DA-Net, MsDA-Net 可实现更为精准的肺部成像。

## 1 方法论

肺部 EIT 检测流程如图 1 所示,将安全的激励电流顺序施加至相邻电极对,同时测量剩余相邻电极对之间的边界电压反馈,在反演算法的帮助下,可从电压测量值中重建肺部电导率变化。

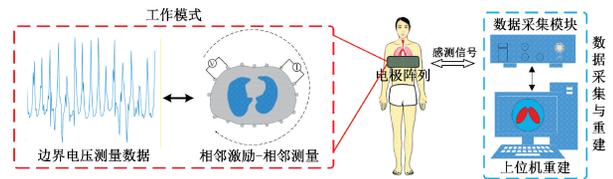


图 1 肺部 EIT 检测原理

Fig. 1 Principle of lung EIT detection

图像重建是求解层析成像逆问题的过程<sup>[17]</sup>,即利用边界测量电压求解电导率分布,如式(1)所示。

$$\mathbf{V} = \mathbf{N}(\boldsymbol{\sigma}) + \mathbf{e} \quad (1)$$

在逆问题求解过程中,通常需要将式(1)进行线性化转换<sup>[7]</sup>,如式(2)所示。

$$\mathbf{V} = \mathbf{J}\boldsymbol{\sigma} + \mathbf{e} \quad (2)$$

求解式(2)中逆问题的一种常用算法是将其转化为Tikhonov正则化问题<sup>[7]</sup>,如式(3)所示。

$$\tilde{\sigma} = \operatorname{argmin} \{ \| \mathbf{J}\sigma - \mathbf{V} \|^2 + \lambda \| \sigma \|^2 \} \quad (3)$$

式中:  $\mathbf{V}$  代表边界测量电压的差值;  $N$  代表非线性正问题算子;  $e$  代表测量噪声;  $\sigma$  代表对象和参考域之间的电导率变化;  $\mathbf{J}$  代表灵敏度矩阵;  $\lambda$  代表正则化参数。

### 1.1 EIT 图像重建模型 MsDA-Net

基于 EIT 技术的 MsDA-Net 肺部重建模型如图 2 所示,由扩张卷积模块、多尺度密集注意力模块和重建模块

组成,模块之间以层级递进方式实现特征提取与重建,特征提取采用一维卷积进行<sup>[18]</sup>。首先,扩张卷积模块中引入扩张卷积拓宽感受野,捕捉测量电压中的空间特征,为后续模块提供初级特征表达。随后,初级特征被输入至 3 个并行的密集注意力模块,利用多尺度卷积核提取多尺度特征,通过密集连接促进特征复用,引入注意力转移机制实现关键特征的筛选与增强。最后,多尺度输出特征拼接形成全局特征向量输入重建模块,将高维特征映射为电导率分布图像。

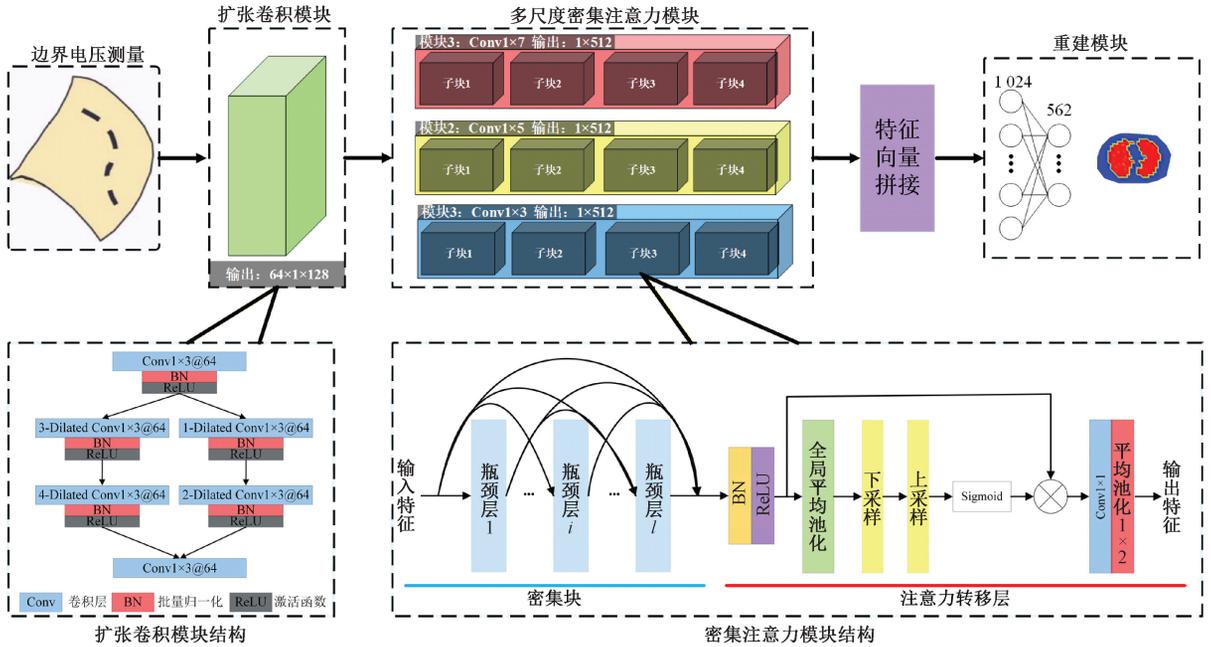


图2 MsDA-Net 结构

Fig. 2 MsDA-Net architecture

#### 1) 扩张卷积模块

扩张卷积模块结构如图 2 所示,首先,通过一个尺寸为  $1 \times 3$  卷积层获取初始图像特征;然后,使用合并运行单元进一步提取特征,输入特征分支通过两个扩张卷积层;最后,特征经过拼接输入到另一个尺寸为  $1 \times 3$  卷积层进行融合。为了充分覆盖输入图像的感受野,扩张卷积层的扩张率分别设置为 1、2、3 和 4<sup>[19]</sup>。

#### 2) 多尺度密集注意力模块

多尺度密集注意力模块的结构如图 2 所示,考虑到单尺度卷积特征提取能力不足,模块设置 3 个具有不同尺度卷积的密集注意力模块充分提取特征信息<sup>[20]</sup>。大尺度卷积核可以由小尺度卷积核叠加获得,因此密集注意力模块中使用小卷积核进行特征提取,尺度分别设置为  $1 \times 3$ 、 $1 \times 5$  和  $1 \times 7$ 。密集注意力模块由 4 个子块构成,子块包含一个密集块和一个注意力转换层,密集块中卷积层数量依次设置为 6、12、24 和 16。

密集块中利用密集连接构建先前层到所有后续层的特征传递以促进模型信息流和特征复用<sup>[21]</sup>,即网络的第  $l$  层接收所有先前卷积层的特征,如式(4)所示。

$$x_l = H_l([x_0, x_1, \dots, x_{l-1}]) \quad (4)$$

式中:  $[x_0, x_1, \dots, x_{l-1}]$  代表第 0 个卷积层至第  $l-1$  个卷积层中产生的特征图拼接,如果每次卷积操作  $H_l$  产生  $k$  个特征图,那么第  $x_l$  层有  $k_0 + k \times (l-1)$  个输入特征图,其中  $k_0$  是输入层中的特征通道数,  $k$  通常被称为增长率,设置为 32。

密集块中引入了瓶颈层 (BN-ReLU-Conv1x1-BN-ReLU-Conv1x3),输入特征图可以通过瓶颈层进行降维,从而降低计算复杂度。

特征信息可以划分为关键和非关键特征,MsDA-Net 中引入注意力转移层 (BN-ReLU-注意力单元-Conv1x1-平均池化  $1 \times 2$ ) 捕捉关键特征,特征图由转移层处理后通道数量减半,转移层中采用注意力单元来提高模型的表

征能力<sup>[22]</sup>,如式(5)所示。

$$\begin{cases} r_c = \gamma(H_v(\delta(H_D(g_p)))) \\ \hat{f}_c = Ap(Conv(r_c \times f_c)) \end{cases} \quad (5)$$

式中: $r_c$ 代表注意力权重因子; $g_p$ 代表全局平均池化操作; $H_D$ 和 $H_v$ 分别代表下采样和上采样操作; $\delta$ 和 $\gamma$ 分别表示激活函数 ReLU 和 Sigmoid; $f_c$ 代表注意力转移层的输入特征; $Ap$ 代表全局/局部池化操作; $Conv$ 代表尺寸为 $1 \times 1$ 的卷积操作; $\hat{f}_c$ 代表转移层的输出特征。

### 3) 重建模块

密集注意力模块中第4个子块的注意力转换层具有不同的配置,引入全局平均池化操作获取全局特征向量,全局特征向量经过拼接后被输入至重建模块进行肺部图像重建<sup>[23]</sup>。重建模块结构如图2所示,包含两个全连接层,分别包含1024和562个神经元。

## 1.2 数据集构建

基于 COMSOL Multiphysics 构建二维 EIT 胸腔数据集用于模型训练,数据集构建流程如图3所示。选取紧邻乳头正下方第5肋骨所在位置的 CT 切片,重点关注距离中心切片 8 cm 垂直范围内的切片。从选定的切片中提取肺部与胸腔轮廓后导入 COMSOL Multiphysics 软件进行建模。随后,在胸腔模型边缘设置 16 个均匀分布的电极,并在肺部轮廓内添加具有不同尺寸与形状的病灶模拟肿瘤及水肿病变,病灶随机分布于肺部区域。模型中设定的电导率值为肺部 0.09 S/m,病灶与背景介质均为 0.3 S/m。基于相邻激励-相邻测量模式进行数据采集,涉及稳态条件下的有限元正问题求解,生成自适应网格以确保仿真精度。基于 $32 \times 32$ 分辨率生成仿真数据,获得包含 208 个元素的电压测量值(模型输入)及包含 562 个元素的真实电导率(期望输出)。基于固定胸腔轮廓共生 3600 组样本,其中包含训练集 3240 组与测试集 360 组。

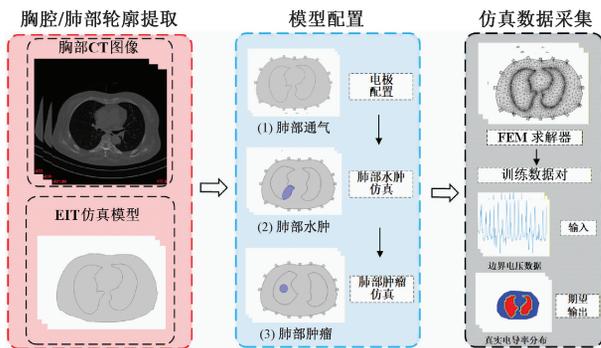


图3 数据集构建

Fig. 3 Construction of dataset

## 1.3 损失函数与模型训练

基于 MsDA-Net 的肺部重建属于回归任务,均方误差

是一种良好的相似性度量指标,重建电导率分布和真实电导率分布之间的均方误差可以作为损失函数用于更新模型的参数,如式(6)所示。

$$l(\theta) = \frac{1}{2N} \sum_{i=1}^N \| R(\tilde{s}_i; \theta) - (\tilde{s}_i - s_i) \|_F^2 \quad (6)$$

式中: $l$ 代表均方误差损失; $R$ 代表 MsDA-Net 模型; $\tilde{s}_i$ 和 $s_i$ 分别代表重建中间结果和标签数据; $\theta$ 代表模型的可训练权值。

MsDA-Net 模型采用 PyTorch-GPU 框架构建,并利用 NVIDIA RTX 3060 加速模型训练。训练批次和周期分别设置为 24 和 400,选择 Adam 优化器更新参数,每 100 个训练周期,学习率从 $10^{-2}$ 呈指数级下降到 $10^{-5}$ 。

## 2 结果讨论与分析

4 种基于学习算法(1D-CNN<sup>[24]</sup>、ResNet50<sup>[25]</sup>、ADCN-Net<sup>[11]</sup>及 DHU-Net<sup>[10]</sup>)被用作性能对照。1D-CNN 是 EIT 重建中广泛采用的架构,可作为经典基准模型;ResNet50 作为改进架构,引入残差结构有效提升了深层特征提取能力;ADCN-Net 和 DHU-Net 则属于先进的重建模型,引入密集注意力机制及多分支学习提升成像精度,可用于论证 MsDA-Net 的竞争力。此外,两种常用的传统重建算法也被用于对照,分别是 Tikhonov 正则化(Tikhonov regularization, TR)和总变差(total variation, TV)算法。基于仿真与实验评估 MsDA-Net 的精度、鲁棒性和实用性,同时采用以下指标对图像进行多维度量化:均方根误差(root mean square errors, RMSEs)和峰值信噪比(peak signal-to-noise ratios, PSNRs)衡量模型数值精度;结构相似性指数(structure similarity index measures, SSIMs)和相关系数(correlation coefficients, CCs)评估模型相关性 with 相似性,如式(7)所示。

$$\begin{cases} CCs = \frac{\sum_{i=1}^n (\tilde{\sigma}_i - m_{\tilde{\sigma}})(\sigma_i - m_{\sigma})}{\sqrt{\sum_{i=1}^n (\tilde{\sigma}_i - m_{\tilde{\sigma}})^2} \sqrt{\sum_{i=1}^n (\sigma_i - m_{\sigma})^2}} \\ SSIMs = \frac{(2m_{\tilde{\sigma}}m_{\sigma} + C_1)(2v_{\tilde{\sigma}\tilde{\sigma}} + C_2)}{(m_{\tilde{\sigma}}^2 + m_{\sigma}^2 + C_1)(\gamma_{\tilde{\sigma}\tilde{\sigma}} + \gamma_{\sigma\sigma} + C_2)} \\ RMSEs = \sqrt{\frac{1}{n} \sum_{i=1}^n (\tilde{\sigma}_i - \sigma_i)^2} \\ PSNRs = 10 \cdot \log_{10} \left( \frac{1}{n \sum_{i=1}^n (\tilde{\sigma}_i - \sigma_i)^2} \right) \end{cases} \quad (7)$$

式中: $\tilde{\sigma}_i$ 和 $\sigma_i$ 分别代表重建电导率元素和真实电导率元素; $m_{\tilde{\sigma}}$ 和 $m_{\sigma}$ 分别代表真实电导率和重建电导率的平均值、标准偏差和协方差; $C_1$ 和 $C_2$ 代表常数。

### 2.1 仿真测试

为了验证 MsDA-Net 的成像精度,随机挑选测试集中的 50 组样本进行重建,重建图像的评价指标如表 1 所示。相较于传统算法,基于学习算法重建图像的指标得到显著改善,平均 CCs 从 < 0.71 (TV) 增加至 > 0.98 (DHU-Net);平均 SSIMs 从 < 0.27 (TR) 增加至 > 0.90 (MsDA-Net);平均 RMSEs 从 > 0.34 (TV) 降低至 < 0.07 (MsDA-Net);平均 PSNRs 从 < 7.44 dB (TR) 增加至 > 31.67 dB (MsDA-Net)。ADCN-Net、DHU-Net 以及 MsDA-Net 重建图像的评价指标接近,对于平均 CCs, MsDA-Net(0.987 1)略低于 DHU-Net(0.988 5),但在其余 3 项指标上取得了最优性能,具有更高的重建精度。

表 1 仿真图像的精度

Table 1 Accuracy of simulated images

算法	平均 CCs	平均 SSIMs	平均 RMSEs	平均 PSNRs/dB
TR	0.703 2	<b>0.265 9</b>	<b>0.342 1</b>	<b>7.432 4</b>
TV	<b>0.703 6</b>	0.379 5	0.310 4	8.585 1
1D-CNN	0.921 3	0.701 3	0.108 9	17.766 4
ResNet50	0.950 7	0.825 6	0.089 4	23.439 7
ADCN-Net	0.982 3	0.891 6	0.065 6	30.833 7
DHU-Net	<b>0.988 5</b>	0.900 7	0.063 1	31.501 8
MsDA-Net	0.987 1	<b>0.903 5</b>	<b>0.060 5</b>	<b>31.671 6</b>

利用特定 5 组样本直观展示模型的成像性能,第 1 和第 2 个样本与肺通气相关,第 3 和第 4 个样本代表肺水肿,第 5 个样本表征肺部肿瘤,仿真成像结果如图 4 所示。

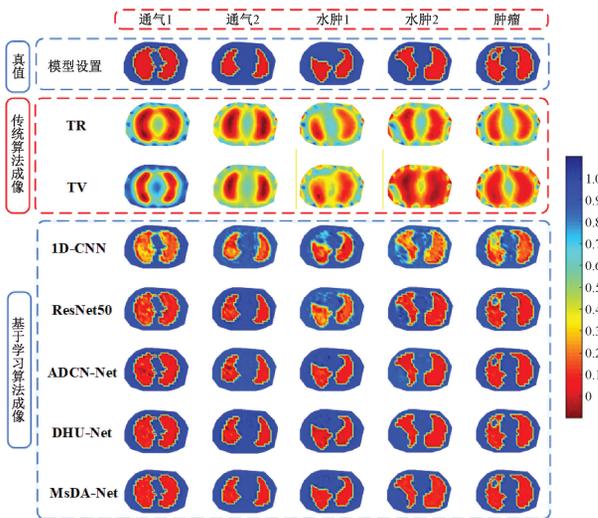


图 4 仿真样本重建图像

Fig. 4 Reconstructed images of simulated samples

传统算法重建图像中存在严重的伪影,肺部轮廓模糊且病变不能被有效重建,重建电导率分布无法准确反映实际电导率分布。基于学习算法图像中均可观察到精度的显著提升,与 1D-CNN 和 ResNet50 相比,ADCN-Net、DHU-Net 以及 MsDA-Net 通过引入更高效的架构进一步提高了成像精度,可以实现病灶结构和肺部轮廓的精准重建。与 ADCN-Net 相比,DHU-Net 和 MsDA-Net 图像中的伪影进一步减少,视觉效果进一步提升。成像结果与定量分析的结果保持一致,表明基于学习的算法可以有效提升成像精度,同时也验证了 MsDA-Net 模型设计的有效性 with 先进性。

### 2.2 噪声鲁棒性测试

仿真测试中使用的 MsDA-Net 在无噪声数据集上进行训练,因此开展噪声鲁棒性测试是必要的,鲁棒性通过在测试集中添加不同信噪比 (signal-to-noise ratios, SNRs) 的高斯白噪声验证。

噪声鲁棒性的测试结果如图 5 所示,随着 SNRs 降低,重建图像中的伪影逐渐增加,且肺部轮廓和病变结构逐渐变的模糊。当 SNRs 为 20 dB 时,重建图像的精度急剧下降,通气样本图像出现了类似于肿瘤病变的电导率区域,表明噪声的加入使得原始电压数据包含的电导率信息被破坏,使其趋近于肿瘤的电压数据。

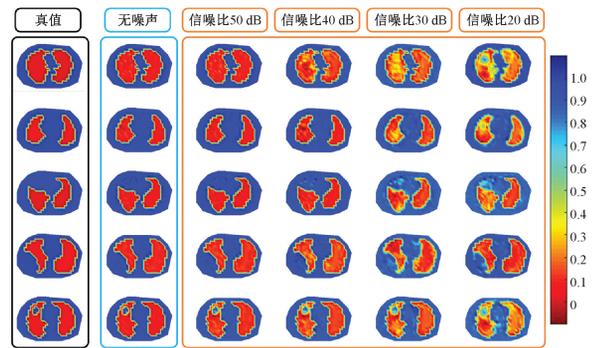


图 5 噪声样本重建图像

Fig. 5 Reconstructed image of noisy samples

噪声样本图像的评价指标如表 2 所示,当 SNRs 从无噪声条件下降至 40 dB 时,重建图像的精度略微降低。当 SNRs 为 30 dB 时,PSNRs 指标出现了显著降低,但 CCs 和 SSIMs 与 RMSEs 指标仍然呈现缓慢且可控地下降,这表明在中等噪声水平下模型重建图像的数值精度有所损失,但其整体结构和分布特征仍能得到较高程度的保留。当 SNRs 进一步降低至 20 dB 的极端条件时,所有评价指标均呈现显著下降。此时,重建图像的 CCs 高于 0.92, RMSEs 低于 0.25, SSIMs 高于 0.67,重建结果保持了基本可用性。综上,MsDA-Net 具有良好的噪声鲁棒性,足以处理常见的硬件系统噪声。

表 2 噪声重建图像的精度  
Table 2 Accuracy of noisy images

样本	指标	无噪声	50 dB	40 dB	30 dB	20 dB
通气 1	CCs	0.992 9	0.988 3	0.981 6	0.971 3	0.934 9
	SSIMs	0.928 2	0.893 1	0.875 6	0.760 3	0.683 1
	RMSEs	0.051 1	0.058 8	0.070 3	0.121 4	0.220 5
	PSNRs/dB	32.277 2	29.226 2	28.435 1	20.424 5	<b>15.999 1</b>
通气 2	CCs	0.987 2	0.985 1	0.979 2	0.966 9	0.932 3
	SSIMs	0.914 7	0.881 1	0.849 1	0.748 9	<b>0.671 2</b>
	RMSEs	0.061 7	0.077 6	0.107 1	0.145 2	0.205 7
	PSNRs/dB	35.190 8	31.137 4	29.223 4	19.147 2	16.361 9
水肿 1	CCs	<b>0.986 7</b>	0.982 4	0.978 2	0.970 4	0.944 3
	SSIMs	0.889 4	0.844 0	0.810 8	0.779 8	0.710 7
	RMSEs	0.067 5	0.073 7	0.110 6	0.144 2	0.197 7
	PSNRs/dB	31.973 1	28.923 5	27.619 4	20.253 2	16.645 6
水肿 2	CCs	0.987 5	0.983 3	0.977 9	0.971 6	0.943 2
	SSIMs	<b>0.884 7</b>	0.836 6	0.805 2	0.786 1	0.719 1
	RMSEs	<b>0.070 5</b>	0.081 5	0.098 7	0.154 2	0.244 9
	PSNRs/dB	<b>31.194 9</b>	27.425 9	25.665 7	20.261 1	17.219 1
肿瘤	CCs	0.990 2	0.985 1	0.975 8	0.964 3	<b>0.924 6</b>
	SSIMs	0.904 4	0.879 5	0.851 6	0.764 9	0.703 7
	RMSEs	0.058 3	0.085 5	0.105 5	0.163 2	<b>0.248 4</b>
	PSNRs/dB	31.645 7	28.802 1	26.293 5	<b>17.794 2</b>	16.593 5

2.3 消融实验

为了验证 MsDA-Net 模块设计的合理性,开展消融实验系统评估各模块对模型重建性能的贡献。此外,增长率  $k$  作为重要超参数,其取值对重建性能的影响也被进一步验证。

1) 模块验证

MsDA-Net 是在 DenseNet<sup>[21]</sup> 的基础上引入了注意力机制和多尺度特征提取构建而成。为了评估各模块对于图像重建的贡献,分别测试了 DenseNet、DA-Net<sup>[16]</sup> 以及 MsDA-Net 的重建表现,重建图像如图 6 所示。对于病变样本,DenseNet 重建图像中病变位置存在明显伪影,且病变区域的边界模糊。引入注意力机制的 DA-Net 有效减轻了部分伪影,病变区域的轮廓更贴近真值。融合了多尺度特征提取的 MsDA-Net 重建图像中电导率分布的梯度变化也更贴合实际电导率分布。

2) 参数选择

增长率  $k$  作为 MsDA-Net 的重要超参数,其正确取值对于平衡模型重建时间,精度及学习效率具有重要意义,为了获取最优增长率,比较了  $k$  分别取值为 16、

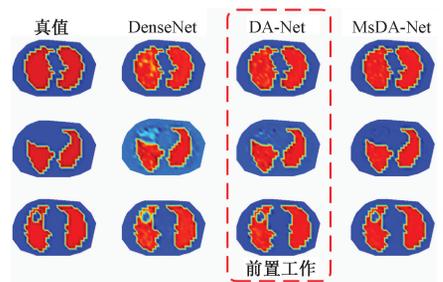


图 6 模块验证结果

Fig. 6 Result of module verification

24、32 和 48 时,MsDA-Net 的精度。不同增长率下的重建精度如表 3 所示,随着  $k$  的增加,模型重建精度虽整体提升,但涨幅呈现逐渐收窄的趋势,这意味着  $k$  增大到一定程度后,精度提升的收益显著下降。综合精度与计算效率,最终选择将  $k$  取值为 32,此时重建图像的指标接近  $k$  取值为 40 时的水平,且计算复杂度更低,能够在保证高精度重建的同时,兼顾更优的学习成本。

表3 不同增长率下的重建精度

Table 3 Reconstruction accuracy at different growth rates

增长率 $k$	平均 CCs	平均 SSIMs	平均 RMSEs	平均 PSNRs/dB
16	0.975 4	0.851 9	0.080 5	27.432 7
24	0.981 3	0.889 7	0.067 9	30.311 9
32	0.987 1	0.903 5	0.060 5	31.671 6
40	0.988 9	0.906 2	0.059 1	31.873 1

## 2.4 实验测试

实验室条件下获取大量肺部实测数据用于模型训练是困难的,尤其是获取病变样本及其对应的真实电导率分布。因此,本研究构建了圆形域中的映射模型模拟不同的肺状态,以验证所提出算法的实用性。

### 1) 实验装置

实验装置如图7所示,由圆形水槽、数据采集处理单元以及上位机构成。首先,控制单元输出选通信号配置开关选通阵列的激励通道和测量通道;其次,幅值为1 mA、频率为50 kHz的激励电流通过选定的激励通道注入测量域;然后,测量通道的输出电压通过数据采集处理单元转换为高质量的电压测量值,并存储在先进先出缓冲器中;最后,完成一帧测量数据采集后,测量数据通过串口传输到上位机进行图像重建。

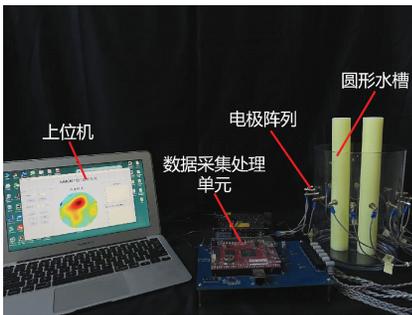


图7 EIT实验装置

Fig. 7 EIT experimental setup

### 2) 模型训练

针对实验阶段的成像需求,额外生成了仿真水槽数据集用于模型训练,模型如图8所示。仿真参数与实验装置参数严格保持一致,通过改变棒的位置、数量与尺寸,共生成9 000组样本数据。背景电导率设置为0.04 S/m,而棒的电导率设置为 $10^{-12}$  S/m。棒的半径随机设置为测量域半径(93.5 mm)的5.4%~27.02%。每个样本均包含电压测量值(208个元素)与真实电导率分布(812个元素)。

由于硬件系统中的噪声难以去除,为了提高模型对实验样本的鲁棒性,在原始数据集的基础上构建了一个用于模型训练的噪声训练集,该训练集通过将噪声样本

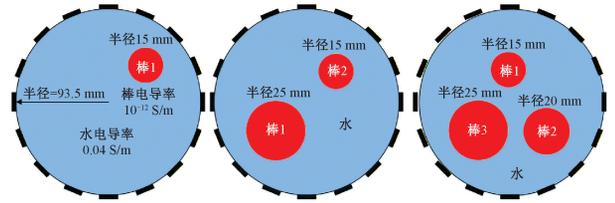


图8 圆形水槽仿真数据集

Fig. 8 Simulation dataset of circular flume

(27 000组)添加到原始训练集(9 000组)中获得,噪声样本的信噪比设置为45、50和55 dB。

### 3) 映射模型成像测试

映射模型中的分布参考了肺部CT图像,将不同数量和尺寸的尼龙棒放置在圆形域中,以模拟不同的肺部状态,包括对称和非对称分布。

实验重建结果如图9所示,随着测量域内的分布复杂度增加,TR算法图像中的伪影逐渐增多,重建电导率分布呈现连续特性,而原始分布是非连续的。相较于TR算法,TV算法重建图像中的伪影较少,可以更准确地反映棒的位置和尺寸。对于简单分布,基于学习算法均能显著减少重建图像中的伪影,且重建图像中棒的形状与尺寸与其真实形状与尺寸高度吻合。对于复杂分布,1D-CNN和ResNet50图像存在明显伪影,模型5中心的棒被错误的重建为背景介质,表明模型在准确捕捉复杂电导率分布方面仍存在局限性。虽然ADCN-Net一定程度克服此类错误,但是复杂分布重建图像中的伪影较多,棒的形状和尺寸重建不够精确。与1D-CNN、ResNet50和ADCN-Net相比,DHU-Net与MsDA-Net

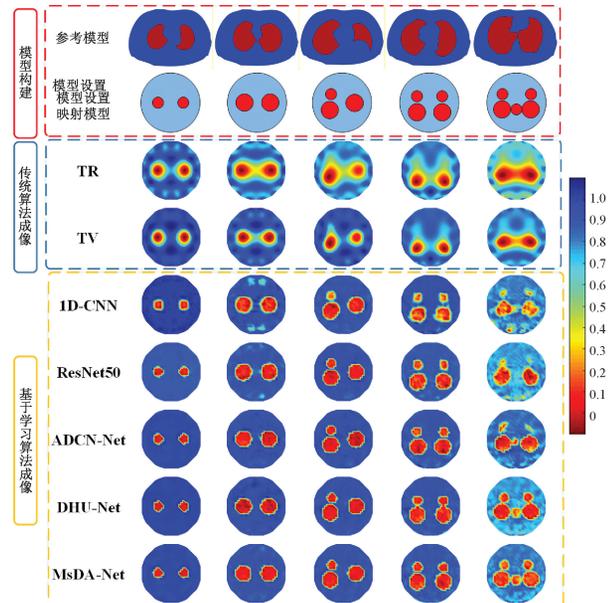


图9 实验样本重建图像

Fig. 9 Reconstructed images of experimental samples

重建图像的视觉效果更接近真实分布,伪影进一步减少,棒的轮廓重建更精细。对于模型 5, MsDA-Net 的精度略高于 DHU-Net。

实验重建图像的平均 CCs、SSIMs、RMSEs 和 PSNRs 如表 4 所示。可以看出基于学习算法,特别是 ADCN-Net、DHU-Net 和 MsDA-Net 在重建精度上显著优于传统 TR 与 TV 算法,相较于 ADCN-Net、DHU-Net 和 MsDA-Net 在 4 项指标上均处于领先地位。MsDA-Net 具有最低 RMSEs(0.109 6)和最高 SSIMs(0.857 5),展现了良好的重建误差控制与结构保持能力,进一步验证了 MsDA-Net 模型设计的有效性与先进性。

表 4 实验图像的精度

Table 4 Accuracy of experimental images

算法	平均 CCs	平均 SSIMs	平均 RMSEs	平均 PSNRs/dB
TR	0.748 7	0.386 8	0.320 2	9.581 4
TV	0.799 3	0.425 8	0.277 2	11.005 8
1D-CNN	0.871 4	0.698 7	0.222 4	13.407 3
ResNet50	0.886 5	0.770 1	0.446 6	15.089 2
ADCN-Net	0.930 7	0.840 7	0.131 5	18.223 1
DHU-Net	0.944 2	0.854 3	0.110 2	19.571 7
MsDA-Net	0.943 1	0.857 5	0.109 6	19.382 1

### 3 结 论

本研究针对 EIT 技术在呼吸动态过程中存在的图像失真问题,提出了一种名为 MsDA-Net 的肺部重建模型。通过引入密集连接、多尺度特征提取与注意力机制, MsDA-Net 能够有效捕获电压测量数据中的特征信息用于图像重建。仿真与实验结果表明所提出方法可以显著提升肺部轮廓与病变区域的成像精度,尤其在复杂分布和噪声环境下仍保持较高的重建质量与鲁棒性,为肺部成像提供了一种新的高精度方案,具有一定的理论价值与临床应用前景。

然而,本研究中提出的方法和实验结果也存在一定的局限性。首先,胸部轮廓会受到呼吸运动的影响而动态变化,但是本研究仅关注固定胸部轮廓下的图像重建;其次,算法的实验验证通过水槽构建映射样本实现,并没有进行实际人体的肺部成像测试。在未来研究中,将考虑胸部轮廓差异性,完善数据集,评估算法对于变化胸腔轮廓的重建表现,同时开展人体肺部实验,验证算法在实际监测场景中的实用性。此外,迁

移学习模型,生成式模型将被设计用于进一步提升实验样本的成像精度。

### 参考文献

- [1] 胡筱敏,张帅福,陈攀峰,等. 电阻抗层析成像技术在肺部疾病诊断和监测中的应用[J]. 生物医学工程学杂志, 2025, 42(2): 389-395.  
HU X M, ZHANG SH F, CHEN P F, et al. Application of electrical impedance tomography in diagnosis and monitoring of pulmonary diseases[J]. Journal of Biomedical Engineering, 2025, 42(2): 389-395.
- [2] FANG X T, JIANG Y D, JI H F, et al. A new CCERT system with shielding for gas-liquid two-phase flow[J]. IEEE Transactions on Industrial Electronics, 2023, 71(4): 4241-4251.
- [3] XIE Y D, LIU F L, SUN J T, et al. Measurement of gas fraction in gas-liquid dispersed bubbly flow with EMAT array and EIT sensor[J]. IEEE Transactions on Instrumentation and Measurement, 2024, 73: 1-10.
- [4] 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[J]. 生物化学与生物物理进展, 2025, 52(7): 1866-1877.  
LI F, CHEN B, WU Y, et al. Research on a COPD diagnosis method based on electrical impedance tomography imaging[J]. Progress in Biochemistry and Biophysics, 2025, 52(7): 1866-1877.
- [5] 李展,招展奇,温若谿,等. 电阻抗断层成像技术在肺通气功能评估中的研究和应用[J]. 解放军医学院学报, 2024, 45(11): 1191-1196.  
LI ZH, ZHAO ZH Q, WEN R X, et al. Review on research and application of electrical impedance tomography in pulmonary ventilation function assessment[J]. Academic Journal of Chinese PLA Medical School, 2024, 45(11): 1191-1196.
- [6] 丁明亮,宋娟,赵树飞,等. 基于八激励模式数据融合的电阻抗成像优化算法[J]. 电子测量与仪器学报, 2025, 39(6): 284-292.  
DING M L, SONG J, ZHAO SH F, et al. Electrical impedance tomography imaging algorithm based on eight-mode excitation mode data fusion[J]. Journal of Electronic Measurement and Instrumentation, 2025, 39(6): 284-292.
- [7] WANG Q, WANG J M, LI X Y, et al. Exploring

- respiratory motion tracking through electrical impedance tomography(EIT)[J]. *IEEE Transactions on Instrumentation and Measurement*, 2021, 70: 1-12.
- [ 8 ] LI F, TAN CH, 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 ] WU Y, CHEN B, LIU K, et al. Shape reconstruction with multiphase conductivity for electrical impedance tomography using improved convolutional neural network method[J]. *IEEE Sensors Journal*, 2021, 21(7): 9277-9287.
- [10] WANG Z CH, LI X Y, SUN Y K, et al. Electrical impedance tomography deep imaging with dual-branch U-Net based on deformable convolution and hyperconvolution[J]. *IEEE Transactions on Instrumentation and Measurement*, 2024, 73: 1-16.
- [11] LOU Y J, YANG K, SHI Y Y, et al. An attention-based deep convolutional neural network for brain imaging with electrical impedance tomography[J]. *IEEE Transactions on Instrumentation and Measurement*, 2025, 74: 1-11.
- [12] REN SH J, SUN K, TAN CH, et al. A two-stage deep learning method for robust shape reconstruction with electrical impedance tomography[J]. *IEEE Transactions on Instrumentation and Measurement*, 2019, 69(7): 4887-4897.
- [13] ZHANG X Y, WANG Z CH, FU R, et al. V-shaped dense denoising convolutional neural network for electrical impedance tomography[J]. *IEEE Transactions on Instrumentation and Measurement*, 2022, 71: 1-14.
- [14] LI X Y, ZHANG R ZH, WANG Q, et al. SAR-CGAN: Improved generative adversarial network for EIT reconstruction of lung diseases[J]. *Biomedical Signal Processing and Control*, 2023, 81: 104421.
- [15] KO Y F, LIN Y D, SU P L. Reconstruction of heart-related imaging from lung electrical impedance tomography using semi-siamese U-Net[J]. *Current Medical Imaging*, 2025, 21(1): E15734056408077.
- [16] ZHANG H Y, WANG Q, LI N. DA-Net: A dense attention reconstruction network for lung electrical impedance tomography(EIT)[J]. *IEEE Internet of Things Journal*, 2024, 11(12): 22107-22115.
- [17] 王世伟, 王超, 郭琪, 等. 用于超音速分离流场参数测量的 ECT 图像重建算法优化[J]. *仪器仪表学报*, 2024, 45(9): 111-119.
- WANG SH W, WANG CH, GUO Q, et al. Optimization of ECT image reconstruction algorithm for flow field measurement of supersonic separator[J]. *Chinese Journal of Scientific Instrument*, 2024, 45(9): 111-119.
- [18] TAN ZH K, ZHANG J W, LIU B, et al. A lightweight air-conditioning monitoring method based on periodic statistical features and one-dimensional convolution[C]. 2024 5th International Conference on Computer Vision, Image and Deep Learning, 2024: 1522-1527.
- [19] YANG J H, LI AN Q, QIAN J X, et al. A hyperspectral image classification method based on pyramid feature extraction with deformable-dilated convolution[J]. *IEEE Geoscience and Remote Sensing Letters*, 2023, 21: 1-5.
- [20] 马敏, 梁雅蓉. 基于多尺度自适应特征聚合网络的 ECT 图像重建[J]. *仪器仪表学报*, 2023, 44(6): 264-272.
- MA M, LIANG Y R. ECT image reconstruction based on multi-scale adaptive feature aggregation network [J]. *Chinese Journal of Scientific Instrument*, 2023, 44(6): 264-272.
- [21] SHI Y Y, LOU Y J, WANG M, et al. Densely connected convolutional neural network-based invalid data compensation for brain electrical impedance tomography[J]. *IEEE Transactions on Computational Imaging*, 2024, 10: 143-153.
- [22] ANWAR S, BARNES N. Real image denoising with feature attention [C]. 2019 IEEE/CVF International Conference on Computer Vision, 2019: 3155-3164.
- [23] LIU R N, WANG F, YANG B Y, et al. Multiscale kernel based residual convolutional neural network for motor fault diagnosis under nonstationary conditions[J]. *IEEE Transactions on Industrial Informatics*, 2019, 16(6): 3797-3806.
- [24] REN J K, TAN CH, LIANG G H, et al. Image reconstruction for electrical resistance tomography using convolutional neural network and visual geometry group[C]. 2024 43rd Chinese Control Conference, 2024: 3351-3356.

- [25] HE K M, ZHANG X Y, REN SH Q, et al. Identity mappings in deep residual networks[C]. European Conference on Computer Vision, 2016: 630-645.

### 作者简介



张函瑜,2019年于聊城大学获得学士学位,2022年于天津工业大学获得硕士学位,目前在西北工业大学攻读博士学位,主要研究方向为电阻抗层析成像、深度学习与柔性传感。

E-mail: zhanghanyutg@163.com

**Zhang Hanyu** received his B.Sc. degree from Liaocheng University in 2019, and his M.Sc. degree from Tiangong University in 2022. He is currently pursuing his Ph. D. degree at Northwestern Polytechnical University. His main research interests include electrical impedance tomography, deep learning, and flexible sensing.



李楠(通信作者),2004年于西安电子科技大学获得学士学位,2008年于曼彻斯特大学获得硕士学位,2010年于西安电子科技大学获得博士学位,现为西安电子科技大学高性能电子装备机电集成制造全国重点实验室教授,主要研究方向为无损检测与评估、传感器设计与自动控制与过程层析成像。

E-mail: nan.li@hotmail.co.uk

**Li Nan** (Corresponding author) received his B.Sc. degree from Xidian University in 2004, his M.Sc. degree from the University of Manchester in 2008, and his Ph. D. degree from Xidian University in 2010. He is currently a professor with the State Key Laboratory of Electromechanical Integrated Manufacturing of High-performance Electronic Equipments at Xidian University. His main research interests include nondestructive testing and evaluation, sensor design and automatic control, and process tomography.