

DOI: 10.13382/j.jemi.B2508564

多尺度注意力与 Transformer 改进的 U-Net 高质量电阻抗层析成像方法*

李秀艳^{1,2} 吴文旭^{1,2} 王琦^{1,2}

(1. 天津工业大学电子与信息工程学院 天津 300387; 2. 天津市光电检测技术与系统重点实验室 天津 300387)

摘要: 由于现有卷积网络固有的局部感受野造成的复杂特征表达局限性, 忽略全局分布信息所造成的内含物电导率参数重建不准确和形状失真, 限制了电阻抗层析成像技术在实际中的应用。提出了一种基于注意力与视觉 Transformer 混合的端到端深度学习方法 (HiRef-EIT)。该方法以 U-Net 为骨干网络, 采用层级特征堆叠构建多尺度空间信息表达; 设计了多头空间衰减注意力 (MHRA) 模块作为编码器, 降低计算复杂度的同时保持全局信息建模能力; 引入基于通道注意力和坐标注意力并行的瓶颈连接模块, 分别从通道层面和空间层面构建电导率分布和内含物形状的潜在表示, 采用基于交叉注意力的解码器单元实现全局-局部信息的多尺度融合, 增强模型的特征表达能力。HiRef-EIT 通过大量的仿真数据训练获得最优模型参数, 并在多样化复杂形状和肺部仿真模型进行了实验验证。定量评估指标表明, 该方法在重建图像中的均方根误差 (RMSE) 结果为 6.028, 结构相似性指数 (SSIM) 结果为 0.956, 可视化结果表明重建结果和真实分布具有很好的一致性。实验结果表明, 提出的 HiRef-EIT 展现出了良好的鲁棒性和泛化能力, 相较于传统的卷积网络成像模型, 该方法为 EIT 在医学诊断、工业过程监测等领域的应用提供了高质量成像解决方案。

关键词: 电阻抗层析成像; 多头空间衰减注意力; 通道注意力; 坐标注意力; 多尺度融合

中图分类号: R318; TH701; TN911.7 **文献标识码:** A **国家标准学科分类代码:** 460.40

High-quality electrical impedance tomography method based on multi-scale attention and transformer-enhanced U-Net

Li Xiuyan^{1,2} Wu Wenxu^{1,2} Wang Qi^{1,2}

(1. School of Electronics & Information Engineering, Tiangong University, Tianjin 300387, China;

2. Tianjin Key Laboratory of Optoelectronic Detection Technology and System, Tianjin 300387, China)

Abstract: Due to the inherent local receptive field limitations of conventional convolutional networks, the representation of complex features in electrical impedance tomography (EIT) is often restricted, leading to inaccurate reconstruction of inclusion conductivity parameters and shape distortion caused by the neglect of global distribution information. To address these challenges, this paper proposes an end-to-end deep learning framework, HiRef-EIT, which integrates attention mechanisms and vision Transformers. Built upon a U-Net backbone, the proposed method employs hierarchical feature stacking to construct a multi-scale latent space representation. A multi-head spatial reduction attention (MHRA) module is designed to reduce computational complexity while preserving global modeling capability. Additionally, a skip bottleneck module combining channel attention and coordinate attention in parallel is introduced to capture the latent representations of conductivity distribution and inclusion shape from both the channel and spatial perspectives. A decoder unit based on cross-attention is employed to achieve global-local multi-scale feature fusion, thereby enhancing the model's representation capacity. HiRef-EIT is trained using a large volume of simulated data to obtain optimal model parameters, and is experimentally validated on diverse complex-shaped phantoms and lung simulation models. Quantitative evaluation metrics demonstrate that the proposed method achieves a root mean square error (RMSE) of 6.028 and a structural similarity index (SSIM) of 0.956, with visual results showing strong consistency with the ground truth distributions and boundaries. The experimental results reveal that HiRef-EIT exhibits excellent robustness and generalization. Compared with traditional convolutional imaging models, the proposed method offers a high-quality

收稿日期: 2025-07-15 Received Date: 2025-07-15

* 基金项目: 天津市自然科学基金重点项目 (24JCZDJC00790)、国家自然科学基金 (61872269) 项目资助

imaging solution for EIT, thus holding significant theoretical and practical value for applications in medical diagnostics and industrial process monitoring.

Keywords: electrical impedance tomography; multi-head spatial reduction attention; channel attention; coordinate attention; multi-scale fusion

0 引言

电阻抗层析成像 (electrical impedance tomography, EIT) 作为一种新兴的电学模态成像技术, 使用高频低幅值的交变电流对观测区域电场进行调制, 测量响应在其他传感电极上的电压信号, 并通过合适的图像重建算法实现电导率参数分布可视化。由于其无电离辐射、低功耗、具有结构功能同时可视化等优势, 被广泛应用于医学、工业、地质勘探等诸多场景^[1-2]。然而, 由于调制电场自身的“软场”特性以及其有限的传感器上的测量信号, EIT 逆问题通常表现出显著的非线性和病态性^[3]。因此, 重建图像的空间分辨率较低, 且测量信号中的微小扰动可能会导致结果存在明显的误差。为了克服上述问题, 通常将逆问题转化为一个最小二乘优化问题, 引入包含先验信息的正则化罚函数来约束逆问题的解空间, 如混合正则化方法^[4-5]、Laplacian 正则化^[6]、组稀疏先验^[7]等。通过改进的优化迭代算法, 包括 Land-weber 算法^[8]、ISTA 算法^[9]等, 获得局部最优解。另外, 基于 Bayesian 统计先验^[10]、D-bar^[11]、形状驱动^[12]等方法, 在形状重建方面获得了改善。基于灵敏度先验的迭代正则化求解框架, 在处理正问题模型和边界测量扰动时存在较高的敏感性。同时, 为了应对模型中的不确定性 (如未知的电极位置、边界形状或接触阻抗), 该框架通常依赖于复杂的建模方法。

随着新兴的深度学习在计算机视觉领域获得的大量成功案例, 一些研究者提出了基于深度学习的图像重建算法^[13], 并在电学层析成像任务中被使用^[14]。例如: Hamilton 等^[15]提出 Deep D-Bar 方法用于肺部 EIT 图像重建, 王子辰等^[16]提出基于残差连接和注意力瓶颈模块的 ResAttU-Net 用于高质量 EIT 成像, Zhang 等^[17]基于稠密连接方式提出了双分支 HybridDenseUNet 用于多相电导率重建, Wang 等^[18]基于可变形卷积和超卷积模块提出 DHU-Net 用于复杂形状重建, 袁晶晶等^[19]基于使用金字塔池化框架结合多尺度语义增强方法提出 S-PNet 实现触觉电阻抗成像, AMEEN 等^[20]基于空间、频率和截断频率多尺度特征提出 TSS-ConvNet, 从空间域和频率域实现低质量 EIT 图像增强, 王琦等^[21]提出 MAT-UNet 方法, 使用卷积神经网络 (convolutional neural network, CNN) 和通道注意力单元实现高分辨率 EIT 重建, Liu 等^[22]基于图数据结构提出无监督 GraphEIT 方法用于 EIT 图像重

建, 闫孝姮等^[23]基于多尺度注意力与残差脉冲神经单元提出 MAR-SNN 方法, 实现接地网故障诊断与可视化。然而, 上述提及的方法通常采用具有单一感受野的固定卷积核来捕捉局部特征, 以及局部连接和静态权重的局限性限制了对全局依赖关系的有效捕获, 在重建复杂电导率分布或形状方面仍然不足。

近年来, 基于视觉 Transformer (vision transformer, ViT) 的方法在视觉任务领域获得了广泛关注, 核心思想是使用自注意力机制来构建长距离的特征依赖, 通过放宽局部性的归纳偏置, 其更有能力处理全局特征交互^[24]。李焱等^[25]提出了一个融合通道注意力的跨尺度 Transformer 方法, 充分利用跨尺度结构自相似性与多尺度 Transformer 来增大感受野, 实现图像超分辨率, 周新民等^[26]基于多尺度卷积的局部感受和 Transformer 的全局特征表达, 提出了多尺度卷积调制模型用于医学图像分割, Chen 等^[27]提出二维和三维通用的 TransUNet 方法, 利用卷积获得的潜在表示和 Transformer 的长程依赖优势实现了小病变分割, Chen 等^[28]提出基于 CNN 和 Transformer 混合的 Dual-former 用于图像复原任务, Zhang 等^[29]基于 Swin Transformer 模块提出了基于感知损失的方法用于低剂量 CT 图像去噪。然而, 单独使用 Transformer 结构并不能充分利用上述优势, 采用多个 Transformer 的堆叠一方面显著增加了二次计算复杂度, 另一方面忽略了卷积算子获得的局部细节特征, 使得重建图像易出现过平滑的问题。尽管近年来基于视觉 Transformer 或 CNN 和 Transformer 混合架构的方法在 EIT 中取得一定进展, 但仍存在以下局限: 多采用堆叠 Transformer 层或全局自注意力, 计算复杂度高, 难以满足实时成像需求; 缺乏对电导率分布与形状信息的解耦建模, 导致重建结果在电导率数值与边界形状上仍存在失真; 现有方法很少将电导率 (数值) 和形状 (几何) 作为不同统计量单独建模, 这在病态的 EIT 逆问题中尤为关键, 因为电导率值的低频分布与形状的高频边缘信息对重建质量的影响不同。

基于上述问题, 本文提出了一种新的基于注意力与 ViT 混合的端到端深度学习方法, 命名为 HiRef-EIT, 用于实现高质量 EIT 图像重建。HiRef-EIT 使用 U-Net 为骨干网络, 采用层级特征堆叠的方式构建多尺度潜空间信息表达, 有效实现了对全局电导率参数分布和局部内含物形状信息的建模。同时, 设计了新的瓶颈连接模块, 采用多尺度自注意力机制实现了将 EIT 图像重建任务分解

为电导率重建和形状重建,降低了逆问题求解的难度。进一步,设计了注意力方式的全局-局部特征融合解码模块,相比于简单的特征拼接或相加的方法具有更高的灵活性,提高了模型对于重要特征的表达同时抑制了噪声伪影信息。

HiRef-EIT 的主要创新点如下:

1) 提出了多头空间衰减注意力 (multi-head spatial reduction attention, MHRA) 的特征编码器,通过引入空间衰减因子的方式降低了 ViT 的计算复杂度同时保持了全局信息的建模能力;

2) 设计了基于通道注意力和坐标注意力并行的瓶颈连接模块,分别从通道层面和空间层面分别构建电导率分布和内含物形状的潜在表示;

3) 提出了基于交叉注意力的解码器单元,其采用注意力的特征融合机制实现了全局-局部信息的多尺度融合,增强了模型的特征表达能力。

使用多相电导率内含物和肺部仿体模型两个重建任务对本文提出的 HiRef-EIT 进行了验证,同时在物理模型上进一步验证 HiRef-EIT 的性能。可视化重建结果和定量指标分析表明,HiRef-EIT 相比于现有的 CNN 或者 Transformer 方法,重建图像具有准确的电导率信息和形状特征,同时计算复杂度更低。

1 EIT 传感原理与逆问题数学模型

1.1 EIT 测量原理

记观测区域为 Ω ,通过边界 $\partial\Omega$ 上放置的电极对圆形区域注入一定频率的交变电流,在剩余电极对上测量产生的边界电压。此过程重复进行,直至所有电极对均完成激励和采集。本文采用全电极模型 (complete electrode model, CEM) 作为边界条件约束椭圆形 Laplace 方程:

$$\nabla \times (\sigma(\mathbf{x}) \nabla u(\mathbf{x})) = 0, \mathbf{x} \in \Omega$$

$$u(\mathbf{x}) + z_l \sigma(\mathbf{x}) \frac{\partial u(\mathbf{x})}{\partial \mathbf{n}} = U_l, \mathbf{x} \in e_l, l = 1, 2, \dots, L$$

$$\sigma(\mathbf{x}) \frac{\partial u(\mathbf{x})}{\partial \mathbf{n}} = 0, \mathbf{x} \in \partial\Omega \setminus \bigcup_{l=1}^L e_l$$

$$\int_{e_l} \sigma(\mathbf{x}) \frac{\partial u(\mathbf{x})}{\partial \mathbf{n}} dS = I_l, l = 1, 2, \dots, L \quad (1)$$

式中: $\mathbf{n}$ 为边界 $\partial\Omega$ 的外法向矢量; z_l 为第 l 个电极的接触阻抗; I_l, U_l 是第 l 个电极的注入电流和边界测量电压。另外,为了保证解的唯一性和存在性,在 CEM 中加入基尔霍夫定律:

$$\sum_{l=1}^L I_l = 0, \sum_{l=1}^L U_l = 0 \quad (2)$$

谢菲尔德协议 (Sheffield protocol) 作为 EIT 领域的标准协议,广泛应用于 16 电极系统配置中。基于相邻电极

对电流注入原理,逐次通过 16 对相邻电极 (1-2, 2-3, ..., 16-1) 注入电流。每次注入时,系统测量除注入电极对及其相邻电极对外的所有相邻电极对间电位差,形成 13 个测量值。设计有效规避了电极-组织界面阻抗对测量的影响,此协议得到总计 208 个独立测量值,其原理如图 1 所示。




图 1 EIT 测量原理

Fig. 1 EIT measurement principle

1.2 EIT 逆问题

电阻抗层析成像 (EIT) 逆问题是指在已知边界电压 V 的条件下,对待测场域内电导率分布 σ 进行反演重构。数学上,此过程可表述为最优化问题,目标是找到最优电导率分布使计算电压与测量电压最为接近。由于问题的病态性,采用最小二乘框架:

$$\sigma^* = \arg\min_{\sigma} \frac{1}{2} \|V - F(\sigma)\|_2^2 + \lambda \times R(\sigma) \quad (3)$$

式中: $R(\sigma)$ 是包含先验信息的正则化项; λ 是对应的权重参数。通过调节正则化参数,在数据拟合与正则化之间实现平衡,以获得稳定且合理重建结果。

近些年来,基于深度学习策略的 EIT 逆问题求解,将具有病态性的图像重建优化问题转化为神经网络的参数优化问题。这类方法通常采用卷积神经网络或 Transformer 架构构建端到端映射模型。数学表达式为

$$f_{EIT} = \arg\min_{\theta} \frac{1}{N} \sum_{i=1}^N L[\sigma_{label}, f_{EIT}(V)] + \lambda R(\theta), \text{ 其中, } \arg\min_{\theta} \text{ 为网络训练模型, } R(\theta) \text{ 为正则化。}$$

2 HiRef-EIT 方法

2.1 方法概述

本文提出了一个新的基于“端到端”的深度学习网络 HiRef-EIT,其结构如图 2 所示。

HiRef-EIT 采用 U 型网络作为骨干模型,核心单元包




图 2 HiRef-EIT 模型架构

Fig. 2 HiRef-EIT model architecture

括基于多头空间衰减注意力模块构成的编码器,基于通道注意力和坐标注意力的并行 Bottleneck 单元,以及基于交叉 Transformer 模块构成的解码器。采用基于 L2 范数正则化的数值迭代求解算法获得预重建图像。预重建图像作为 HiRef-EIT 的输入,其维度为 $H \times W \times C$ 。首先,经过块嵌入对输入图像进行位置编码。编码器具有 4 个模块,每个编码模块输出结果的空间维度为 $\frac{H}{2^{i-1}} \times \frac{W}{2^{i-1}}$ ($i = 1, 2, 3, 4$), 对应的通道数目为 $[C_1, C_2, C_3, C_4]$ 。两个相邻的编码模块间使用 2×2 的平均池化层和 $1 \times 1 \times 2C_i$ ($i = 1, 2, \dots, 4$) 的卷积层相连接,实现空间层面的特征聚合和通道信息的扩展。多头空间衰减注意力模块实现了全局潜在特征的构建,同时降低了模型的参数量。Bottleneck 模块采用并行注意力策略,将图像重建任务分为电导率参数重建和形状特征重建。通道注意力将电导率分布转化为通道信息,实现全局分布学习;坐标注意力采用两个不同方向空间卷积核实现形状学习。Bottleneck 采用全局/局部的注意力方式实现长距离特征传递。解码器采用交叉 Transformer 模块,将 Bottleneck 获得的电导率特征、形状特征以及全局上采样结果,采用注意力机制的策略进行多尺度特征融合,有效地保留了多尺度的特征。

2.2 多头空间衰减注意力模块

多头空间衰减注意力模块的特征图首先经过块嵌入进行初始投影,然后通过 MHRA 进行特征表示计算。通过不断降采样来逐步减小空间尺寸,同时增加通道数,以适应高分辨率图像处理任务,其原理如图 3 所示。

在 MHRA 计算过程中,采用标准的多头注意力计算:




图 3 多头空间衰减注意力机制

Fig. 3 Multi-head spatial reduction attention mechanism

$$MHRA(Q, K, V) = \text{Concat}[S_1, S_2, \dots, S_N] \times W \quad (4)$$

$$S_j = SA(QW_j^Q, SR(K)W_j^K, SR(V)W_j^V), j = 1, 2, \dots, N \quad (5)$$

$$SA(Q, K, V)_i = \text{softmax}\left(\frac{Q \times K^T}{\sqrt{d_H}}\right) \times V \quad (6)$$

其中, QKV 代表一个查询 Q 、一个键 K 和一个值 V 作为输入; $\text{Concat}[\]$ 表示将 N 个注意力头拼接, $W_j^Q \in \mathbf{R}^{P_i^2 C \times d_H}$, $W_j^K \in \mathbf{R}^{P_i^2 C \times d_H}$, $W_j^V \in \mathbf{R}^{P_i^2 C \times d_H}$ 和 $W \in \mathbf{R}^{P_i^2 C \times P_i^2 C}$ 表示可学习的注意力权重向量; $d_H = C/N$ 表示注意力头的维度; $SR(X)$ 代表空间衰减操作,即对键和值进行空间降采样,以降低计算复杂度。计算表达式为:

$$SR(X) = LN[(\text{Reshape}(X, r_i) \cdot W_s)] \in \mathbf{R}^{\frac{H}{r_i} \times \frac{W}{r_i} \times r_i^2 C} \quad (7)$$

式中: LN 表示层归一化; $\text{Reshape}(X, r_i)$ 是形状变化算子,将输入特征宽和高分别压缩为原来的 $\frac{1}{r_i}$, 权重矩阵维度大小为 $W_s \in \mathbf{R}^{(r_i^2 C) \times C}$ 将输入序列通道维度变为 C 。

2.3 基于注意力的特征瓶颈连接

基于通道注意力和空间注意力并行协调的特征传递机制,优化了编码器与解码器之间的信息交互。HiRef-EIT 在每个特征提取模块与相应的重建模块之间嵌入该机制,以提高跨尺度信息的有效性。

1) 通道注意力(channel attention)

通道注意力机制由全局特征嵌入和自适应校准两部分组成。首先,对输入张量 $\mathbf{X}_c$ 的各通道进行全局平均池化(global average pooling, GAP)提取通道层面的统计信息,其过程为:

$$z_c = \frac{1}{H \times W} \sum_{i,j=1}^{H,W} \mathbf{X}_c(i,j) \quad (8)$$

并生成通道特征向量。随后,利用两层全连接网络(FC)完成特征调整,先通过降维层(缩放因子为 r)获得低维潜在空间特征,再经过 ReLU 非线性激活层,最终升维至原通道数目,生成权重系数向量。过程如图 4 所示,其运算过程表示为:

$$\mathbf{S} = F_{ex}(\mathbf{Z}, \mathbf{W}_{ex}) = \text{sigmoid}[\mathbf{W}_{in}(r) \times \text{ReLU}(\mathbf{W}_{de}(r)\mathbf{Z})] \quad (9)$$

其中, $\mathbf{S} \in \mathbf{R}^{1 \times 1 \times C}$ 为 FC 网络的输出张量; $\mathbf{W}_{in}(r)$ 和 $\mathbf{W}_{de}(r)$ 分别表示升维系数和降维系数为 r 的全连接层权重; $\mathbf{Z}$ 表示输入特征图。经过 FC 网络后获得了输入张量的每一个通道对于全局特征的权重系数。将输入张量的每一个通道与 FC 网络的输出相乘,得到通道注意力张量 $\mathbf{X}'_{Channel}$, 其运算过程为:

$$\mathbf{X}'_{Channel} \in \mathbf{R}^{C \times H \times W} = \mathbf{S} \times \mathbf{X} \quad (10)$$

SE 通道注意力使用简单的模型结构,实现对关键电导率特征的增强和无关特征的抑制,提高 EIT 图像的电导率分布表征能力。




图4 通道注意力
Fig.4 Channel attention

2) 坐标注意力(coordinate attention)

空间注意力机制基于水平方向(x 轴)和垂直方向(y 轴)的一维池化,分别提取特征图的位置信息和形状信息。首先,采用水平和竖直的一维平均池化核对输入张量进行方向性特征聚合,得到两个独立的特征向量。即:

$$\begin{cases} \mathbf{Z}^h \in \mathbf{R}^{C \times H \times 1} = [z_1^h, z_2^h, \dots, z_C^h], z_i^h = \frac{1}{W} \sum_{0 \leq i \leq W} z_i(h, i); \\ \mathbf{Z}^v \in \mathbf{R}^{C \times 1 \times W} = [z_1^v, z_2^v, \dots, z_C^v], z_i^v = \frac{1}{H} \sum_{0 \leq j \leq H} z_i(j, w); \end{cases} \quad (11)$$

随后,将两者拼接后通过 1×1 卷积降维,并经过非线性变换生成优化的空间特征向量。该向量分别沿 x 和 y 方向分离,再通过 1×1 卷积恢复通道维度,生成水平和垂直方向的注意力映射,过程如图 5 所示。




图5 坐标注意力
Fig.5 Coordinate attention

通道与空间注意力的结合有效提高了特征表达能力,使得 HiRef-EIT 在复杂电导率分布场景下能够实现更精确的成像重建。

2.4 交叉-Transformer

交叉-Transformer 的作用是从输入特征中提取与关键区域相关的注意力,特别是在跳跃连接的结构中,它帮助有效地捕捉不同区域间的重要关联。首先,特征通过转置卷积和上采样过程进行处理,以便在得到输出特征图后,从中提取查询向量和键值对。具体来说,从跳跃连接的输入特征图获取 $\mathbf{Q}_i = \mathbf{X}_{SE-Attention} \times \mathbf{W}^{Q_i}$, 从上采样特征图获得键向量 $\mathbf{K}_i = \mathbf{X}_{Coordinate} \times \mathbf{W}^{K_i}$ 和值向量 $\mathbf{V}_i = \mathbf{X}_{Up} \times \mathbf{W}^{V_i}$ 。其中可学习的权重矩阵分别为 $\mathbf{W}^{Q_i} \in \mathbf{R}^{d_i \times d_q}$, $\mathbf{W}^{K_i} \in \mathbf{R}^{d_i \times d_k}$, $\mathbf{W}^{V_i} \in \mathbf{R}^{d_i \times d_v}$, 注意力模块的输出特征

$Y_i \in \mathbf{R}^{c \times d_v}$ 可以由下式计算得到:

$$Y_i = \text{softmax}\left(\frac{\mathbf{Q}_i \times \mathbf{K}_i^T}{\sqrt{d_q}}\right) \times \mathbf{V}_i \quad (12)$$

交叉-Transformer 利用式 (12) 注意力机制, 通过 1×1 卷积与特征连接, 结合编码模块, 获得融合后的多尺度特征。随后, 特征通过残差卷积和其他模块对输入特征进行进一步结构化处理, 其结构如图 6 所示。




图 6 交叉-Transformer

Fig. 6 Cross-transformer

2.5 损失函数

HiRef-EIT 的损失函数定义为:

$$Loss = L_{MSE} + \lambda \times R(\theta) = \sum_{(\hat{x}, y) \in D} \|\hat{x} - f_{\text{HiRef-EIT}}(y | \theta)\|_2^2 + \lambda \times \|\theta\|_2^2 \quad (13)$$

式中: $\hat{x}$ 为待重建的目标电导率图像; y 为输入的初始电导率分布; D 为给定的训练样本; θ 为待训练的参数。损失函数中 L_{MSE} 用于确保模型的输出尽可能与标签分布地接近, $R(\cdot)$ 为损失函数的正则项, 用于避免训练过程中出现过拟合的问题, 对应的 λ 为正则项参数, 本文设定为 0.01。模型的训练过程即监控损失函数的变化, 使得最终的模型参数 θ^* 使得网络可以重建与目标一致的结果 X^* 。

3 实验与结果

3.1 数据集

用于 HiRef-EIT 训练的数据集为使用 Comsol 多物理场联合 Matlab 软件获得的仿真数据集, 为提高模型在不同成像任务方面的性能, 构建了两组不同的仿真数据集, 分别包括复杂形状的多电导率分布和模拟人体肺部的仿体数据。所有的数据集均设置直径为 0.19 m 的圆形区域为测量敏感场, 测量区域外部均匀设置 16 个电极传感器, 使用“相邻激励-相邻测量”的方式对观测区域进行电流信号调制, 注入的电流的大小为 4.5 mA, 频率为 50 kHz, 并采集电极上的电压响应信号。

EIT 正问题采用有限元方法进行数值求解, 使用有限单元法 (FEM) 将观测域离散为致密的三角形网格后进行数值求解。对于 16 电极 EIT 测量模型, 全部电极激励—测量一次共获得 208 个有效电压。为了避免 “inverse crime” 问题, 使用不同的离散单元划分方法来表示区域内电导率的分布特征。使用方形网格将观测区域进行单元剖分, 为了充分表达具有复杂边界形状的内含物信息, 将观测区域剖分为 256×256 pixels 网格用于反问题重建的标签电导率分布, 其余像素单元使用线性归一化方法将全部单元规范在 $[0, 1]$ 。用差分成像方式来降低测量系统噪声的影响, 因此设定观测区域内没有任何内含物的测量时刻为参考时刻, 有不同相的介质分布的时刻为测量时刻, 两者的差值作为模型的输入信息。

1) 复杂形状数据集: 为提升 HiRef-EIT 在形状表达方面的性能, 使用复杂的几何形状作为内含物训练模型。包含正方形、三角与圆形组合等复杂内含物, 共 42 830 个样本 (训练/验证/测试 = 80%/10%/10%)。背景电导率 0.06 S/m, 内含物电导率随机分布在 $10^{-6} \sim 10^{-1}$ S/m 范围。

2) 肺部仿体数据集: 基于联盟影像集合 LIDC-IDRICT 图库^[30]构建胸廓与肺区解剖结构, 内部人体解剖结构 (皮下组织、肺部、心脏/主动脉和脊柱) 的近似电导率参数设置为 0.30、0.15、0.50、0.60、0.09 S/m。通过随机检测 20%~60% 的肺部区域模拟肺部疾病, 病变的肺部电导率范围为 0.165~0.285 S/m。共生成 10 100 个样本, 其中训练集 9 100 个, 测试集 1 000 个。数据集示意图如图 7 所示。




图 7 数据集示意图

Fig. 7 Schematic diagram of datasets

3.2 实验设置

模型参数配置: 主干是 U 形框架其中五层编码器的空间维度为 256, 128, 64, 32, 16 (指高度和宽度) 通道数分别为 $[8, 32, 128, 512, 1024]$ 多头空间衰减注意力头数设置为 $[1, 4, 4, 8]$, 衰减因子设置为 $[8, 8, 4, 4]$ 且注意力块设置为 $[4, 4, 4, 4]$ 。通道中的降维系数 r 设置为 8, 对称的解码器用于恢复空间维度并减小信道维度, 其中空间维度 32, 64, 128, 256 并且信道维度为 $[512, 128, 32, 8]$ 最后利用 $1 \times 1 \times 1$ 卷积对输出通道进行调整。

HiRef-EIT 使用最小批量随机梯度下降优化器训练

网络模型,全部训练轮数为 200,优化器为 Adamax,参数 $\beta_1 = 0.9, \beta_2 = 0.999$, 学习率在每次参数更新时按照式 (14) 进行调整。

$$\eta_t = \eta_{t-1} \cdot \left(1 - \frac{t}{T}\right)^{0.9} \quad (14)$$

其中, η_t, η_{t-1} 表示第 t 次和第 $t-1$ 次学习率; t 表示当前训练步数, T 表示总训练步数,权重参数随机设置为均值为 0, 标准差为 0.01 的高斯分布随机数。该模型在电脑配置为 Windows 10 和计算机处理器为 Intel CoreTM i7-9700K @ 3.6 GHz, 机带 RAM 为 32.0 GB。Python3.9 中使用训练环境是开源框架 Pytorch 1.12.1 和 CUDA 和 CUDNN 环境下进行,训练用时约为 26 h。

3.3 实验结果

为了验证本文所提出的 HiRef-EIT 的性能,本文使用基于卷积神经网络的模型和基于 Transformer 网络的方法进行了充分比较。比较的方法包括 VA-Net^[31]、HybridDenseUNet^[17]、ResAttU-Net^[16]、DHU-Net^[18]、MAT-UNet^[21]。

为了定量分析重建结果与真实分布之间的差异,选择了均方根误差 (RMSE)、峰值信噪比 (PSNR) 和结构相似性指数 (SSIM) 进行量化:

$$RMSE = \sqrt{\frac{1}{N} \|x_{Rec} - x_{label}\|_2^2} \quad (15)$$

$$PSNR = 20 \log_{10} \frac{\max(x_{Rec}) \sqrt{N}}{\|x_{Rec} - x_{label}\|_2^2} \quad (16)$$

$$SSIM = \frac{(2\mu_{Rec}\mu_{label} + C_1)(2\Sigma_{Rec, label} + C_2)}{(\mu_{Rec}^w + \mu_{label}^2 + C_1)(\Sigma_{Rec}^2 + \Sigma_{label}^2 + C_2)} \quad (17)$$

式中: Rec 表示重建图像; label 表示标签分布; N 为图像的总像素值; μ 和 Σ 分别表示均值和协方差矩阵。RMSE 和 PSNR 在像素级层面衡量了重建结果和真实分布之间的差异, SSIM 度量了重建图像与参考图像之间特征内容的相似性, RMSE 越低, PSNR 越高, 结果越好, SSIM 越大, 重建图像与参考图像在结构上越相似。

1) 鲁棒性测试

在仿真模拟实验数据中,为了评估 HiRef-EIT 算法对噪声的抵抗力,本文引入了不同信噪比水平 (30~70 dB) 的高斯白噪声,对比 HiRef-EIT 的成像结果,量化指标 RMSE 与 SSIM 的性能表现。

图 8 所示为不同信噪比 (SNR) 条件下, HiRef-EIT 算法的成像结果。在低信噪比下,尽管噪声较强,算法仍能保持基本的成像结构和边界信息,体现了其在强噪声干扰下的稳定性。随着 SNR 提升至 40 dB 及以上,电导率分布趋于均匀,边缘逐渐恢复至接近真实值。在 SNR 达到 60 dB 时,边缘清晰且电导率分布与真实图像一致,表

现出优越的成像质量。




图 8 不同信噪比水平下的肺部仿体重建结果

Fig. 8 Lung phantom reconstruction results at different signal-to-noise ratios

在量化性能方面,低信噪比条件下 (30 dB), RMSE 为 25.047, SSIM 为 0.820 2, 尽管噪声较强,算法仍能保持基本的成像结构。随着信噪比提升, RMSE 快速下降, SSIM 稳步上升。在 SNR 达到 40 dB 以上时, RMSE 能够维持在 8.00 以下, SSIM 高于 0.93, 这表明 HiRef-EIT 算法在复杂边界的形状重建任务中能够获得较为精确的成像结果,量化指标数据曲线如图 9 所示。




图 9 不同信噪比水平下的重建结果量化指标曲线


Fig. 9 Quantitative imaging metrics at different signal-to-noise curve graph

实验结果进一步验证了 HiRef-EIT 算法在抗噪声方面的性能表现突出,能够适应不同噪声水平下的电阻抗成像需求。

2) 仿真数据结果


(1) 重建结果可视化:为了充分说明本文提出的方法,选择了两个重建任务中的代表性测试样本进行结果可视化,相关结果如图 10 所示。其中图 10(a) 为复杂形状与多相分布重建结果,图 10(b) 为健康/病变的肺部仿体重建结果,在每组结果中第 1 列为真实电导率分布。第 2~7 列分别为 VA-Net^[31]、HybridDenseUNet^[17]、ResAttU-Net^[16]、DHU-Net^[18]、MAT-UNet^[21] 和 HiRef-EIT。

从图 10 可以得出,基于简单的卷积重建方法 (VA-Net, HybridDenseUNet) 仅可以重建出大致的分布情况,但是出现电导率数值不准确和明显的形状过平滑的问题,主要是由于单纯的卷积方法仅关注局部特征,但是忽略了全局信息;进一步,基于注意力机制的方法 (ResAttU-Net, DHU-Net) 在一定程度上消除了重建伪影,但是对于一些低电导率对比度的内含物重建任务,仍然无法准确



(a) 复杂形状与多相分布重建结果

(a) Reconstruction results for complex shapes and multi-phase distributions



(b) 肺部仿真仿真重建结果

(b) Simulation reconstruction results for lung phantoms

图 10 仿真数据可视化结果(所有结果均归一化在[0,1])

Fig. 10 Simulation data visualisation results(All results are normalised between [0,1])




图 11 仿真数据重建结果指标

Fig. 11 Simulation data reconstruction result indicators

3) 实验数据结果

(1) 实验设定。本研究采用自主研发的 16 电极 EIT 数据采集系统开展物理实验。系统配置参数如下:直径为 0.19 m 的圆形水槽作为成像区域,激励电流幅值为 4.5 mA,根据自主研发的 EIT 数据采集系统的硬件特性,激励频率选择 100 kHz 时系统信噪比更高、测量稳定性更强,有效提升实验数据的可靠性。数据采集系统信噪

地表达出电导率数值,并且对于复杂形状的特征恢复存在失真;基于 Transformer 的方法,包括 MAT-UNet 和本文提出的 HiRef-EIT,重建结果显著优于基于 CNN 和 Attention 的方法。值得注意的是,HiRef-EIT 通过引入多尺度的特征编码单元与并行通道-空间 Bottleneck 模块,可以更好地学习观测区域的潜在特征,重建结果表明本文方法可以更好地保留形状细节与复杂的多相电学参数分布。同时,在两个重建任务上均获得了最好的结果。

(2) 定量指标分析。本文考虑了上述两个不同的 EIT 成像任务,使用 RMSE、PSNR 和 SSIM 量化,将两组评价指标如图 11 所示。

可以看出,VA-Net 方法的结果不佳(最高的 RMSE,最低的 SSIM 和 PSNR),表示其成像质量容易受到噪声干扰和复杂场景的影响。虽然改进型网络如 HybridDenseUNet、ResAttU-Net 和 DHU-Net 等在一定程度上提升了成像质量,但它们的 RMSE 仍然偏高,而 SSIM 和 PSNR 仍然偏低,表明这些模型在面对各种复杂场景时泛化能力有限。相比之下,HiRef-EIT 方法在量化指标上表现最为出色,不仅 RMSE、SSIM 和 PSNR 值更优,方差也更小,证明了该方法具有更强的泛化能力和抗干扰性,能在多种复杂条件下提供高质量成像结果。

总之,在不同的成像任务上评估 HiRef-EIT 方法,与现有的几种图像重建方法相比,所提出的方法在定量评估指标(RMSE、PSNR 和 SSIM)和视觉表征方面都有显著的增强。

比为 70 dB,比特分辨率为 14 位。整个系统由传感阵列、压控流源(VCCS)、程控可变增益放大器、FPGA 主控芯片、数/模转换器及 PC 上位机构成,形成完整的数据传感、采集与处理链路。数据传感与采集装置结构如图 12 所示。实验采用电导率为 0.06 S/m 的水溶液模拟,非均匀相使用圆形、正方形和三角形的树脂塑胶棒(考虑到树脂塑胶材料为绝缘物体,在设置时使用 1×10^{-12} S/m 假定

内含物的电导率) 和不同盐水浓度制成的琼脂模型。另外,使用琼脂材料模拟人体胸腔,包括健康和病变的肺部、心脏、主动脉和脊柱等组织。不同仿体的电导率参数设置为:健康肺部电导率为 0.5 S/m,心脏电导率为 1.5 S/m,主动脉电导率为 1.7 S/m,脊柱电导率为 0.3 S/m,设置病变区域的电导率数值范围是 0.55~0.95 S/m。






图 12 实验设备
Fig. 12 Experimental equipment

(2) 重建图像可视化定量指标分析。可视化实验结果如图 13 所示所示,其中图 13(a) 为具有复杂形状的多相夹杂物,图 13(b) 是健康/损伤肺部模型。可以看出,VA-Net 方法仅仅能够重建内含物的大致分布信息,但是无法给出准确的边界形状特征,边界存在明显伪影。HybridDenseUNet 虽有改进但处理复杂结构时区域过渡不平滑。基于 attention 的方法虽然在形状表达能力方面相比于 VA-Net 提升,但是仍然出现了局部形状失真的问题。说明仅使用局部特征实现 EIT 重建任务是具有局限性。相比之下,基于 Transformers 改进的方法由于融合了全局特征建模和局部信息构建,其重建结果与真实分布

具有更高的一致性。特别是本文提出的 HiRef-EIT,在处理多相复杂分布的场景中,能够准确区分不同电导率的区域,保持背景电导率分布的均匀性,明显的提高了重建图像的质量。表 1 和 2 分别给出了复杂形状数据和肺部仿体数据的定量评估指标。



(a) 复杂形状与多相分布重建结果
(a) Complex shape and multi-phase distribution reconstruction results



(b) 肺部仿体仿真重建结果
(b) Lung phantom simulation reconstruction results

图 13 实验数据集的可视化重建结果
(所有结果均归一化在[0,1])
Fig. 13 Visualisation of experimental data set reconstruction results (All results are normalised between [0,1])

表 1 复杂形状数据量化评价指标 Table 1 Quantitative evaluation indicators for complex shape data												
模型指标	模型 1			模型 2			模型 3			模型 4		
	RMSE	PSNR	SSIM	RMSE	PSNR	SSIM	RMSE	PSNR	SSIM	RMSE	PSNR	SSIM
VA-Net	13.835	26.700	0.920	16.165	25.289	0.916	11.835	31.715	0.921	13.950	26.675	0.925
HybridDenseUNet	10.574	29.078	0.933	10.605	28.974	0.940	6.514	31.715	0.956	5.827	34.312	0.953
ResAttU-Net	10.823	28.870	0.937	11.681	28.125	0.931	7.889	31.715	0.945	8.128	31.519	0.941
DHU-Net	8.402	31.048	0.945	9.539	29.886	0.931	6.158	31.715	0.960	6.418	33.328	0.952
MAT-UNet	6.988	32.598	0.954	7.829	31.580	0.961	5.765	31.715	0.960	5.824	34.217	0.952
HiRef-EIT	<u>5.882</u>	<u>34.074</u>	<u>0.963</u>	<u>6.429</u>	<u>33.322</u>	<u>0.963</u>	<u>5.720</u>	<u>31.715</u>	<u>0.963</u>	<u>5.125</u>	<u>35.412</u>	<u>0.956</u>

根据表 1 和 2 的数据分析可以看出,HiRef-EIT 方法在两个不同数据集上都展现了优秀的性能表现。在复杂形状数据量化评价中,HiRef-EIT 取得了最优的 RMSE (5.882)、PSNR (34.074) 和 SSIM (0.963) 指标;在肺部实验数据量化评价中同样保持领先,分别达到 5.075、

35.404 和 0.960 的最佳值。与传统方法相比,HiRef-EIT 相对于 VA-Net 在 RMSE 上实现了约 60%~75% 的显著改善,PSNR 提升了 8~12 dB,SSIM 提高了 4%~9%,这些数值充分体现了算法的技术优势,充分证明了该方法在电阻抗成像重建领域的技术领先性和实际应用价值。

表 2 肺部实验数据量化评价指标

Table 2 Quantitative evaluation indicators for lung experiment data

模型指标	模型 1			模型 2			模型 3			模型 4		
	RMSE	PSNR	SSIM	RMSE	PSNR	SSIM	RMSE	PSNR	SSIM	RMSE	PSNR	SSIM
VA-Net	20.627	23.156	0.877	21.792	22.704	0.840	16.447	25.173	0.847	22.134	22.562	0.829
HybridDenseUNet	10.083	29.379	0.924	12.064	27.915	0.914	12.717	27.427	0.886	10.202	29.298	0.893
ResAttU-Net	12.530	27.491	0.910	15.193	25.885	0.892	14.018	26.574	0.873	12.172	27.756	0.876
DHU-Net	7.942	31.441	0.934	9.375	30.115	0.930	10.765	28.881	0.902	8.959	30.433	0.907
MAT-UNet	6.823	32.742	0.945	7.538	31.973	0.940	9.612	29.863	0.910	8.220	31.173	0.916
HiRef-EIT	<u>5.075</u>	<u>35.404</u>	<u>0.960</u>	<u>5.418</u>	<u>34.780</u>	<u>0.961</u>	<u>7.043</u>	<u>32.603</u>	<u>0.943</u>	<u>7.528</u>	<u>32.001</u>	<u>0.939</u>

4 结 论

本文提出了新的电阻抗层析成像框架 HiRef-EIT,将 U-Net 骨干网络、多头空间衰减注意力模块和视觉 Transformer 结合,从而建立电压测量值与电导率分布之间的高精度映射。通过将注意力机制与层级特征堆叠技术相结合,增强了模型对复杂电导率分布和内含物形状的表达能力,同时降低了计算复杂度。为了提高特征表示能力,还设计了基于通道注意力和坐标注意力并行的瓶颈连接模块,以及基于交叉注意力的解码器单元,实现全局-局部信息的多尺度融合。因此,HiRef-EIT 不仅实现了高质量的电导率参数重建,而且在内含物边界形状表达方面表现出色。在多相电导率分布、复杂形状重建和肺部仿真模型等多种任务上的大量实验结果表明,提出的 HiRef-EIT 在各种评价指标下提供了优异的重建性能,显著优于其他先进的 EIT 成像方法。

参考文献

[1] 李志伟,于瑶,吴阳,等.电阻抗成像技术在肺功能检测的研究进展[J].机械制造与自动化,2024,53(1):1-9.
LI ZH W, YU Y, WU Y, et al. Research progress of electrical impedance tomography technology in lung function detection [J]. Machine Building & Automation, 2024, 53(1):1-9.

[2] ADLER A,HOLDER S. Electrical Impedance Tomography[M]. Boca Raton:CRC Press,2021.

[3] MUELLER J L, SILTANEN S. Linear and nonlinear inverse problems with practical applications[M]. Society for Industrial and Applied Mathematics, 2012.

[4] 范文茹,么雪飞.基于改进 L1/2 正则化的电阻抗层析成像[J].电子测量技术,2022,45(7):56-61.
FAN W R, YAO X F. Electrical impedance tomography based on improved L1/2 regularization [J]. Electronic Measurement Technology, 2022, 45(7):56-61.

[5] SHI Y, ZHANG X, WANG M, et al. An adaptive non-

convex hybrid total variation regularization method for image reconstruction in electrical impedance tomography[J]. Flow Measurement and Instrumentation, 2021, 79: 101937.

[6] LIU Z, GU H, CHEN Z, et al. Dual-modal image reconstruction for electrical impedance tomography with overlapping group lasso and Laplacian regularization[J]. IEEE Transactions on Biomedical Engineering, 2023, 70(8): 2362-2373.

[7] CHEN Z, ZHANG L, LIANG S, et al. Electrical impedance tomography for thorax image using connected component labeling and sparse group lasso [J]. IEEE Transactions on Instrumentation and Measurement, 2024. DOI: 10.1109/TIM.2024.3427859.

[8] WANG J. A two-step accelerated Landweber-type iteration regularization algorithm for sparse reconstruction of electrical impedance tomography [J]. Mathematical Methods in the Applied Sciences, 2024, 47 (5): 3261-3272.

[9] WANG Q, CHEN X, WANG D, et al. Regularization solver guided FISTA for electrical impedance tomography [J]. Sensors, 2023, 23(4): 2233.

[10] WANG N, LI Y, ZHAO P F, et al. Fast electrical impedance tomography based on sparse Bayesian learning[J]. Applied Soft Computing, 2023, 143: 110384.

[11] MUELLER J L, SILTANEN S. The D-bar method for electrical impedance tomography—demystified [J]. Inverse problems, 2020, 36(9): 093001.

[12] ALBUQUERQUE Y F, LAURAIN A, STURM K. A shape optimization approach for electrical impedance tomography with point measurements [J]. Inverse Problems, 2020, 36(9): 095006.

[13] WANG G, YE J C, DE MAN B. Deep learning for tomographic image reconstruction [J]. Nature Machine Intelligence, 2020, 2(12): 737-748.

[14] 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 lung diseases [J]. Journal of Biomedical Engineering, 2025, 42(2):389-395.
- [15] HAMILTON S J, HAUPTMANN A. Deep D-bar: Real-time electrical impedance tomography imaging with deep neural networks [J]. IEEE Transactions on Medical Imaging, 2018, 37(10): 2367-2377.
- [16] 王子辰, 陈晓艳, 王倩, 等. 基于残差自注意力连接的深度电学层析成像方法[J]. 仪器仪表学报, 2023, 44(5):288-301.
- WANG Z CH, CHEN X Y, WANG Q, et al. Deep electrical tomography method based on residual self-attention connection [J]. Chinese Journal of Scientific Instrument, 2023, 44(5):288-301.
- [17] ZHANG B, WANG Z, CHEN X, et al. Hybrid DenseU-Net: Learning a multi-scale convolution and dense connectivity CNN for inverse imaging problems [J]. Measurement Science and Technology, 2023, 35(3): 035404.
- [18] WANG Z, LI X, SUN Y, et al. Electrical impedance tomography deep imaging with dual-branch U-Net based on deformable convolution and hyper-convolution [J]. IEEE Transactions on Instrumentation and Measurement, 2024. DOI: 10.1109/TIM.2024.3369160.
- [19] 袁晶晶, 戎舟. 基于S-PNet的触觉电阻抗成像后处理算法研究[J]. 国外电子测量技术, 2024, 43(6): 68-75.
- YUAN J J, RONG ZH. Research on tactile electrical impedance imaging post-processing algorithm based on S-PNet [J]. Foreign Electronic Measurement Technology, 2024, 43(6):68-75.
- [20] AMEEN A A, SACK A, PÖSCHEL T. TSS-ConvNet for electrical impedance tomography image reconstruction[J]. Physiological Measurement, 2024, 45(4): 045006.
- [21] 王琦, 张涛, 徐超炜, 等. 多尺度注意力融合与视觉Transformer方法优化的电阻抗层析成像深度学习方法[J]. 仪器仪表学报, 2024, 45(7):52-63.
- WANG Q, ZHANG T, XU CH W, et al. Deep learning method for electrical impedance tomography optimized by multi-scale attention fusion and visual Transformer [J]. Chinese Journal of Scientific Instrument, 2024, 45(7): 52-63.
- [22] LIU Z, WANG J, SHAN Q, et al. GraphEIT: Unsupervised graph neural networks for electrical impedance tomography [J]. IEEE Transactions on Computational Imaging, 2024:1559-1570.
- [23] 闫孝姮, 丁一凡, 陈伟华, 等. 多注意力残差脉冲神经网络的接地网故障诊断[J]. 电子测量与仪器学报, 2025, 39(3): 77-91.
- YAN X H, DING Y F, CHEN W H, et al. Grounding grid fault diagnosis based on multi-attention residual spiking neural network [J]. Journal of Electronic Measurement and Instrumentation, 2025, 39(3): 77-91.
- [24] LIU Y, ZHANG Y, WANG Y, et al. A survey of visual transformers[J]. IEEE Transactions on Neural Networks and Learning Systems, 2023,35(6):7478-7498.
- [25] 李焱, 董仕豪, 张家伟, 等. 融合通道注意力的跨尺度Transformer图像超分辨率重建[J]. 中国图象图形学报, 2025, 30(3): 784-797.
- LI Y, DONG SH H, ZHANG J W, et al. Cross-scale transformer image super-resolution reconstruction fusing channel attention [J]. Journal of Image and Graphics, 2025, 30(3):784-797.
- [26] 周新民, 熊智谋, 史长发, 等. 基于多尺度卷积调制的医学图像分割[J]. 电子学报, 2024, 52(9): 3159-3171.
- ZHOU X M, XIONG ZH M, SHI CH F, et al. Medical image segmentation based on multi-scale convolution modulation [J]. Acta Electronica Sinica, 2024, 52(9): 3159-3171.
- [27] CHEN J, MEI J, LI X, et al. TransUNet: Rethinking the U-Net architecture design for medical image segmentation through the lens of transformers [J]. Medical Image Analysis, 2024, 97: 103280.
- [28] CHEN S, YE T, LIU Y, et al. Dual-former: Hybrid self-attention transformer for efficient image restoration [J]. Digital Signal Processing, 2024, 149: 104485.
- [29] ZHANG B, ZHANG Y, WANG B, et al. Denoising swin transformer and perceptual peak signal-to-noise ratio for low-dose CT image denoising[J]. Measurement, 2024, 227: 114303.
- [30] CLARK K, VENDT B, SMITH K, et al. The cancer imaging archive (TCIA): Maintaining and operating a public information repository [J]. Journal of Digital Imaging, 2013, 26: 1045-1057.
- [31] VAUHKONEN P, VAUHKONEN M, SAVOLAINEN T, et al. Three-dimensional electrical impedance tomography based on the complete electrode model [J]. IEEE Transactions on Biomedical Engineering, 1999, 46(9): 1150-1160.

作者简介



李秀艳, 2007年于河北工业大学获得硕士学位, 2010年于天津大学获得博士学位, 现为天津工业大学教授, 主要研究方向为机器学习、图像处理与模式识别、电学成像。

E-mail: lixiuyan@tiangong.edu.cn

Li Xiuyan received her M. Sc. from Hebei University of Technology in 2007, Ph. D. from Tianjin University in 2010. She is now a professor at Tiangong University. Her main research interests include image processing and pattern recognition, machine learning and research on electrical imaging technology.



吴文旭, 2023 年于石家庄学院获得学士学位, 现为天津工业大学硕士研究生, 主要研究方向图像处理、电阻抗成像、嵌入式系统开发等。

E-mail: wuwenxu@tiangong.edu.cn

Wu Wenxu received his B. Sc. degree from Shijiazhuang University in 2023. He is now a M. Sc. candidate

of Tiangong University. His main research interests include image processing, electrical impedance imaging, embedded system development and so on.



王琦(通信作者), 2012 年于天津大学获得博士学位, 现为天津工业大学教授, 主要研究方向为过程层析、图像重建和智能信息处理。

E-mail: wangqitju@163.com

Wang Qi (Corresponding author) received her Ph. D. degree from Tianjin University in 2012. She is now a professor at Tiangong University. Her main research interests include tomography process, image reconstruction and intelligent information processing.