

DOI: 10.19650/j.cnki.cjsi.J2514384

半监督学习 MultiU-Net 网络的 ERT 图像重建方法*

黄世洋¹, 谭超¹, 梁光辉¹, 任继坤¹, 董峰^{1,2}

(1. 天津大学电气自动化与信息工程学院 天津 300072; 2. 天津仁爱学院信息与智能工程学院 天津 301636)

摘 要:电阻层析成像(ERT)作为一种非侵入式断层扫描技术,在地质勘探、工业检测和生物医学等领域具有广泛的应用前景。由于其逆问题求解存在病态性与非线性特征,传统图像重建算法在成像精度、鲁棒性方面难以满足复杂工况下的应用需求。近年来,基于深度学习的电阻层析成像图像重建方法展现出强大的非线性映射能力,有效提升了图像重建精度,但仍面临高度依赖大规模标注训练数据集、泛化能力弱、抗噪性能不足等瓶颈。针对上述问题,提出了一种半监督学习 MultiU-Net 网络的电阻层析成像图像重建算法。该网络以一致性约束的半监督学习策略为基础,采用编码器和解码器为主要框架,降低了模型对训练数据的依赖,具有较强的泛化能力和抗噪能力;将通道注意力优化机制引入到网络的特征提取部分,自适应地调整特征通道的权重分布,提升了模型的训练效率和特征表达能力,从而提高图像重建精度。无标签数据占比优化实验表明,标注数据占训练数据比例为 50% 时成像效果最优。抗噪性测试实验表明,模型成像效果在 30 dB 时仍保持稳定,50 dB 时几乎无失真。仿真、静态与动态图像重建实验结果表明,与线性反投影算法(LBP)、Tikhonov 算法、Landweber 算法以及卷积神经网络-视觉几何组算法相比,MultiU-Net 网络在图像重建视觉效果与重建精度上具有更好的性能。

关键词:电阻层析成像;半监督学习;MultiU-Net 网络;通道注意力机制

中图分类号: TP23 TH86 **文献标识码:** A **国家标准学科分类代码:** 510.8040

Image reconstruction of ERT using semi-supervised learning MultiU-Net network

Huang Shiyang¹, Tan Chao¹, Liang Guanghui¹, Ren Jikun¹, Dong Feng^{1,2}

(1. School of Electrical and Information Engineering, Tianjin University, Tianjin 300072, China;

2. School of Information and Intelligent Engineering, Tianjin Renai College, Tianjin 301636, China)

Abstract:Electrical resistance tomography (ERT), as a non-invasive tomographic technique, has broad application prospects in fields such as geological exploration, industrial inspection, and biomedicine. Due to the ill-posedness and nonlinearity inherent in its inverse problem, conventional image reconstruction algorithms struggle to meet the demands of complex operating conditions in terms of imaging accuracy and robustness. In recent years, deep learning-based image reconstruction methods for electrical resistance tomography have demonstrated strong nonlinear mapping capabilities and effectively improved imaging accuracy. However, they still face bottlenecks such as heavy reliance on large-scale labeled training datasets, weak generalization capability, and insufficient noise immunity. To address these issues, a semi-supervised learning MultiU-Net network is proposed for ERT image reconstruction. Built upon a consistency-constrained semi-supervised learning strategy with an encoder-decoder framework, this network reduces dependence on labeled training data while improving generalization and anti-noise performance. A channel attention optimization mechanism is introduced into the feature extraction module to adaptively adjust the weight distribution of feature channels, thereby enhancing training efficiency and feature representation capability, and consequently improving image reconstruction accuracy. Experiments on unlabeled data ratio optimization show that optimal imaging performance is achieved when labeled data constitutes 50% of the training dataset. Noise immunity tests demonstrate that the reconstructed images remains stable under 30 dB Gaussian white noise and exhibits almost no distortion at 50 dB. Results from simulation, static, and dynamic image reconstruction experiments indicate that, compared with the linear back projection

收稿日期: 2025-08-14 Received Date: 2025-08-14

* 基金项目: 国家自然科学基金项目(62201381)、天津市自然科学基金项目(25JCQNJC01660)资助

(LBP) algorithm, Tikhonov algorithm, Landweber algorithm, and Convolutional Neural Network-Visual Geometry Group algorithm, the MultiU-Net network achieves superior performance in both visual quality and reconstruction accuracy.

Keywords: ERT; semi-supervised learning; MultiU-Net network; channel attention optimization mechanism

0 引言

电阻层析成像(electrical resistance tomography, ERT)技术诞生于 20 世纪 80 年代后期,是电学层析成像(electrical tomography, ET)技术的重要分支^[1]。电阻层析成像具有非侵入、无辐射、测量速度快、硬件成本低等优势^[2],在地质勘探^[3-4]、工业过程检测^[5-6]、生物医学成像^[7-8]等领域具有广阔的应用前景。

图像重建算法作为逆问题求解的核心,直接决定电导率分布图像的准确性。根据求解过程中是否建立线性假设,图像重建算法可分为线性重建算法和非线性重建算法。线性重建算法又可分为直接线性化算法与迭代线性化算法^[9]。直接线性化算法包括线性反投影算法^[10](linear back projection, LBP)、Tikhonov 正则化算法^[11-12]、一步牛顿重建算法^[13](newton's one-step error reconstructor, NOSER)等。直接线性化算法具有计算流程简洁、运算效率高的特点,但成像质量较低,主要用于定性分析或作为其他方法的初始解。迭代算法包括 Landweber 算法^[14-15]、总变差(total variation, TV)正则化^[16-17]、共轭梯度法^[18-19]、牛顿-拉夫逊法^[20]等。迭代线性算法具有更高的图像重建精度,但依赖多次迭代优化,其实时性能有待提升。非线性重建算法包含 D-bar 算法^[21]、分解法^[22]等,可以解决线性重建方法无法处理的复杂电导率分布问题,但其重建精度易受检测误差和模型误差的影响。在基于有限元法的图像重建中,网格剖分的质量直接影响求解精度,因此有研究人员针对图像重建过程提出了网格优化策略,如梯度引导电学成像自适应网格生成方法^[23],为传统重建算法的改进提供了新思路。

近年来,深度学习技术得到快速发展,并成功运用到多个领域^[24-28]。由于具有强大的数据拟合能力和非线性建模能力,研究人员开始将深度学习技术运用到 ET 图像重建。Tan 等^[29]将卷积神经网络(convolutional neural network, CNN)运用到 ERT 图像重建过程,该网络在经典结构 LeNet 的基础上进行改进,具有较好的图像重建精度和鲁棒性。Li 等^[30]基于 CNN 设计了一种具有 33 层结构的 V 型网络(V-Net),该网络能充分提取传感区域的空间信息,提升了图像重建精度。Wu 等^[31]通过添加归一化层、指数线性单元(exponential linear units, ELU)激活函数、径向基函数(radial basis function, RBF)神经网络和全局平均池化层优化了电阻抗层析成像结果。端到

端的神经网络方法在电学成像中表现出较好的潜力,但过度依赖大量标注好的数据。为了克服数据依赖性,研究人员开始将神经网络运用于传统成像算法的后处理阶段。Martin 等^[32]提出了使用人工神经网络对一步线性高斯-牛顿方法的成像结果进行后处理的联合重建方法。Hamilton 等^[33]利用 U-Net 网络对 D-bar 算法获得的初始电导率分布图像进行后处理,去除伪影的同时能够降低图像时延。Ren 等^[34]构造了预重构块和 CNN 模块结合的两阶段深度学习方法,将 CNN 通过多层析特征分析技术对预重构块结果进行后处理。Zhao 等^[35]提出了一种 V 型密集降噪网络对共轭梯度法的初始重构结果进行后处理。Ren 等^[36]将视觉几何组(visual geometry group, VGG)中的卷积方法运用到卷积神经网络中,提升了单一 CNN 网络的图像重建性能。

基于深度学习的 ERT 图像重建虽然具有较好的性能,但仍面临的挑战为:1)深度学习模型广泛依赖于标注的仿真数据集,导致实际泛化能力较弱;2)模型在噪声干扰下的稳定性不足;3)在有限训练数据下,神经网络易陷入对特定传感器或噪声特性的局部最优,从而表现不佳。为解决上述问题,本文提出了一种基于半监督学习的 ERT 图像重建解决方案。通过构造 MultiU-Net 网络,改善了模型的非线性映射能力。首先,通过全连接前置层建立“边界测量电压-电导率分布”映射,然后引入编码器捕获多尺度敏感场特征,随后,引入解码器嵌入通道注意力机制来强化边界响应。最后,引入半监督对比学习策略,利用未标注数据优化特征空间分布。仿真和实验结果均验证了该方法的有效性。

1 ERT 基本原理

电阻层析成像系统主要由传感器阵列、数据采集系统和上位机图像重建 3 个部分组成,其结构如图 1 所示。传感器阵列由 16 个电极组成,等距排列在被测场域边界。相邻电极被施加电流激励时,会引起其余 13 对电极间的电势差发生变化。数据采集系统采集该电势差信号,从中解调出幅值与相位等信息,作为图像重建算法的输入。图像重建算法负责将电势差信号转化为目标区域的电导率分布图像。

ERT 包含两个相互关联的数学问题:正问题和逆问题。正问题为已知场域电导率分布和激励模式,求解边界电压响应。逆问题是已知边界电压响应,求解目标场域内部的电导率分布,即 ERT 图像重建^[37]。ERT 敏感




图1 ERT系统结构

Fig. 1 Structure of ERT system

场中电位分布方程可表示为:

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

式中: $\sigma(x, y)$ 表示场域内电导率分布; $\phi(x, y)$ 表示场域内电势分布。将式(1)进行归一化和离散化, 得到线性近似方程如式(2)所示。

$$\mathbf{U} = \mathbf{S}\mathbf{G} \quad (2)$$

式中: $\mathbf{U}$ 为 $n \times 1$ 的归一化边界电压测量值矩阵; $\mathbf{S}$ 为 $n \times m$ 的归一化灵敏度矩阵; $\mathbf{G}$ 为 $m \times 1$ 的归一化电导率分布矩阵。电阻层析成像图像重建的目的是通过已知的电压测量矩阵 $\mathbf{U}$ 求得未知的电导率分布 $\mathbf{G}$ 。

2 MultiU-Net 半监督网络

为了提高成像算法的精度和泛化性, 提出基于半监督学习的 MultiU-Net 网络。该网络以编码器和解码器为核心, 结合一致性约束策略构建半监督学习策略和网络损失函数。相比于监督学习, 该网络能够降低模型对数据的依赖, 同时一致性约束策略提高了网络的泛化性和抗噪性。网络的特征提取部分结合了通道注意力优化机制, 该机制能够自适应地调整特征通道的权重分布, 从而大幅提升模型的训练效率和特征表达能力。

2.1 MultiU-Net 结构

MultiU-Net 半监督网络主要包括全连接、编码器、解码器 3 个模块, 其结构如图 2 所示。

网络首端采用全连接层构建的数据转换模块, 通过非线性映射将原始电压测量矢量投影至目标重建空间。该模块包含 3 个级联的全连接层, 通过逐层降维操作实现变换过程, 使得最终输出维度与目标电导率分布矩阵保持空间维度对齐。数学表达式为:

$$\mathbf{h}_3 = \mathbf{W}_3 \cdot \text{ReLU}(\mathbf{W}_2 \cdot \text{ReLU}(\mathbf{W}_2 \cdot \mathbf{x} + \mathbf{b}_1) + \mathbf{b}_2) + \mathbf{b}_3 \quad (3)$$

式中: $\mathbf{W}_i$ 为权重矩阵; $\mathbf{b}_i$ 是偏置项; $\mathbf{x}$ 为输入的边界电压测量值; ReLU 为线性整流函数 (rectified linear unit, ReLU), 表达式为:

$$\text{ReLU}(x) = \begin{cases} 0, & x < 0 \\ x, & x \geq 0 \end{cases} \quad (4)$$




图2 MultiU-Net 网络结构

Fig. 2 Structure of MultiU-Net

编码器采用改进的 U-Net 结构, 包含 4 个特征提取层。每层由两个卷积构成的残差块、通道注意力模块和最大池化操作组成。残差块用于缓解深层网络训练中的梯度消失问题, 促进信息的跨层流动, 从而稳定训练过程并增强模型对多尺度特征的融合能力; 通道注意力模块通过建模特征通道间的依赖关系, 自适应地校准各通道的权重, 使网络能够自主强化对重建任务关键特征的响应, 提升特征的判别性表达能力; 最后采用最大池化操作执行下采样, 降低特征图空间尺寸、减少参数量并突出局部最显著的特征响应。编码器第 i 阶段输出特征 $\mathbf{F}_i$ 的计算过程为:

$$\mathbf{F}_i = \text{MaxPool}(\text{SEBlock}(\text{ConvBlock}(\mathbf{F}_{i-1}))) \quad (5)$$

SEBlock 采用挤压-激励结构, 通过全局平均池化获取通道统计量, 经两层全连接生成通道权重, 最终特征图各通道加权调整。这种动态通道加权机制使网络在浅层关注基础物理特征, 在深层聚焦复杂模式, 有效提升特征表征效率。

解码器采用异构上采样策略构建三通路重建架构。主解码器沿袭标准 U-Net 结构, 通过转置卷积实现特征图上采样, 并与编码器对应层特征进行跳跃连接。辅助解码器则引入双线性插值上采样与深度可分离卷积的混合策略。该设计既保留了常规解码器的细节重建能力, 又增强了全局连续性约束。解码器同样结合通道注意力机制, 对不同通道分配不同的权重来突出重要的特征, 抑制了不重要的特征, 减少了无效的计算。

2.2 基于一致性约束的损失函数

半监督学习使用少量标注数据和大量未标注数据来训练模型, 通过未标注数据中的结构信息学习到更多的有用知识, 解决传统监督学习面临的数据瓶颈问题。因此, 半监督学习更加灵活且应用范围更加广泛^[38-39]。为

充分利用有标签的数据集和无标签的数据集,本文结合一致性约束策略构建 MultiU-Net 网络的损失函数。

对于有标签数据集,计算期望输出和预测输出的均方误差作为网络的有监督损失函数,其表达式为:

$$Loss_{supervised} = \sum_{i=1}^n loss(y_{label}^i, y_{pre}^i) \quad (6)$$

式中: y_{label} 为期望输出; y_{pre} 为预测输出; n 为有标签数据集中的样本数量; $loss$ 代表均方误差计算,表达式为:

$$loss(a, b) = \frac{1}{m} \sum_{i=1}^m (a_i - b_i)^2 \quad (7)$$

式中: a_i 和 b_i 分别为样本 a 和样本 b 中的元素; m 为像素点数量且 $m = 812$ 。

对于无标签数据集,采用一致性约束策略,将所有无标签数据的多个输出之间的均方误差作为网络的无监督损失函数。这一策略通过强制网络在不同扰动下保持输出的一致性,提高了模型的泛化能力和抗噪性能。无监督损失函数表达式为:

$$Loss_{unsupervised} = \sum_{\substack{i,j=1 \\ i \neq j}}^u loss(y_{u_pre}^i, y_{u_pre}^j) \quad (8)$$

式中: y_{u_pre} 为无标签数据集的预测输出。

网络的总损失函数由有监督损失函数和无监督损失函数加权构成,表达式为:

$$LOSS = Loss_{supervised} + \lambda \cdot Loss_{unsupervised} \quad (9)$$

式中: λ 为指数预热函数,表达式为:

$$\lambda(t) = e^{-5 \cdot (1 - \frac{1}{T})^2} \quad (10)$$

式中: T 为训练总轮数; t 为当前轮数; e 为自然常数。 $\lambda(t)$ 表示训练轮数为 t 时无监督学习权重。

指数预热函数的引入有效平衡了有监督学习和无监督学习的权重分配。保证无监督学习在训练过程中权重由 0 由 S 型趋势增加到 1。

2.3 训练集建立

采用 COMSOL 和 MATLAB 联合仿真平台建立训练数据集。每组数据包含电导率分布及其对应的边界电压测量值。ERT 传感器采用 16 电极模型,其二维结构如图 1 所示。每个电极厚度为 1 mm,宽度为 10 mm,高度为 30 mm,管道内径为 125 mm;背景介质为电导率为 0.05 S/m 的水介质,内含物为电导率为 10^{-8} S/m 的气泡。为保证数据的全面性,随机生成不同数量、不同尺寸和不同位置的内含物分布。典型分布如图 3 所示。




图3 离散气泡样本的典型分布

Fig.3 Typical distribution of discrete bubble samples

采用有限元法计算正问题,即获得每种分布的边界电压测量值。对于 16 电极的 ERT 传感器,COMSOL 基于模型几何特征采用智能自适应算法生成三角形网格,如图 4(a)所示。网格划分过程中,优先在曲率较大的区域分配更密集的网格,提高求解精度;而在传感器中间区域采用相对稀疏的网格,提高计算效率。在相邻电极施加电流激励,然后依次采集其余 13 对相邻电极间的电势差,16 电极循环激励后,可以得到一个包含 208 个电压测量值的矢量。逆问题网格划分如图 4(b)所示。重建区域为 32×32 的规则网格体系。在电导率参数处理方面,为增强视觉效果,引入二值化预处理策略:将连续相(背景介质)电导率归一化为 0 S/m,离散相(目标介质)标准化为 1 S/m。这种映射简化了反演方程的求解难度,并且提升了离散介质的边缘对比度。




图4 正问题和逆问题的网格划分

Fig.4 Meshing generation of the forward problem and inverse problem

2.4 交叉验证

在图像重建问题中,模型的泛化能力和鲁棒性对图像重建结果准确性具有重要影响,因此在 MultiU-Net 模型训练过程中引入了交叉验证方法。交叉验证是一种模型验证方法,用于评估模型的泛化能力,即模型在陌生数据上的表现。通过系统划分数据集,能够有效评估模型在陌生数据上的表现,从而为模型优化提供可靠依据。为了充分利用有限的的数据资源并避免过拟合,本文采用十折交叉验证方法,具体流程如图 5 所示。




图5 十折交叉验证

Fig.5 Ten-fold cross-validation

首先将数据集随机划分为 10 个大小相等的子集,确保每个子集的数据分布与整体数据集尽可能一致。然后在每一轮模型迭代训练中,选择其中一个子集作为验证集,其余 9 个子集作为训练集。通过训练模型并在验证集上评估其性能,记录每次的验证误差或性能指标。完成 10 轮计算后,将所有验证结果进行平均,得到模型的综合性能评估指标。由于模型在每一轮迭代中都在不同的子集上进行验证,十折交叉验证能够有效抑制过拟合现象,提升模型稳定性,确保模型在训练集和验证集上表现良好。

3 实验结果与分析

3.1 无标签数据占比优化实验

半监督学习中,无标签数据在总数据中的占比对模型性能有关键影响。无标签数据比例过高时,网络能够充分利用未标注信息,但梯度更新受噪声干扰严重,导致模型收敛困难,影响成像精度。无标签数据比例过低时,可以确保模型快速收敛,保持基础成像质量,但是模型泛化能力较弱,无法充分发挥半监督学习的优势。

如图 6 所示为确定最优无标签数据占比,设置不同的标签数据比例(20%、30%、50%、100%)对 MultiU-Net 网络进行训练,并对仿真数据的成像效果进行评估。




图 6 无标签数据占比为 20%、30%、50%、100% 时图像重建结果
Fig. 6 Image reconstruction with unlabeled data accounting for 20%, 30%, 50% and 100%

仿真数据测试结果如图 6(a) 所示。当带标签数据比例为 50% 时,仿真数据的成像质量达到最优,主要表现为图像边缘清晰、伪影减少以及目标介质与背景介质的区分度增强。为进一步验证无标签数据占比对 MultiU-

Net 泛化性能的影响,利用实际测量的实验数据进行成像,对实验数据成像效果进行评价。采用天津大学过程层析成像与多相流测试实验室研发的 ERT 系统获取实验数据^[29],ERT 系统如图 7 所示。




图 7 ERT 实验系统
Fig. 7 ERT experimental system

实验过程中,传感器内部填充电导率为 0.04 S/m 的氯化钠溶液作为连续相,使用电导率近似为零的有机玻璃棒作为内含物以模拟气体条件。实验数据成像结果如图 6(b) 所示。实验结果表明,无监督数据比例过高时,由于监督信息不足,模型难以学习到准确的映射关系,导致成像结果中出现伪影,目标边缘模糊;无监督数据比例过低时,模型出现过拟合现象,针对实验数据的图像重建效果降低。

综合对比仿真数据和实验数据的图像成像结果,本文将无监督数据在训练数据中的占比确定为 50%。此时,MultiU-Net 模型在训练成本与泛化性能之间达到平衡,取得较好的成像质量。

3.2 模型训练

本文使用包含 50% 的未标注数据比例的数据集对 MultiU-Net 模型进行训练。优化算法采用基于自适应学习率的优化算法,该策略能够根据训练过程中的梯度变化动态调整学习效率,从而加速模型收敛并提高训练稳定性。训练过程在配备 NVIDIA GeForce RTX GPU 的高性能计算平台上进行,整个训练过程利用 PyTorch 深度学习框架实现。

训练过程中损失函数随迭代次数的变化趋势如图 8 所示。

随着迭代次数增加,损失函数值呈现稳定下降。采用相对均方误差 (relative mean square error, RMSE) 和图像相关系数 (image correlation coefficient, ICC) 评估训练




图8 损失函数变化曲线

Fig. 8 Variation curve of loss function

过程中的图像重建精度。RMSE 越小,ICC 越大,图像重建质量越好。RMSE 和 ICC 表达式为:

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (\hat{\sigma}_i - \sigma_i)^2} \quad (11)$$

$$ICC = \frac{\sum_{i=1}^N (\hat{\sigma}_i - \bar{\hat{\sigma}})(\sigma_i - \bar{\sigma})}{\sqrt{\sum_{i=1}^N (\hat{\sigma}_i - \bar{\hat{\sigma}})^2 \sum_{i=1}^N (\sigma_i - \bar{\sigma})^2}} \quad (12)$$

式中: σ 和 $\hat{\sigma}$ 分别为真实电导率分布和预测电导率分布; $\bar{\sigma}$ 和 $\bar{\hat{\sigma}}$ 是 σ 和 $\hat{\sigma}$ 的平均值; N 为像素点个数。

随着训练次数增加,针对验证集的 RMSE 变化曲线如图 9(a) 所示,ICC 变化曲线如图 9(b) 所示。图 9 表明,随着训练次数的增加,验证集的 RMSE 逐渐减少,ICC 逐渐增加,表明 MultiU-Net 模型电导率分布图像的拟合精度逐渐提高。




图9 RMSE 和 ICC 变化曲线

Fig. 9 Variation curve of RMSE and ICC

3.3 仿真数据图像重建

对模型进行训练后,随机在测试集中选取电导率分布来进行图像重建,并将图像重建结果与 LBP、Tikhonov、Landweber 和 CNN-VGG^[36] 这 4 种算法进行比较,其结果如图 10 所示。其中,Tikhonov 算法的正则化参数为 0.000 1, Landweber 算法的迭代步长为 10 000。CNN-VGG 网络结构采用 CNN 中卷积层和池化层的交替堆叠方式,逐层提取输入数据的局部特征,并通过全连接层进行回归,两组卷积层采用 VGG 中的卷积堆叠方式以允许网络逐渐提取更高级别的特征表示^[36]。




图10 仿真数据图像重建

Fig. 10 Image reconstruction of simulation data

由图 10 可知,无论是简单流型还是复杂流型,LBP 算法均存在严重偏差,在复杂分布时甚至不能呈现内含物的精确数量信息。Tikhonov 算法和 Landweber 算法的图像重建结果存在一定的伪影,且随着内含物数量的增加,伪影越来越严重。CNN-VGG 模型的图像重建结果优于传统图像重建算法,但针对部分流型的重建结果存在失真现象。MultiU-Net 模型可以更准确地预测夹杂物的大小、位置和数量,其预测结果比其他算法更接近真实的介质分布。

3.4 抗噪性测试

为了验证模型在噪声环境下的稳定性,将信噪比为 30 和 50 dB 的高斯白噪声分别添加到验证集的边界电压数据中,图像重建结果如图 11 所示。信噪比为 30 dB 时,图像重建结果与无噪声时基本一致,表明该网络可以接受信噪比为 30 dB 的噪声存在;信噪比为 50 dB 时,图像重建结果几乎不存在伪影,此时噪声对模型预测精度没有明显影响。抗噪性测试证明了提出的 MultiU-Net 半监督网络在复杂介质分布重建任务中的优越性及其在噪声环境下的鲁棒性。

3.5 静态实验

为验证 MultiU-Net 网络的的实际应用性能,使用 16 电极传感器的 ERT 系统进行静态实验,实验装置如图 7




图 11 抗噪性测试
Fig. 11 Anti-noise test

所示。实验过程中,对 8 种电导率分布情况进行了数据采集。将实验数据的图像重建结果与 LBP、Tikhonov、Landweber 和 CNN-VGG 这 4 种算法进行比较,结果如图 12 所示。其中,Tikhonov 算法的正则化参数为 0.000 1, Landweber 算法的迭代步长为 10 000。相比于仿真数据,实验数据存在一定噪声,所以 MultiU-Net 模型针对部分实验数据的图像重建结果存在轻微失真。但是 MultiU-Net 模型的图像重建精度仍然优于其余几种算法,表明 MultiU-Net 模型具有良好的泛化能力。




图 12 静态实验图像重建
Fig. 12 Image reconstruction in static experiment

如图 13(b) 所示,进一步验证了提出的 MultiU-Net 模型的优势。




图 13 静态实验的平均 RMSE 和 ICC
Fig. 13 Average RMSE and ICC of static experiment

3.6 动态实验

为验证 MultiU-Net 模型的动态性能,进行了动态成像实验。在二维平面将有机玻璃棒按照两种预定轨迹匀速移动,记录被测物在不同位置处的动态成像结果。有机玻璃棒移动轨迹如图 14 所示,其中图 14(a) 为沿管壁移动轨迹,图 14(b) 为螺旋移动轨迹。




图 14 动态实验中被测物移动轨迹
Fig. 14 Motion trajectory of the measured object in dynamic experiment

对比了 MultiU-Net 模型与 LBP 算法、Landweber 迭代算法、Tikhonov 正则化算法以及 CNN-VGG 网络的图像重建结果如图 15 和 16 所示。

动态重建结果中,LBP 算法虽然能够大致定位目标,

静态实验的平均 RMSE 如图 13(a) 所示,平均 ICC




图 15 动态轨迹 1 的图像重建

Fig. 15 Image reconstruction of motion trajectory 1




图 16 动态轨迹 2 的图像重建

Fig. 16 Image reconstruction of motion trajectory 2

但其重建结果分辨率低,存在明显的伪影和失真;Landweber 算法和 Tikhonov 算法能够在部分情况下能够恢复目标的基本轮廓,但在细节还原和噪声抑制方面表现较差,重建结果中存在较多模糊区域;CNN-VGG 网络在动态成像过程中图像重建精度和鲁棒性明显不足,尤其是在目标边缘和细节部分存在明显的偏差。相比之下,MultiU-Net 网络不仅能够准确定位尼龙棒的位置,还能精确还原其大小和形状,且重建图像的边界清晰、细节丰富。动态实验进一步验证了 MultiU-Net 网络具有优异的性能,该模型可以在除训练集之外的数据上取得良好的重建效果。

4 结 论

针对基于深度学习的 ERT 图像重建算法在实际应

用中高度依赖标注数据集、成像精度较低、泛化能力弱等问题,提出了一种基于半监督学习 MultiU-Net 网络。该网络包含全连接模块、编码器、解码器 3 个部分,全连接模块将电压测量值转化为和分布同维的数据,编码器对全连接模块的输出进行特征提取,提取到的特征由采用不同上采样策略的解码器进行处理。模型训练过程中,引入一致性约束策略使得无标注的数据集得到充分利用。进行了仿真实验、抗噪实验、静态实验和动态实验。仿真实验初步验证了 MultiU-Net 模型的有效性。抗噪实验表明 MultiU-Net 模型具备一定的抗噪性能,能够应对信噪比为 30 dB 的高斯白噪声。静态实验和动态实验表明 MultiU-Net 模型的图像重建结果优于 LBP、Tikhonov、Landweber 和 CNN-VGG 算法,具备一定的泛化能力和鲁棒性。相较于 CNN-VGG 算法,MultiU-Net 网络引入半监督学习机制,降低了对大量标注数据的依赖,且其编码器-解码器结构与通道注意力模块增强了特征提取与图像重建能力,因此在重建精度、噪声鲁棒性以及跨场景泛化性能上具有优势。

然而,本文工作仍存在一定局限性。首先,MultiU-Net 网络的训练与验证主要基于二维仿真数据和实验室环境测试数据,其针对复杂流场或高速动态过程的图像重建性能有待进一步验证。其次,尽管采用半监督策略降低对标注数据的依赖,但模型的初始特征学习仍基于仿真数据集,其与实际测量数据之间的差异可能影响最终泛化性能。此外,提出的 MultiU-Net 网络结构相对复杂,在模型推广与轻量化计算方面面临挑战。未来工作将围绕以下方面展开:首先,将物理约束与数据驱动方法相结合,以提升模型在有限训练数据下的泛化能力与重建结果的合理性。其次,针对实际工业现场对实时性与便携性嵌入式部署的需求,对 MultiU-Net 网络进行轻量化结构设计。最后,将研究该网络在嵌入式硬件平台上的部署,开发适用于工业现场的高实时性、高鲁棒性图像重建系统,以实现模型在实际工业应用中的落地。

参考文献

- [1] 胡远洋. 基于深度神经网络的电阻层析成像重建方法[J]. 电子测量技术, 2023, 46(5):78-82.
HU Y Y. Reconstruction method of electrical resistance tomography based on deep neural network[J]. Electronic Measurement Technology, 2023, 46(5):78-82.
- [2] 颜华, 胡丽娟, 王伊凡, 等. 基于改进灵敏度矩阵的 ERT 图像重建[J]. 仪器仪表学报, 2018, 39(5):241-248.
YAN H, HU L J, WANG Y F, et al. Image reconstruction of ERT based on improved sensitivity matrix[J]. Chinese Journal of Scientific Instrument,

- 2018, 39(5):241-248.
- [3] MENG F S, WANG J G, ZHAO Y SH, et al. Quantification of soil water content by machine learning using enhanced high-resolution ERT [J]. *Journal of Hydrology*, 2024, 643: 131994.
- [4] 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.
- [5] DIAZ-ESCOBAR J, DÍAZ-MONTIEL P, VENKATARAMAN S, et al. Classification and characterization of damage in composite laminates using electrical resistance tomography and supervised machine learning [J]. *Structural Control and Health Monitoring*, 2023, 2023(1): 1675867.
- [6] LIU J CH, MENG W L, ZHANG Y Q, et al. Insight into bubble hydrodynamic characteristics in the freeboard region of fluidized bed flotation columns [J]. *Chemical Engineering Science*, 2025, 316: 121926.
- [7] ZHU L Y, LU W, SOLEIMANI M, et al. Electrical impedance tomography guided by digital twins and deep learning for lung monitoring [J]. *IEEE Transactions on Instrumentation and Measurement*, 2023, 72: 1-9.
- [8] REN J J, HE H W, LI ZH W, et al. Elimination of breath interference for conductivity/contrast pulmonary perfusion process with high-frequency electrical impedance tomography [J]. *IEEE Transactions on Instrumentation and Measurement*, 2025, 74: 4509309.
- [9] 张立峰, 张梦涵. 基于自适应模拟退火及 LM 联合反演算法的 ECT 图像重建 [J]. *仪器仪表学报*, 2021, 42(12):228-235.
- ZHANG L F, ZHANG M H. Image reconstruction for electrical capacitance tomography based on adaptive simulated annealing and LM joint inversion algorithm [J]. *Chinese Journal of Scientific Instrument*, 2021, 42(12): 228-235.
- [10] SANTOSA F, VOGELIUS M. A backprojection algorithm for electrical impedance imaging [J]. *Siam Journal on Applied Mathematics*, 1990, 50(1): 216-243.
- [11] VAUHKONEN M, VADASZ D, KARJALAINEN P A, et al. Tikhonov regularization and prior information in electrical impedance tomography [J]. *IEEE Transactions on Medical imaging*, 2002, 17(2): 285-293.
- [12] 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.
- [13] CHENEY M, ISAACSON D, NEWELL J C, et al. NOSER: An algorithm for solving the inverse conductivity problem [J]. *International Journal of Imaging System and Technology*, 1990, 2(2): 66-75.
- [14] 王化祥, 王超, 陈磊. 基于 Landweber 迭代的图像重建算法 [J]. *信号处理*, 2000, 16(4):354-356,328.
- WANG H X, WANG CH, CHEN L. Image reconstruction algorithm based on the Landweber iteration method [J]. *Journal of Signal Processing*, 2000, 16(4): 354-356, 328.
- [15] 严春满, 穆哲. 一种改进的梯度加速 Landweber 算法及其在 ECT 图像重建中的应用 [J]. *电子测量与仪器学报*, 2021, 35(6):169-175.
- YAN CH M, MU ZH. Application of an improved gradient accelerated Landweber algorithm in ECT image reconstruction [J]. *Journal of Electronic Measurement and Instrumentation*, 2021, 35(6):169-175.
- [16] RUDIN L I, OSHER S, FATEMI E. Nonlinear total variation based noise removal algorithms [J]. *Physica D: Nonlinear Phenomena*, 1992, 60(1-4): 259-268.
- [17] 闫孝姮, 吕秋皓, 林晓雪, 等. 基于 Tikhonov 和 TV 混合正则化的接地网电阻抗成像算法研究 [J]. *仪器仪表学报*, 2021, 42(11):160-171.
- YAN X H, LYU Q H, LIN X X. Research on grounding grid electrical impedance tomography algorithm based on Tikhonov and TV hybrid regularization [J]. *Chinese Journal of Scientific Instrument*, 2021, 42(11): 160-171.
- [18] WANG M. Inverse solutions for electrical impedance tomography based on conjugate gradients methods [J]. *Measurement Science and Technology*, 2002, 13(1): 101-117.
- [19] 李秀艳, 韩倩, 汪剑鸣, 等. 基于改进共轭梯度法的 ERT 图像重建 [J]. *仪器仪表学报*, 2016, 37(7): 1673-1679.
- LI X Y, HAN Q, WANG J M, et al. ERT image

- reconstruction based on improved CG method [J]. Chinese Journal of Scientific Instrument, 2016, 37(7): 1673-1679.
- [20] 肖理庆, 王化祥. 基于聚类电阻层析成像静态图像重建算法[J]. 仪器仪表学报, 2016, 37(6): 1258-1266. XIAO L Q, WANG H X. Absolute image reconstruction algorithm based on clustering for ERT [J]. Chinese Journal of Scientific Instrument, 2016, 37(6): 1258-1266.
- [21] MUELLER J L, SILTANEN S, ISAACSON D. A direct reconstruction algorithm for electrical impedance tomography[J]. IEEE Transactions on Medical Imaging, 2002, 21(6): 555-559.
- [22] BRUHL M. Explicit characterization of inclusions in electrical impedance tomography [J]. SIAM Journal on Mathematical Analysis, 2001, 32(6): 1327-1341.
- [23] 王语, 任尚杰, 董峰. 梯度引导电学成像自适应网格生成方法[J]. 仪器仪表学报, 2022, 43(4): 163-171. WANG Y, REN SH J, DONG F, et al. Gradient guided adaptive mesh generation for image reconstruction of electrical tomography [J]. Chinese Journal of Scientific Instrument, 2022, 43(4): 163-171.
- [24] 薛钟毫, 姜金刚, 孙健鹏, 等. 基于多尺度卷积和选择性核双注意力机制的半监督全景 X 射线图像龋齿分割[J]. 仪器仪表学报, 2025, 46(6): 241-250. XUE ZH H, JIANG J G, SUN J P, et al. Semi-supervised caries segmentation of panoramic X-ray images based on multi-scale convolution and selective kernel dual-attention [J]. Chinese Journal of Scientific Instrument, 2025, 46(6): 241-250.
- [25] 张立军, 曹江涛, 姬晓飞, 等. 基于深度学习的学生课堂学习状态监测系统设计[J]. 电子测量与仪器学报, 2024, 38(4): 37-45. ZHANG L J, CAO J T, JI X F, et al. Design of classroom learning state monitoring system for students based on deep learning [J]. Journal of Electronic Measurement and Instrumentation, 2024, 38(4): 37-45.
- [26] 杨林鹏, 刘祎, 梁旭东, 等. IADR-Net: 一种结合迭代优化与细节注意力增强的稀疏角 CT 重建网络[J]. 电子测量技术, 2026, 49(4): 190-203. YANG L P, LIU Y, LIANG X D, et al. IADR-Net: A sparse-view ct reconstruction network with iterative optimization and dual-path attention enhancement [J]. Electronic Measurement Technology, 2026, 49(4): 190-203.
- [27] 彭宇, 娄越, 岳豪帅, 等. 面向 FPGA 的 CNN 软硬协同加速方法研究综述[J/OL]. 电子测量与仪器学报, 1-20[2026-02-28]. PENG Y, LOU Y, YUE H SH, et al. A survey of FPGA-oriented CNN hardware and software co-accelerated methods[J/OL]. Journal of Electronic Measurement and Instrumentation, 1-20[2026-02-28].
- [28] 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. Optimized learning method for electrical impedance tomography with multi-scale attention fusion and vision transformer [J]. Chinese Journal of Scientific Instrument, 2024, 45(7): 52-63.
- [29] TAN CH, LYU SH H, DONG F, et al. Image reconstruction based on convolutional neural network for electrical resistance tomography [J]. IEEE Sensors Journal, 2018, 19(1): 196-204.
- [30] 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.
- [31] 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, 1(7): 9277-9287.
- [32] MARTIN S, CHOI C T. A post-processing method for three-dimensional electrical impedance tomography [J]. Scientific Reports, 2017, 7(1): 7212.
- [33] HAMILTON S J, MUELLER J L, SANTOS T R. Robust computation in 2D absolute EIT (aEIT) using D-bar methods with the 'exp' approximation [J]. Physiological Measurement, 2018, 39(6): 064005.
- [34] 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.
- [35] ZHAO ZH Q, FU F, FRERICH S I. Thoracic electrical impedance tomography in Chinese hospitals: A review of clinical research and daily applications [J]. Physiological Measurement, 2020, 41(4): 04TR01.
- [36] 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.

- [37] 谭超, 董峰. 多相流过程参数检测技术综述[J]. 自动化学报, 2013, 39(11):1923-1932.

TAN CH, DONG F. Parameters measurement for multiphase flow process [J]. Acta Automatica Sinica, 2013, 39(11):1923-1932.

- [38] 刘紫阳, 高占宝, 李绪隆. 基于边缘增长的协同训练方法[J]. 仪器仪表学报, 2018, 39(3):45-53.

LIU Z Y, GAO ZH B, LI X L. Co-training method based on margin sample addition [J]. Chinese Journal of Scientific Instrument, 2018, 39(3):45-53.

- [39] 陈赛赛, 杨晨曦, 陈超, 等. 基于小波核扩散与双阶段 SVM 的轴承复合故障分类方法[J]. 仪器仪表学报, 2023, 44(10):179-188.

CHEN S S, YANG CH X, CHEN CH, et al. Bearing compound fault classification method based on wavelet kernel diffusion and two-stage SVM[J]. Chinese Journal of Scientific Instrument, 2023, 44(10):179-188.

作者简介



黄世洋, 2021、2024 年于天津大学获得学士、硕士学位, 现于天津大学攻读博士学位, 主要研究方向为电学层析成像。

E-mail: shiyang_huang@tju.edu.cn

Huang Shiyang received his B. Sc. and M. Sc. degrees both from Tianjin University in 2021 and 2024, respectively. He is currently pursuing his Ph. D. degree at Tianjin University. His main research interest is electrical tomography.



谭超, 2003、2006 和 2009 年于天津大学获得学士、硕士和博士学位, 现为天津大学电气自动化与信息工程学院教授, 主要研究方向为过程参数检测及控制系统, 多相流测量及仪器, 工业过程层析成像, 多传感器/数据融合。

E-mail: tanchao@tju.edu.cn

Tan Chao received his B. Sc., M. Sc. and Ph. D. degrees all from Tianjin University in 2003, 2006 and 2009, respectively.

He is currently a professor in the School of Electrical and Information Engineering at Tianjin University. His main research interests include process parameter detection and control systems, multiphase flow measurement and instrumentation, industrial process tomography, and multisensor/data fusion.



梁光辉 (通信作者), 2014 年于天津工业大学获得学士学位, 2021 年于天津大学获得博士学位, 现为天津大学电气自动化与信息工程学院副教授, 主要研究方向为过程层析成像技术。

E-mail: ghliang@tju.edu.cn

Liang Guanghui (Corresponding author) received his B. Sc. degree from Tiangong University in 2014, and his Ph. D. degree from Tianjin University in 2021. He is currently an associate professor in the School of Electrical and Information Engineering at Tianjin University. His main research interest is process tomography.



任继坤, 2022 年于东北大学获得学士学位, 2025 年于天津大学获得硕士学位, 主要研究方向为电学层析成像。

E-mail: renjikun@tju.edu.cn

Ren Jikun received her B. Sc. degree from Northeastern University in 2022, and her M. Sc. degree from Tianjin University in 2025. Her main research interest is electrical tomography.



董峰, 1988、1996 和 2002 年于天津大学获得学士、硕士和博士学位, 现为天津大学电气自动化与信息工程学院教授, 主要研究方向为过程在线检测与可视化技术; 复杂过程检测、建模与诊断; 工业自动化仪表与过程控制。

E-mail: fdong@tju.edu.cn

Dong Feng received his B. Sc., M. Sc., and Ph. D. degrees all from Tianjin University in 1988, 1996, and 2002, respectively. He is currently a professor in the School of Electrical and Information Engineering at Tianjin University. His main research interests include process monitoring and visualization technology; detection, modeling and diagnosis of complex processes; industrial automation instruments and process control.