

DOI: 10.19650/j.cnki.cjsi.J2615217

融合物理先验与坐标条件神经表示的自监督 学习电阻抗成像方法*

武跃辉^{1,2}, 白鑫昊^{1,2}, 韩建达^{1,2}, 于宁波^{1,2}

(1. 南开大学人工智能学院 天津 300350; 2. 南开大学深圳研究院智能技术与机器人系统研究院 深圳 518083)

摘要:电阻抗层析成像 (EIT) 是一种利用边界电流激励与电压测量反演内部电导率分布的成像方法,但其逆问题具有强病态性。传统方法重建的图像分辨率低,基于深度学习的方法有效提升了成像质量,但依赖配对的电压-电导率数据,故提出一种融合物理先验与坐标条件神经表示的自监督学习电阻抗成像方法。该方法以一阶前向物理模型为基础,在图像域和测量域之间分别构建正向和逆向循环一致约束,实现非配对数据下的网络训练;同时,设计了坐标条件表示的逆向图像生成网络,将电压序列重排为伪图像后提取局部卷积特征,结合全局电压变量与坐标位置编码逐像素预测电导率值,以增强对连续电导率场及边界细节的表达能力。在此基础上,引入边界一致性约束和对抗学习策略,进一步改善重建图像的结构保持能力。重建图像结果表明,所提方法在目标定位、形状恢复和抑制伪影等方面均优于其他传统方法和自监督学习方法。在仿真数据集上,所提方法的平均相关系数 (CC)、均方根误差 (RMSE) 和结构相似度 (SSIM) 分别为 0.919、0.099 和 0.812;在物理模体实验中,相较于最优的基线对比方法,平均相关系数提高 0.043,均方根误差降低 0.027,结构相似度提高 0.037 7,并在噪声扰动条件下表现出较好的鲁棒性,实现了无需配对标签数据的高质量图像重建。

关键词: 电阻抗成像; 自监督学习; 物理信息神经网络; 图像重建; 坐标条件神经表示

中图分类号: TP23 TH86 **文献标识码:** A **国家标准学科分类代码:** 510.4050

A self-supervised learning electrical impedance tomography method with physics-informed prior and coordinate-conditioned neural representation

Wu Yuehui^{1,2}, Bai Xinhao^{1,2}, Han Jianda^{1,2}, Yu Ningbo^{1,2}

(1. College of Artificial Intelligence, Nankai University, Tianjin 300350, China; 2. Institute of Intelligence Technology and Robotic Systems, Shenzhen Research Institute of Nankai University, Shenzhen 518083, China)

Abstract: Electrical impedance tomography (EIT) reconstructs the internal conductivity distribution from boundary voltage measurements induced by current excitation. However, its inverse problem is severely ill-posed. Conventional reconstruction methods generally suffer from low spatial resolution, whereas deep learning approaches can substantially improve image quality but rely heavily on paired voltage-conductivity data. This paper proposes a self-supervised learning EIT method with physics-informed priors and coordinate-conditioned neural representation. Built upon a first-order forward physical model, the proposed method establishes forward and backward cycle-consistency constraints between the image domain and the measurement domain, thereby enabling network training with unpaired data. To enhance the representation of continuous image domain and improve target boundary detail recovery, a coordinate-conditioned image generation network is developed. Specifically, the voltage sequence is reorganized as a pseudo-image for local feature extraction through convolutional layers, after which conductivity values are predicted pixel by pixel by jointly integrating global voltage features and coordinate-based positional encoding. In addition, a boundary consistency constraint and an adversarial learning strategy are introduced to further improve the structural fidelity of reconstructed images. The reconstruction results demonstrate that the proposed method outperforms other traditional and self-supervised learning methods in target localization, shape recovery, and artifact suppression. On the simulation dataset, the average correlation coefficient (CC), root mean square error (RMSE), and structural similarity index (SSIM) of

收稿日期: 2026-05-03 Received Date: 2026-05-03

* 基金项目: 国家自然科学基金 (U24A20284, 62473214)、天津市自然科学基金 (25JCZDJC01020) 项目资助

the proposed method are 0.919, 0.099, and 0.812, respectively. Compared with the most competitive baseline in the phantom experiments, the proposed method improves the average CC by 0.043, reduces the RMSE by 0.027, and increases the SSIM by 0.037 7. Moreover, the proposed method exhibits good robustness under noise conditions and enables high-quality image reconstruction without paired labeled data.

Keywords: electrical impedance tomography; self-supervised learning; physics-informed neural network; image reconstruction; coordinate-conditioned neural representation

0 引言

电阻抗层析成像 (electrical impedance tomography, EIT) 是一种利用边界电流激励与电压测量值反演内部电导率分布的成像方法^[1], 具有无创、无辐射和快速成像等优点, 在工业过程监测和生物医学成像领域具有广阔应用前景, 如两相流监测^[2]、触觉传感^[3]、肺通气监测^[4]和脑卒中辅助诊断^[5]等任务。然而, EIT 受限于分辨率低、边界模糊和建模误差等问题, 其根本原因在于由少量边界电压重建电导率分布属于非线性强不适定逆问题, 且软场特性会导致远离电极区域灵敏度衰减, 使得目标边界和局部细节难以恢复。

围绕上述问题, 已有研究首先从传统模型驱动方法入手, 通过显式引入先验约束提高逆问题求解稳定性。以 Tikhonov^[6]、全变分正则化^[7]和稀疏正则化^[8]为代表的方法, 都是在物理模型基础上引入不同形式的正则项抑制噪声和病态性。这类方法物理意义清晰、求解流程规范且可解释性强, 在工程应用中长期占据重要地位。然而, 单纯依赖最小二乘法与正则化的方法重建图像分辨率较低, 并且对超参数选择敏感^[9-10]。

近年来, 深度学习为 EIT 逆问题提供了新的求解思路^[11]。现有方法可分为监督学习和自监督学习两类。

监督学习方法利用配对的电压序列与电导率图像, 通过端到端神经网络、迭代展开网络或传统算法与深度网络级联结构, 学习测量域到图像域的非线性映射。Li 等^[12]利用计算机断层扫描影像构建三维肺部配对训练集, 并通过监督映射实现快速高分辨率重建, 说明引入解剖先验可显著提升特定场景成像性能。Hamilton 等^[13]提出了用于 EIT 实时图像重建的 Deep D-bar 方法, 该方法先由 D-bar 算法获得初始图像, 再采用级联 U-Net 提高空间分辨率并消除伪影。Wang 等^[14]提出 TransADMM, 将基于交替方向乘子法的迭代求解过程展开为可端到端训练的深度框架, 并利用 Transformer 增强的 U-Net 求解数据一致性子问题。总体而言, 监督学习方法具有较高的重建精度和较快的推理速度, 但需要大规模、多样化的配对电压-电导率训练数据^[15]。在实际工业和生物医学应用中, 检测区域内部的电导率分布难以直接测量, 高质量配对标签数据获取困难, 限制了此类方法的泛化性和实用性。

自监督学习方法通过利用深度网络的结构偏置、表征能力和物理约束, 尝试减少对电导率图像标签的依赖并提升重建性能。Liu 等^[16]提出了 DeepEIT 方法, 该方法将深度图像先验的正则化效应应用于 EIT 图像重建。在无需训练数据的情况下, 重建的图像优于传统正则化方法, 但需要额外的方法来稳定优化且重建耗时较长。Sun 等^[17]设计了一个自监督孪生网络, 以提高多模态 EIT 的空间分辨率。Guo 等^[18]通过构建前向电磁场模型并结合变分自编码器, 实现了微波三维数据反演, 并通过脑卒中成像的数值实验进行了验证。Shi 等^[19]使用扩散模型学习电导率图像的表征, 以条件生成方式实现电压到图像的重建, 但需要使用配对数据来训练前向模型。自监督方法在数据依赖性方面更具吸引力, 但现有研究仍存在物理约束有限、训练不稳定或先验信息利用不足等问题。

从已有工作可以看出, EIT 图像重建的关键在于有效融合神经网络非线性表征能力与物理先验, 以提升重建精度和泛化能力。基于此, 本文提出一种融合物理先验与坐标条件神经表示的自监督学习电阻抗成像方法。该方法将 EIT 前向物理模型嵌入网络训练, 在测量域和图像域之间构造正向与逆向循环一致性约束, 通过非配对电压-电导率数据优化网络, 在提高重建性能的同时降低对真实标签的依赖。设计了坐标条件表示的逆向图像生成网络, 融合局部特征、全局特征和位置编码, 对电导率分布进行逐点预测, 以增强目标轮廓和空间细节恢复能力。同时结合边界一致性约束与对抗学习机制, 提高结构保持和图像分布逼近能力。通过仿真与物理模体实验验证方法有效性, 并从收敛性、抗噪性、前向模型精度等角度进行了评估。

1 电阻抗成像原理

电阻抗成像基本思想是在被测区域边界施加激励电流并测量边界电压, 根据测量的电压序列反演区域内部电导率的分布。EIT 的数学模型包括正问题和逆问题, 正问题是指在已知电导率分布和注入电流的情况下求解边界电压。假设成像区域为 Ω , 内部电导率分布为 $\sigma(r)$, 则连续介质模型可表示为:

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

其中, $\phi(r)$ 为位置 r 处的电势。

给定的交流电通过附着在表面的电极对注入检测区域,随后从其他电极测量得到一组边界电压,待所有电极对都被依次选作激励后,可获得电压 U ,即:

$$U = \mathcal{F}(\sigma) \quad (2)$$

其中, $\mathcal{F}(\cdot)$ 表示非线性前向映射。

在实际应用中,差分 EIT 是最常用的形式^[20]。EIT 的逆问题旨在利用重建算法,根据电压序列差值重建电导率变化。由于电压测量数量远少于待重建像素数量,直接求解非线性逆映射具有显著不适定性,且图像重建易受建模误差、噪声影响。一般通过引入先验知识来求解逆问题,实现对被测区域电导率的变化可视化重建^[21-22]。逆问题的求解可表示为:

$$\Delta\sigma = \text{inv}(\Delta U, P) \quad (3)$$

其中, $\text{inv}(\cdot)$ 表示逆函数, P 表示先验知识。 $\Delta\sigma \in \mathbf{R}^N$ 是定义在像素上的离散电导率, $\Delta U \in \mathbf{R}^M$ 是电压测量值, N 和 M 分别表示离散电导率的维数和边界电压的数量。为表示方便,下文将 $\Delta\sigma$ 和 ΔU 表示为 σ 和 U 。

2 基于物理循环一致性的重建方法

本文将 EIT 正问题中的物理模型显式嵌入重建网络训练过程中,提出一种融合物理先验与坐标条件神经表示的自监督学习电阻抗成像方法。所提方法并未采用测量电压与电导率图像配对数据的监督学习方法,而是利用非配对数据,通过共享物理前向模型和逆向生成网络构建正向与逆向循环一致性,同时引入对抗学习策略,实现电导率图像的无监督学习图像重建,有效提升重建质量并减少对标签数据的依赖,仅在验证阶段使用配对数据计算重建指标。

如图 1 所示,所提方法主要由物理前向模型(即生成器 G_1)、逆向图像生成网络(生成器 G_2)和图像域判别器 D 这 3 个模块组成,其中 G_1 为基于灵敏度矩阵的一阶前向物理模型, G_2 为融合局部卷积特征、全局电压变量和坐标位置编码的生成器, G_1 和 G_2 实现图像域与测量域的转换,最终构建正向与逆向循环。




图 1 所提方法框图

Fig. 1 Overview of the proposed method

首先,将图像域非配对数据集的电导率图像 σ_1 ,经前向模型得到模拟电压序列 U_3 ,再送入逆向图像重建网络得到 σ_2 ,构成正向循环:

$$\sigma_1 \xrightarrow{G_1} U_3 \xrightarrow{G_2} \sigma_2 \quad (4)$$

对于非配对数据集的测量电压 U_1 ,生成器 G_2 重建图像 σ_3 ,再通过物理前向模型得到重投影的电压 U_2 ,构成逆向循环:

$$U_1 \xrightarrow{G_2} \sigma_3 \xrightarrow{G_1} U_2 \quad (5)$$

正向循环主要保证由真实图像经物理映射再反演重建后仍能保持原始电导率分布的信息,逆向循环主要保证由测量电压反演再经前向物理模型后仍能保持原始测量信息。通过正向、逆向循环的一致性联合优化,可在无配对条件下实现自监督训练。

2.1 物理前向模型构建

对于 EIT 正问题,采用完整电极模型 (complete electrode model, CEM) 进行建模,在给定电导率方程和边界条件的情况下,可通过有限元方法 (finite element method, FEM) 求解边界电压^[23]。但是,尽管 FEM 能够得到精确的边界电势,但计算耗时、资源消耗较大,并且难以实现高效的反向传播训练。相比之下,通过对电导率变化引起的电压响应进行建模,可以加快边界电压值的求解,并且有利于通过梯度下降方法更新逆向生成网络的参数。本文基于一阶泰勒近似^[24],构建灵敏度来表示由电导率变化到边界电压差值的关系,即:

$$\mathbf{S} = \begin{bmatrix} S_{1,1} & S_{1,2} & \cdots & S_{1,j} & \cdots & S_{1,N} \\ S_{2,1} & S_{2,2} & \cdots & S_{2,j} & \cdots & S_{2,N} \\ \vdots & \vdots & \ddots & \vdots & \ddots & \vdots \\ S_{M,1} & S_{M,2} & \cdots & S_{M,j} & \cdots & S_{M,N} \end{bmatrix} \quad (6)$$

$$S_{i,j} = - \int_{\Omega} \frac{\nabla \phi_i}{I_i} \frac{\nabla \phi_j}{I_j} d\Omega \quad (7)$$

其中, $\mathbf{S}$ 为灵敏度矩阵,表示电压测量对各像素电导率变化的响应程度。 ϕ_i 表示向第 i 个电极注入电流时所产生的电势, ϕ_j 表示向第 j 个电极注入电流时所产生的电势。于是,差分 EIT 的物理前向模型可表示为:

$$\mathbf{U} = \mathbf{S}\boldsymbol{\sigma} \quad (8)$$

如图 2 所示,对于给定的检测区域和激励测量模式,通过有限元方法分析分别获取第 i 、 j 个电极对激励时,测量场域内每个像素点的电势分布,利用式(7)计算出灵敏度图 $\mathbf{S} \in \mathbf{R}^{M \times (P \times P)}$, M 为激励测量的总次数, P 为分辨率。




图2 16 电极 EIT 系统与相邻激励测量模式

Fig. 2 16-electrodes EIT system using adjacent excitation and measurement pattern

2.2 基于坐标条件表示的逆向图像生成网络

本文设计坐标条件表示的逆向图像生成网络,用于由电压序列到电导率图像的非线性重建。与传统直接输出整幅图像的卷积网络不同,所设计网络首先从电压序列中提取全局和局部特征,然后结合空间坐标逐点预测电导率值,更适合表征电导率场的连续空间结构。

首先,根据激励测量模式将 208 维电压序列重排为 16×13 的二维向量,为便于后续卷积网络提取测量通道间的局部相关特征在宽度方向补零至 16×16 的单通道伪图像表示:

$$\tilde{\mathbf{U}} = P(\mathbf{U}) \in \mathbf{R}^{1 \times 16 \times 16} \quad (9)$$

随后,将 $\tilde{\mathbf{U}}$ 输入主干卷积神经网络,网络采用基于 U-Net 结构的编码与解码网络提取特征。通过两层卷积提取浅层特征,经两次下采样获得更高层表征;再通过两次上采样与跳跃连接恢复空间信息,最终得到 16×16 分辨率的特征图 $\mathbf{F}_{\text{fine}}$ 。其中,上采样采用最近邻插值来降低边界过度平滑现象。

除局部卷积特征外,通过多层感知机 (multilayer perceptron, MLP) 网络直接对原始 208 维电压向量进行编码,得到全局电压变量 $\mathbf{z}_g \in \mathbf{R}^{64}$ 。该分支用于补偿纯局部卷积网络对整体测量模式建模不足的问题,使网络在恢复电导分布时具有更强表征能力。 $\mathbf{z}_g$ 表示为:

$$\mathbf{z}_g = \text{MLP}(\mathbf{U}) \quad (10)$$

对于每个像素坐标 $\mathbf{p}_n = (x_n, y_n)$,采用坐标条件隐式解码器来生成重建的电导率图像。设输出图像大小为 64×64 ,通过傅里叶位置编码得到:

$$\gamma(\mathbf{p}_n) = \left(\mathbf{p}, \sin(2^0 \pi \mathbf{p}), \cos(2^0 \pi \mathbf{p}), \dots, \right. \\ \left. \sin(2^{L-1} \pi \mathbf{p}), \cos(2^{L-1} \pi \mathbf{p}) \right) \quad (11)$$

其中, $L=6$,多频位置编码有助于提升隐式网络对高频边界与细节结构的表达能力。

最后,通过双线性采样将 16×16 的局部特征图 $\mathbf{F}_{\text{fine}}$ 重采样到 64×64 图像网格上,得到每个像素对应的局部特征 $\mathbf{f}_n$ 。将局部特征 $\mathbf{f}_n$ 、全局变量 $\mathbf{z}_g$ 与坐标编码 $\gamma(\mathbf{p}_n)$ 投影到同一空间并进行加性融合,第 n 个坐标点的融合形式为:

$$\mathbf{h}_n = \phi_f(\mathbf{f}_n) + \phi_c(\gamma(\mathbf{p}_n)) + \phi_g(\mathbf{z}_g) \quad (12)$$

式中: $\phi_f(\cdot)$ 、 $\phi_c(\cdot)$ 、 $\phi_g(\cdot)$ 分别表示线性投影。融合特征 $\mathbf{h}_n$ 经 MLP 模块解码,通过 Sigmoid 函数映射输出像素电导率值:

$$\hat{\boldsymbol{\sigma}}_n = \text{Sigmoid}(\mathbf{w}^T \mathbf{h}_n + \mathbf{b}) \quad (13)$$

式中: $\mathbf{b}$ 为网络的偏置参数。训练初期利用较低的初始偏置提高训练稳定性,全部像素 $\hat{\boldsymbol{\sigma}}_n$ 共同组成重建图像 $\boldsymbol{\sigma}_3$,局部特征、全局特征与坐标查询的设计兼具不同尺度感受野建模能力与连续坐标表达能力。

2.3 基于物理循环一致性的自监督约束

基于非配对测量域样本 $\mathbf{U}_1$ 和图像域样本 $\boldsymbol{\sigma}_1$,分别在测量域与图像域之间构建正向和逆向循环,并通过物理一致性损失约束网络学习。正向循环从图像域开始,对于真实图像 $\boldsymbol{\sigma}_1$,利用灵敏度生成模拟电压 $\mathbf{U}_3$,同时考虑到真实电压与线性前向模型输出之间存在尺度差异,对每个样本执行独立的最大绝对值归一化:

$$U_3 = \mathcal{F}(\sigma_1) = S\sigma_1 \quad (14)$$

$$\bar{U}_3 = \frac{U_3}{\max(|U_3|) + \varepsilon} \quad (15)$$

将归一化的电压序列输入生成器得到 $\sigma_2 = G_2(\bar{U}_3)$, 理想情况下, σ_2 应尽可能逼近 σ_1 。采用带前景加权的像素级 L_1 损失:

$$\mathcal{L}_{\text{fwd}} = \frac{\sum_n M_n W_n |\sigma_{2,n} - \sigma_{1,n}|}{\sum_n M_n W_n + \varepsilon} \quad (16)$$

其中, M_n 为有效域掩膜, $W_n = 1 + (\alpha - 1) \mathbb{I}(\sigma_{1,n} > \tau)$ 为前景权重。对于前景像素, 给予更高惩罚权重, 以强化异常目标区域的恢复能力。该损失项约束了图像域到测量域到图像域的一致性。

为进一步约束图像结构, 在正向循环中引入基于 Sobel 梯度的边界损失。设 ∇_x 与 ∇_y 分别表示水平与垂直方向 Sobel 梯度, 则有:

$$\mathcal{L}_{\text{edge}} = \frac{\sum_n M_n \tilde{W}_n (|\nabla_x \sigma_2 - \nabla_x \sigma_1| + |\nabla_y \sigma_2 - \nabla_y \sigma_1|)}{\sum_n M_n \tilde{W}_n + \varepsilon} \quad (17)$$

$$\tilde{W}_n = 1 + (\beta - 1) \mathbb{I}(\sqrt{(\nabla_x \sigma_1)^2 + (\nabla_y \sigma_1)^2} > \tau_e) \quad (18)$$

其中, $\tilde{W}_n$ 根据真实图像梯度幅值是否超过阈值进行边缘加权。该项损失显著提升重建图像对目标轮廓与边界变化的敏感性。

逆向循环由测量域开始, 对于测量电压 U_1 , 生成器先输出重建图像 $\sigma_3 = G_2(U_1)$, 再由物理前向模型得到 U_2 , 对 U_1 和重投影电压 U_2 分别执行独立的最大绝对值归一化后, 计算测量域一致性损失:

$$\mathcal{L}_{\text{bwd}} = \|\bar{U}_2 - \bar{U}_1\|_2^2 \quad (19)$$

逆向循环一致性要求由测量反演得到的图像再经过物理前向投影回到原始测量域后, 应能尽可能原始的电压序列保持一致, 从而保证重建结果在物理意义上的一致性。

为了使重建图像不仅满足物理循环一致性, 同时符合真实电导率图像的分布特征, 在图像域额外引入对抗学习策略。判别器 D 输入单通道 64×64 电导率图像, 其中真实样本为无配对图像集中的 σ_1 , 伪样本为由测量重建得到的 σ_3 。判别器损失和对抗损失定义为:

$$\mathcal{L}_D = \mathbb{E}[\max(0, 1 - D(\sigma_1))] + \mathbb{E}[\max(0, 1 + D(\sigma_3))] \quad (20)$$

$$\mathcal{L}_{\text{adv}} = -\mathbb{E}[D(\sigma_3)] \quad (21)$$

对抗学习的作用并非替代物理约束, 而是在物理循环一致性的基础上进一步逼近真实图像分布, 从而改善重建图像的纹理合理性与边界真实性。

综合上述各项损失, 生成器优化目标写为:

$$\mathcal{L}_{G_2} = \lambda_{\text{fwd}} \mathcal{L}_{\text{fwd}} + \lambda_{\text{bwd}} \mathcal{L}_{\text{bwd}} + \lambda_{\text{edge}} \mathcal{L}_{\text{edge}} + \lambda_{\text{adv}} \mathcal{L}_{\text{adv}} \quad (22)$$

图像生成器 G_2 的参数通过最小化 $\mathcal{L}_{G_2}$ 更新, 判别器则通过最小化 $\mathcal{L}_D$ 损失更新。在推理阶段, 仅需将测量的电压序列独立归一化后输入训练完成的逆向生成网络 G_2 , 即可获得目标电导率分布图像。

2.4 模型训练与验证

本文采用仿真数据集和实验数据集来验证所提方法的性能。仿真数据集利用 COMSOL Multiphysics 的 Live Link for Matlab 生成, 待成像区域定义为一个半径为 7.5 cm 的二维圆形模型。将 1~3 个成像目标位置随机地放置在检测区域内, 目标包含圆形、矩形和三角形。如图 3(a) 所示, 为几个典型的电导率分布图像。随机设置每个目标的电导率值在 0.1~1.2 S/m 范围。值得一提的是, 通常 EIT 重建图像中的目标比较模糊, 对于边界锐利角的成像效果较差, 对于矩形、三角形目标的重建极大地提高了成像难度。

对二维圆形成像区域构建有限元模型, 划分三角形网格如图 3(b) 所示, 采用相邻激励与相邻测量模式^[25], 其中一组相邻电极激励时的测量场域电势分布在图中给出。通过有限元计算获取电极电压数据, 每一帧电压序列一共包含 208 个电压值。对于单个目标、双目标和三目标分别计算了 4 096 个训练样本, 并且获取每个样本对应的电导率图像。图像划分为 $P \times P$ 个正方形网格, 正方形中心的电导率表示为网格像素值, 圆域内的像素为有效像素点。综合考虑图像质量与成像时间, 本文将重建图像设置为 64×64 pixels, 其中 3 228 个像素为有效像素。需要注意的是训练样本中的电导率图像仅用于计算定量指标。生成了同样数量的非配对的电导率图像用于网络训练。以同样的数据生成方式获取了单个目标、双目标、三目标各 512 个样本用于测试。




图3 正问题与逆问题所用模型

Fig. 3 Models used for forward and inverse problems

实验数据通过图 4 所示的 16 电极 EIT 系统在盐水槽体模上进行采集。成像区域的尺寸和激励测量方式与数值仿真中的一样。在数据采集过程中,将不同组合的圆形、矩形和三角形琼脂块或聚氨酯棒放入盐水中,构造 1~3 个成像目标。琼脂块基于水、氯化钠和琼脂制成,通过控制氯化钠的浓度使琼脂块的电导率在 0.14~1 S/m。随机移动这些成像目标,EIT 系统实时采集电压数据,共采集 8 200 帧数据用于训练神经网络,采集额外的数据用于验证。




图 4 实验所用的 EIT 系统

Fig. 4 EIT system used in the experiment

本文方法基于 PyTorch 深度学习框架实现,实验硬件配置为 NVIDIA GeForce RTX 3060 GPU,选择 CUDA 加速训练。网络中基础卷积通道数设 32,全局电压特征维度设为 64,位置编码频率数为 6。训练时批大小为 64,训练轮数设为 100,生成器与判别器学习率分别设为 1×10^{-3} 和 5×10^{-5} ,权重衰减系数设为 1×10^{-6} 。损失权重设置为 $\lambda_{\text{fwd}} = 10.0$ 、 $\lambda_{\text{bwd}} = 10.0$ 、 $\lambda_{\text{edge}} = 2.0$ 。为提升训练稳定性,判别器在第 20 轮启动,每 2 步更新 1 次,对生成器与判别器均执行梯度范数裁剪,并设置生成器学习率高于判别器,以减轻对抗训练中判别器过强的问题。

3 结果与讨论

为系统验证所提方法的有效性,本文从训练收敛性、抗噪稳健性、前向物理模型精度以及重建性能方面展开分析。首先,通过训练损失与验证指标曲线观测了网络优化过程的稳定性与收敛性;结合不同噪声水平下的性能变化讨论了方法对测量扰动的敏感性;随后,比较不同离散精度前向模型的电压映射误差与计算时间,说明本文采用 64×64 前向模型的合理性;最后,分别在仿真数据和物理模体实验数据上,与典型数值方法和深度学习方法进行对比,以验证所提方法在结构保持、边界恢复等方面的重建性能。

3.1 收敛性与鲁棒性分析

图 5(a) 给出了训练阶段的收敛曲线。从图 5 中可以看出,生成器总损失以及前向、逆向循环损失在训练初期均快速下降,随后逐步进入平稳收敛阶段,表明由物理循环一致性构成的自监督目标函数能够为网络提供稳定而有效的优化方向。正向循环从图像域约束重建结果保持原始电导率分布信息,逆向循环从测量域约束重建结果满足边界电压的一致性,两类损失共同约束了可行解空间,整个训练过程中未出现明显的震荡发散现象,仅在引入判别器后,总损失出现小幅度的波动,经过约 25 轮次的优化,损失又继续稳定下降。此外,由损失曲线可以看出,未出现过拟合或者欠拟合的现象。

进一步结合图 5(b) 中的验证指标变化可见,随着训练推进,相关系数 (correlation coefficient, CC) 与结构相似度 (structural similarity index, SSIM) 整体呈上升趋势,而均方根误差 (root mean square error, RMSE) 持续下降并在后期趋于稳定。这说明网络不仅能够测量拟合边界电压,而且能够学习到相对于前向模型的电压测量值到电导率图像的非线性映射,并且逐步恢复更合理的空间结构。尤其是 SSIM 的持续提升表明,模型对轮廓与局部结构的细节重建能力得到增强。




图 5 训练时的收敛曲线与评价指标曲线

Fig. 5 Loss and evaluation curves during training

为进一步评估模型的抗噪性能,本文在测试集原始电压上按不同比例加入高斯噪声。噪声标准差按单个通道最大绝对电压值的固定比例设定,更接近实际 EIT 测量中不同样本受扰动的情形。在 0%~10% 的噪声区间内进行图像重建,计算了测试集中每个样本的 CC、RMSE 和 SSIM,定量指标的均值及结果分布如图 6 所示。

从图 6 中可以看出,随着噪声水平增加,CC 和 SSIM 总体呈下降趋势,RMSE 逐步升高,这是测量信噪比降低后不可避免的结果。尽管噪声对深度学习方法的影响较




图 6 不同噪声下的定量评估

Fig. 6 Quantitative evaluation under different noise levels


大,但需要指出的是,大多数 EIT 系统的信噪比 (signal-to-noise ratio, SNR) 均高于 50 dB。图 6 中 3 项指标的变化曲线整体变化地较为平缓,未出现突变式退化,说明所提方法对中等强度噪声具有较好的稳健性。逆向循环一致性限制了重建图像在测量域中的一致性使得重建图像不会出现大的偏差,而正向循环和边界一致性损失则抑制了噪声引起的局部伪影,使得模型在噪声存在时仍能保持主要重建目标的位置与轮廓信息。

3.2 不同精度前向物理模型对比


前向物理模型的精度直接影响循环一致性约束的有效性。若前向模型精度过低,则电压映射误差会被直接引入训练过程;若前向模型过于精细,虽然能够提升映射精度,但会显著增加训练与推理开销。因此,本节基于正问题对测量域离散化并划分不同分辨率的网格,比较了不同网格划分下构建的线性前向模型在电压映射精度与计算开销上的差异,包括 16×16、32×32、64×64、128×128 和 256×256 这 5 种分辨率。

通过前向模型计算了如图 7(a) 所示电导率分布对应的电压序列并进行归一化,以有限元模型生成的电压测量值为基准,在图中给出了不同分辨率模型的残差。可以看出,前向模型分辨率较低时,其电压映射残差在各测量通道上较为明显,尤其在电压变化较剧烈的区段,残差幅值更大。随着网格分辨率提高,残差整体呈下降趋势,说明更精细的离散模型能够更充分地刻画电导率分布变化对边界电压的影响。图 7(b) 进一步给出了 16×16 与 64×64

两种前向模型的映射电压对比。将有限元生成的电压与前向映射得到的电压值进行最大值归一化。可以看到,16×16 模型能够大致拟合 FEM 生成的电压值,但在若干测量通道上存在偏差。相比之下,64×64 模型的映射曲线与 FEM 的参考结果更加接近,且整体趋势保持更好。



(a) 不同分辨率前向模型的误差
(a) Errors of forward models with different resolutions



(b) 16×16与64×64前向模型对比
(b) Comparison of 16×16 and 64×64 forward model

图 7 不同分辨率前向模型映射精度对比

Fig. 7 Comparison of mapping accuracy of forward models with different resolutions

此外,表 1 给出了不同分辨率前向模型的电压映射误差和时间。随着前向模型分辨率从 16×16 提高到 64×64,平均相对误差由 0.499 显著降至 0.130,分别较 16×16 和 32×32 模型降低 73.95% 和 45.15%,说明过低分辨率的前向模型难以准确描述边界电压与像素电导率之间的映射关系。进一步将分辨率提升至 128×128 和 256×256 时,平均相对误差进一步下降,但改进幅度分别仅为 11.54% 和 13.08%,而前向计算时间却增至 64×64 模型的 3.96 倍和 13.38 倍。综合考虑映射精度和计算代价,64×64 前向模型已经取得较优平衡,因此被选作本文训练与重建阶段的前向物理模型。

表 1 不同分辨率前向模型的电压映射误差和时间
Table 1 Voltage mapping error and time of forward models with different resolutions

像素数	平均相对误差	前向计算时间/s
16×16	0.499	0.000 285
32×32	0.237	0.000 695
64×64	0.130	0.001 300
128×128	0.115	0.005 150
256×256	0.113	0.017 400

此外,为评估模型复杂度与运行效率,对本文方法进行了参数量、浮点运算量及训练重建时间统计。结果表明,模型完整训练耗时为 1.03 h,生成器 G_2 的参数量为 67.3 万,前向推理计算量为 1.205 十亿次浮点运算(giga floating-point operations,GFLOPs)。在重复 200 次测试的条件下,平均单次推理时间为 3.8023 ± 0.88 ms。所提方法在保持较低参数规模的同时,具有较高的推理效率。

3.3 仿真数据下的图像重建结果

本文首先在仿真数据集上比较各方法的重建性能。选择 GREIT (Graz consensus reconstruction algorithm for electrical impedance tomography)、SR (sparse reconstruction)、Deep D-bar、SCNN (supervised convolutional neural network) 和 CDiffusion 方法作为对比方法,其中 GREIT 为经典的电阻抗成像方法^[26],SR 为基于 L1 范数的稀疏重建方法^[27],Deep D-bar 为细化 D-bar 初始重建的深度学习方方法^[13],SCNN 是基于配对样本训练的监督学习卷积神经网络方法^[28],CDiffusion 为参考 Shi 等^[19]工作的基于扩散先验与数据一致性优化的自监督方法。对于重建的图像,通常采用 CC、RMSE 和 SSIM 进行评价^[29]。CC 反映重建图像与真实图像的整体相关程度, RMSE 表征像素级幅值的误差,SSIM 则更强调结构与局部细节与真值的一致性。3 项指标分别侧重相关性、强度误差和结构保持,从 3 个角度对 EIT 重建结果综合评估。为体现不同成像难度下的性能,测试集按目标数量划分为 3 组,记为测试集 1(test dataset 1, TeD1)、测试集 2(test dataset 2, TeD2)和测试集 3(test dataset 3, TeD3),分别对应单目标、双目标和三目标场景。随着目标数量增加以及矩形、三角形等目标比例提高,TeD3 的重建难度明显高于 TeD1。图 8 给出了 6 个典型样本的重建结果,第 1 列是样本的真值,每个方法下左侧为重建图像、右侧为误差图。

可以看出,GREIT 方法能够恢复目标的大致位置,但目标明显模糊;SR 方法在稀疏场景下可突出目标区域,




图 8 仿真数据上的图像重建结果

Fig. 8 Image reconstruction results on simulated data

但在多目标条件下容易出现尺寸偏差和局部变形。深度学习方法能够学习到图像的特征,重建质量有所改善。Deep D-bar 和 SCNN 改善了成像清晰度,但在一些尖锐边界和相邻多目标场景下存在边缘平滑现象;CDiffusion 重建的异常区域幅值变化明显,与真值差异大。相比之下,所提方法在目标定位、边界完整性和多目标恢复方面表现更均衡,尤其对于矩形、三角形等高曲率边界目标,仍能保持较好的形状保真度。

表 2 给出了 3 组测试集上的定量评价结果(表头中的箭头“↑”和“↓”分别表示指标越大越好和指标越小越好)。对于 TeD1,所提方法的 RMSE 为 0.073,与 SCNN 并列最低,同时 SSIM 达到 0.871,为该组最高,说明在单目标场景下所提方法在保持较低误差的同时,更好地恢复结构细节。对于 TeD2 和 TeD3,所提方法的 CC 和 RMSE 虽略低于 SCNN,但 SSIM 分别达到 0.814 和 0.752,均为各方法最高,表明在多目标和复杂几何形状条件下,所提方法在轮廓连续性、目标辨识和局部结构保持方面更具优势。从定量评价可以看出 SCNN 方法的重建性能较好,然而需要注意的是,这类基于监督学习的方法严重依赖于训练数据,在 EIT 应用场景在难以获取标签数据,实际中泛化性能较弱。

表 2 仿真数据集重建图像的定量评价

Table 2 Quantitative evaluation of reconstructed images from simulated datasets										
方法	有无监督	TeD1			TeD2			TeD3		
		CC ↑	RMSE ↓	SSIM ↑	CC ↑	RMSE ↓	SSIM ↑	CC ↑	RMSE ↓	SSIM ↑
TK	无监督	0.880	0.139	0.642	0.814	0.147	0.546	0.827	0.171	0.472
SR	无监督	0.888	0.143	0.783	0.838	0.148	0.705	0.792	0.188	0.611
Deep D-bar	有监督	0.920	0.092	0.844	0.899	0.108	0.794	0.892	0.127	0.743
SCNN	有监督	0.959	0.073	0.822	0.923	0.093	0.774	0.917	0.113	0.738
CDiffusion	自监督	0.915	0.104	0.790	0.895	0.109	0.735	0.881	0.131	0.655
所提方法	自监督	0.952	0.073	0.871	0.913	0.099	0.814	0.894	0.126	0.752

从 3 组数据的平均结果看,所提方法的平均 SSIM 为 0.812,而平均 RMSE 为 0.099,低于 CDiffusion 和 Deep D-bar。综合可视化结果与定量评价可以认为,所提自监督方法取得了较高的图像重建精度,达到了和监督学习方法可比的性能。

3.4 物理模体实验的图像重建结果

真实系统中存在电极接触阻抗、边界建模误差以及更加复杂噪声等,为进一步考察模型的性能,本文在 16 电极盐水槽及物理模体实验平台上,对所提方法与各基线方法对比验证。图 9(a)给出了 6 个实验样本,将制备的不同电导率及形状的琼脂棒作为重建目标放置在盐水槽中,根据槽底定位板确定目标位置,进而生成相应图像真值数据用于计算性能指标。

图 9(b)为重建的图像,可以看出传统 GREIT 在多数样本中仍能定位异常的大致区域,但边界扩散较为明显;SR 对噪声和模型误差影响更敏感,部分重建的样本出现形状变形。基于监督学习的方法在仿真数据集上进行训练,然后基于少量真实数据进行微调。Deep D-bar 和 SCNN 在成像目标的清晰度上优于传统方法,但在目

标靠近边界或多个目标相邻时仍存在尺寸偏差;CDiffusion 在部分样本上能够恢复主要异常区域,但不同样本间波动较大。相比之下,所提方法实现了更接近真实分布的重建结果,目标位置、相对尺寸关系以及电导率变化值均更准确,从重建图像来看实现更好的结果。

表 3、4 和 5 给出了实验数据的定量评估结果。所提方法在 6 个样本上取得最高 CC 和最低 RMSE,同时 SSIM 也均为各方法最高,说明该方法不仅在像素强度层面更接近真实分布,而且在结构保持方面达到了更好的性能。具体而言,所提方法的平均 CC、RMSE 和 SSIM 分别为 0.902 5、0.113 和 0.789 2;相较平均表现最优的基线 Deep D-bar,其平均 CC 提高 0.043, RMSE 降低 0.027, SSIM 提高 0.037 7。特别是在案例 8、9 和 11 的重建中,所提方法的优势更加明显。以上说明所提方法在实验场景中相较于基线对比方法取得了最优结果。

表 3 实验数据重建图像的相关系数
Table 3 CC of reconstructed images from experimental data

方法	案例 7	案例 8	案例 9	案例 10	案例 11	案例 12
TK	0.873	0.893	0.764	0.876	0.864	0.850
SR	0.731	0.871	0.696	0.832	0.730	0.735
Deep D-bar	0.900	0.871	0.774	0.867	0.881	0.864
SCNN	0.898	0.876	0.788	0.870	0.761	0.798
CDiffusion	0.879	0.623	0.809	0.867	0.783	0.824
所提方法	0.933	0.927	0.869	0.897	0.902	0.887

表 4 实验数据重建图像的均方根误差
Table 4 RMSE of reconstructed images from experimental data

方法	案例 7	案例 8	案例 9	案例 10	案例 11	案例 12
TK	0.124	0.100	0.178	0.121	0.179	0.188
SR	0.174	0.121	0.204	0.157	0.249	0.253
Deep D-bar	0.108	0.106	0.172	0.126	0.151	0.177
SCNN	0.106	0.105	0.165	0.112	0.228	0.204
CDiffusion	0.101	0.185	0.151	0.124	0.203	0.188
所提方法	0.087	0.072	0.136	0.104	0.127	0.152

表 5 实验数据重建图像的结构相似度
Table 5 SSIM of reconstructed images from experimental data

方法	案例 7	案例 8	案例 9	案例 10	案例 11	案例 12
TK	0.439	0.655	0.415	0.630	0.424	0.419
SR	0.692	0.796	0.651	0.670	0.540	0.515
Deep D-bar	0.823	0.826	0.679	0.778	0.728	0.675
SCNN	0.799	0.809	0.615	0.759	0.592	0.587
CDiffusion	0.701	0.664	0.669	0.635	0.567	0.550
所提方法	0.861	0.879	0.716	0.804	0.759	0.716




图 9 实验数据上的图像重建结果

Fig. 9 Reconstruction results based on experimental data

4 结 论

本文针对电阻抗成像中重建质量差、深度学习方法依赖标签数据等问题,提出了一种基于物理循环一致性与坐标条件表示的自监督学习电阻抗成像方法。该方法以一阶物理前向模型为基础,在测量域与图像域之间分别构建正向循环和逆向循环,从而在无配对标签条件下实现逆映射网络的训练。同时,设计了融合局部卷积特征、全局电压变量和坐标位置编码的坐标条件解码网络,以增强对电导率场连续空间结构的表达能力,并通过边界一致性约束和对抗学习进一步改善目标轮廓恢复能力。仿真和物理模体实验结果表明,所提方法在无配对训练条件下在目标定位、目标辨识以及整体结构恢复方面均表现出较好的性能,与经典数值求解方法及基于生成模型的方法相比,所提方法在取得了更优的定量评价结果,达到了和监督学习方法相当的性能。此外,线性前向模型的训练和推理兼顾了物理一致性与计算效率,使得该方法在参数规模和重建速度方面具有一定工程应用潜力。

然而需要指出的是,受逆问题欠定性和前向模型近似能力的限制,当前方法对尖角边界的恢复仍存在一定不足。后续工作将围绕以下 3 个方向展开:1)引入可微分的非线性前向模型,以进一步提高物理建模精度;2)结合生成模型的先验信息,增强对复杂几何目标的重建能力;3)开展更大规模实验验证,进一步提升方法在工业检测与生物医学成像场景中的泛化性和实用性。

参考文献

- [1] 吴阳,刘凯,陈柏,等. 自适应粒子群优化算法优化径向基函数神经网络用于电阻抗成像图像重建[J]. 仪器仪表学报, 2020, 41(6): 240-249.
- WU Y, LIU K, CHEN B, et al. Image reconstruction for electrical impedance tomography using radial basis function neural network optimized with adaptive particle swarm optimization algorithm [J]. Chinese Journal of Scientific Instrument, 2020, 41(6): 240-249.
- [2] TAN CH, LI F, LYU SH H, et al. Gas-liquid two-phase stratified flow interface reconstruction with sparse batch normalization convolutional neural network [J]. IEEE Sensors Journal, 2021, 21(15): 17076-17084.
- [3] PARK K, YUK H, YANG M J, et al. A biomimetic

elastomeric robot skin using electrical impedance and acoustic tomography for tactile sensing [J]. Science Robotics, 2022, 7(67): abm7187.

- [4] 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.
- [5] ZHANG W R, JIAO Y, ZHANG T, et al. Early detection of acute ischemic stroke using contrast-enhanced electrical impedance tomography perfusion [J]. NeuroImage: Clinical, 2023, 39: 103456.
- [6] CHEN Y X, DONG F, TAN CH. Space-constrained optimized Tikhonov regularization method for 3D hemorrhage reconstruction by open magnetic induction tomography [J]. Physics in Medicine & Biology, 2022, 67(22): 225012.
- [7] 李曦婷,高云鹏,谢琴,等. 基于 TV-KF 的矿浆液位电阻抗成像方法研究[J]. 仪器仪表学报, 2025, 46(2): 141-151.
- LI X T, GAO Y P, XIE Q, et al. Research on electrical impedance tomography method for mineral slurry level based on TV-KF [J]. Chinese Journal of Scientific Instrument, 2025, 46(2): 141-151.
- [8] 马敏,余浪,范文茹. 基于 L1/L2 正则化电阻抗层析成像算法的碳纤维增强复合材料损伤检测[J]. 激光与光电子学进展, 2023, 60(2): 225-232.
- MA M, YU L, FAN W R. Detection of carbon-fiber-reinforced polymer damage based on l1/l2 regularization electrical impedance tomography algorithm [J]. Laser & Optoelectronics Progress, 2023, 60(2): 225-232.
- [9] SHEN CH Y, GONZALEZ Y, CHEN L Y, et al. Intelligent parameter tuning in optimization-based iterative CT reconstruction via deep reinforcement learning [J]. IEEE Transactions on Medical Imaging, 2018, 37(6): 1430-1439.
- [10] XU Y B, PEI Y, DONG F. An adaptive Tikhonov regularization parameter choice method for electrical resistance tomography [J]. Flow Measurement and Instrumentation, 2016, 50: 1-12.
- [11] 李峰,谭超,董峰. 全连接深度网络的电学层析成像

- 算法[J]. 工程热物理学报, 2019, 40(7): 1526-1531.
- LI F, TAN CH, DONG F. Fully connected deep network algorithm for electrical impedance tomography [J]. Journal of Engineering Thermophysics, 2019, 40(7): 1526-1531.
- [12] LI ZH W, WU Y, XU T CH, et al. A fast 3D lung image reconstruction method based on CT pixel matrices learning with electrical impedance tomography [J]. Measurement, 2025, 251: 117176.
- [13] 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.
- [14] WANG Z CH, ZHANG T, ZHAO T CH, et al. TransADMM: Transformer enhanced unrolling alternating direction method of multipliers framework for electrical impedance tomography [J]. Expert Systems with Applications, 2025, 276: 127007.
- [15] 黄世洋, 谭超, 梁光辉, 等. 半监督学习 MultiU-Net 网络的 ERT 图像重建方法[J]. 仪器仪表学报, 2026, 47(3): 212-222.
- HUANG SH Y, TAN CH, LIANG G H, et al. Image reconstruction of ERT using semi-supervised learning MultiU-Net network [J]. Chinese Journal of Scientific Instrument, 2026, 47(3): 212-222.
- [16] LIU D, WANG J W, SHAN Q X, et al. DeepEIT: Deep image prior enabled electrical impedance tomography[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2023, 45(8): 9627-9638.
- [17] SUN J Y, ZHU Q D, FANG H, et al. Multi-modal EIT image reconstruction using deep similarity prior [C]. 2024 IEEE International Instrumentation and Measurement Technology Conference, 2024: 1-6.
- [18] GUO R, LIN ZH CH, XIN J Y, et al. Three dimensional microwave data inversion in feature space for stroke imaging[J]. IEEE Transactions on Medical Imaging, 2024, 43(4): 1365-1376.
- [19] SHI D P, ZHENG W D, GUO D, et al. Conditional diffusion model for electrical impedance tomography[J]. IEEE Transactions on Instrumentation and Measurement, 2025, 74: 4504513.
- [20] ZHANG K, WANG L, GUO R, et al. A deep generative model-integrated framework for 3-D time-difference electrical impedance tomography[J]. IEEE Transactions on Instrumentation and Measurement, 2023, 72: 4501212.
- [21] SHI SH K, KANG R Y, LIATSIS P. Fast electrical impedance tomography with hybrid priors [J]. IEEE Transactions on Computational Imaging, 2026, 12: 573-586.
- [22] WANG Z CH, ZHANG T, ZHANG X Y, et al. Unsupervised sensitivity prior generation with diffusion model for EIT image reconstruction [J]. IEEE Transactions on Industrial Informatics, 2026, 22(4): 3400-3411.
- [23] BRONK T S, EVERITT A C, MURPHY E K, et al. Novel electrode placement in electrical bioimpedance-based stroke detection: Effects on current penetration and injury characterization in a finite element model [J]. IEEE Transactions on Biomedical Engineering, 2022, 69(5): 1745-1757.
- [24] ADLER A, BOYLE A. Electrical impedance tomography: Tissue properties to image measures[J]. IEEE Transactions on Biomedical Engineering, 2017, 64(11): 2494-2504.
- [25] 王琦, 尹鑫铭, 李晓捷, 等. 肺部电阻抗成像电极阵列优化方法研究[J]. 电子测量与仪器学报, 2022, 36(6): 55-65.
- WANG Q, YIN X M, LI X J, et al. Optimization of electrode array for lung electrical impedance tomography[J]. Journal of Electronic Measurement and Instrumentation, 2022, 36(6): 55-65.
- [26] ADLER A, ARNOLD J H, BAYFORD R, et al. GREIT: A unified approach to 2D linear EIT reconstruction of lung images[J]. Physiological Measurement, 2009, 30(6): S35-S55.
- [27] SHI Y Y, WU Y H, WANG M, et al. Sparse image reconstruction of intracerebral hemorrhage with electrical impedance tomography[J]. Journal of Medical Imaging, 2021, 8(1): 014501.
- [28] LI F, TAN CH, DONG F, et al. V-Net deep imaging method for electrical resistance tomography [J]. IEEE Sensors Journal, 2020, 20(12): 6460-6469.
- [29] XIA H Y, SHAN Q X, WANG J W, et al. NAS powered deep image prior for electrical impedance tomogra-

phy[J]. IEEE Transactions on Computational Imaging, 2024, 10: 1165-1174.

作者简介



武跃辉,2019 年于河南理工大学获得学士学位,2022 年于河南师范大学获得硕士学位,现为南开大学博士研究生,主要研究方向为深度学习、电学成像、图像重建等。

E-mail:yuehuiwu@mail.nankai.edu.cn

Wu Yuehui received his B. Sc. degree from Henan Polytechnic University in 2019, and his M. Sc. degree from Henan Normal University in 2022. He is currently a Ph. D. student at Nankai University. His main research interests include deep learning, electrical tomography and image reconstruction, etc.



于宁波(通信作者),2003 年于天津大学获得学士学位,2005 年于香港科技大学获得硕士学位,2011 年于瑞士苏黎世联邦理工学院获得博士学位,现为南开大学英才教授,主要研究方向为医疗康复机器人、医疗人工智能。

E-mail:nyu@nankai.edu.cn

Yu Ningbo (Corresponding author) received his B. Sc. degree from Tianjin University in 2003, his M. Sc. degree from Hong Kong University of Science and Technology in 2005, and his Ph. D. degree from ETH Zurich in 2011. He is currently a professor at Nankai University. His main research interests include medical rehabilitation robot, medical artificial intelligence.