

DOI: 10.19650/j.cnki.cjsi.J2108064

基于 V-ResNet 的电阻抗层析成像方法*

付荣,张新宇,王子辰,王迪,陈晓艳
(天津科技大学电子信息与自动化学院 天津 300222)

摘要:电阻抗层析成像技术(EIT)因其非侵入和可视化等特性为人体肺部空间特性的监测提供了一种有效的方法。但是 EIT 的逆问题具有严重的非线性、病态性和欠定性,使得图像重建结果含有严重的伪影。针对上述问题,提出了一种由预映射、特征提取、深度重建以及残差去噪四个模块构成的 V-ResNet 的深度网络成像算法,实现对场域空间位置和电导率参数分布的重建。该算法有效地增加了前馈信息的多重传递并解决了深度网络的梯度消失问题,同时残差去噪模块有效地平滑了图像边界。采用相对误差(RE)和结构相似度(SSIM)来衡量成像质量,实验得出 RE 的平均值为 0.14,SSIM 平均值为 0.96。仿真与实验结果表明,基于 V-ResNet 的成像算法与传统的成像算法相比,图像重建结果边界清晰,空间分辨率高。

关键词:电阻抗层析成像;逆问题;V 型残差去噪网络;图像重建

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

Electrical impedance tomography method based on V-ResNet

Fu Rong, Zhang Xinyu, Wang Zichen, Wang Di, Chen Xiaoyan

(College of Electronic Information and Automation, Tianjin University of Science & Technology, Tianjin 300222, China)

Abstract:Electrical impedance tomography (EIT) provides an effective method for monitoring the spatial features of human lungs because of its non-invasiveness and visualization natures. However, the inverse problem of EIT has serious non-linearity, ill-posedness and indeterminate feature, which makes the reconstructed images contain serious artifacts. Aiming at the above problems, a deep network imaging algorithm of V-ResNet composed of pre-mapping module, feature extraction module, deep reconstruction module and residual denoising module is proposed in this paper, which achieves the reconstruction of the spatial position and conductivity parameter distributions of the field. This algorithm can effectively increase the feedforward information by multiple transmissions and solve the phenomenon of gradient disappearance in deep networks. Meanwhile, the residual denoising module is utilized to effectively smooth the image boundary. The relative error (RE) and structural similarity (SSIM) are used to evaluate the imaging quality, and the experiments show that the average RE is 0.14 and the average SSIM is 0.96. The results of the simulations and experiments illustrate that compared with traditional imaging algorithms, the imaging algorithm based on V-ResNet achieves clearer boundaries and higher resolution in imaging result.

Keywords:electrical impedance tomography; inverse problem; V residual denoising network; image reconstruction

0 引言

电阻抗层析成像技术(electrical impedance tomography, EIT)是一种新型的过程参数可视化测量技术^[1],它采用空间敏感阵列实现复杂的过程参数二维/三维空间分布的检测。EIT 主要是利用敏感场域的电特

性,通过对贴附在敏感场域边界上的电极阵列注入一定的激励电流或电压,测量其他电极的电位分布,并结合相应的图像算法完成对敏感场域内电导率参数分布的检测和重建。因为其具有非侵入、无辐射、低成本等特性在医疗监测及工业检测等领域有着广泛的应用^[2-3]。

EIT 的图像重建具有严重的非线性、病态性和欠定性^[4]。目前大多数重建算法主要是基于灵敏度理

收稿日期:2021-06-08 Received Date: 2021-06-08

* 基金项目:国家自然科学基金(61903274)项目资助

论^[5-6]将非线性问题通过泰勒展开的方法转化为一阶线性问题。针对 EIT 的非线性问题,采用多次迭代的方法使得重建图像结果与原始图像之间的误差最小化,常见的迭代算法有 Landweber 算法^[7],牛顿-拉弗森(Newton Raphson, NR)算法^[8],共轭梯度算法(conjugate gradient, CG)^[9],Kalman 滤波算法^[10]等;针对图像重建的病态性问题,可采用恰当的阻尼因子实现对解的正则作用,常见的正则化算法有吉洪诺夫正则化(tikhonov regularization, TR)算法^[11]、总变差(total variation, TV)正则化算法^[12]等。上述算法虽然一定程度地改善了病态性和非线性,但由于 EIT 自身的“软场”特性,导致重建图像的空间分辨率仍难以达到医学监测的要求。

近些年来,随着大数据的发展及高性能图形处理器(graphics processing unit, GPU)的出现,深度学习^[13]受到了人们的广泛关注,其在图像处理^[14]、物体检测^[15]、人脸识别^[16]等视觉领域所取得的成功,使越来越多的学者和专家开始尝试将深度学习应用于电学层析的图像重建中。如李峰等^[17]提出了6层全连接深度网络算法;陈瑞娟等^[18]提出一种堆栈式自编码器提高了电阻抗图像的精度和抗噪性;Zheng 等^[19]提出了一种编码-解码的网络结构用于解决电容层析成像的正问题和逆问题;Tan 等^[20]提出了一种基于卷积神经网络的电阻层析成像方法;叶明等^[21]提出了一种基于两级嵌套 U 型网络结构(U²-Net)的电阻抗成像方法;刘东等人提出了一种基于主导电流的深度学习方案(dominant-current deep learning scheme for electrical impedance tomography, DC-DLS)方法重建电阻抗图像^[22]。但是肺部 EIT 图像重建容易受到人体胸腔轮廓、生理差异以及人体呼吸状态等诸多因素等影响,因此科学有效地改善肺部 EIT 重建图像的质量仍是一个亟需解决的问题。

针对上述 EIT 图像重建方法的不足,本文提出了一种基于 V 型深度残差去噪网络(V residual denoising network, V-ResNet)模型的新型电阻抗图像重建方法。以敏感场域的边界测量值作为网络的输入,利用可训练的预映射(pre-mapping)构成边界测量信息与场域内电导率分布特征之间的非线性关系,然后通过一种“编码-解码”结构的深度卷积神经网络对预映射的特征进行充分挖掘与重构,并联合残差模块对重建的图像噪声进行滤波,得到最终的成像结果。利用该方法重建的图像可以准确地表征敏感场域的空间结构和电导率分布。相比于 TV、TR、CG 及浅层卷积自编码器等算法,其对 EIT 的图像重建的非线性问题表征能力更强,网络泛化能力更加突出。

1 基于 V-ResNet 的图像重建方法

1.1 EIT 数理模型

对于二维的 EIT 模型,其边界等间距贴附 16 个电极,边界电压测量采用相邻电流激励法,选取一对相邻电极作为激励电极对,其它相邻电极作为电压测量电极,依次更替激励电极对,循环一周共可采集到 208 个电压数据。EIT 仿真模型测量系统如图 1 所示。

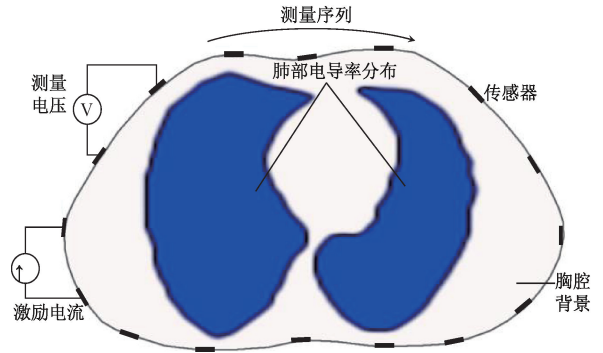


图 1 EIT 仿真模型测量系统

Fig. 1 The measurement system of EIT simulation model

根据麦克斯韦方程组的微分形式,纽曼边界条件和全电极模型^[23],EIT 数理方程可以表示为:

$$\begin{cases} \nabla \cdot \boldsymbol{\sigma}(\vec{r}) \nabla \varphi(\vec{r}) = 0, \vec{r} \in \Omega \\ \frac{\partial \varphi(\vec{r})}{\partial n} = 0, \vec{r} = \partial \Omega \setminus \bigcup_{l=1}^L E_l \\ \boldsymbol{\sigma}(\vec{r}) + \rho \boldsymbol{\sigma}(\vec{r}) \frac{\partial \varphi(\vec{r})}{\partial n} = V_l, \vec{r} \in E_l, l = 1, 2, \dots, 16 \\ \int_{E_l} \boldsymbol{\sigma}(\vec{r}) \frac{\partial \varphi(\vec{r})}{\partial n} d\Omega = I_l, l = 1, 2, \dots, 16 \\ \sum_{l=1}^{16} I_l = 0, \\ \sum_{l=1}^{16} V_l = 0 \end{cases} \quad (1)$$

式中: \vec{r} 表示空间位置; $\boldsymbol{\sigma}(\vec{r})$ 表示敏感场域内电导率分布; $\varphi(\vec{r})$ 表示场域内电位分布; \boldsymbol{n} 表示边界单位法向量; ρ 为接触阻抗; Ω 为敏感场域; E_l 为边界贴附电极; I_l 和 V_l 分别表示第 l 号电极上的注入电流和测量电压。已知敏感场域内电导率分布特性来求解边界电压的过程为 EIT 正问题,其可以描述为:

$$\boldsymbol{V} = \boldsymbol{S}(\boldsymbol{\sigma}; \boldsymbol{I}) = \boldsymbol{S}\boldsymbol{\sigma} \quad (2)$$

其中, \mathbf{V} 表示边界测量电压; \mathbf{S} 是表示场域内电导率参数与边界信息的刚度矩阵, 即灵敏度矩阵。

图像重建即 EIT 的逆问题, 根据测量得到的边界电压使用适当的图像重建算法来求解场域的空间结构和电导率分布特征。其数学表达为:

$$\delta\sigma = \mathbf{S}^{-1} \cdot \delta\mathbf{V} \quad (3)$$

其中, $\delta\sigma$ 表示敏感场域内电导率的微小变化; \mathbf{S}^{-1} 表示灵敏度矩阵的逆矩阵; $\delta\mathbf{V}$ 表示敏感场域边界电压与参考状态电压的差分。在深度学习模型中, 对于逆问题的求解可以表示为:

$$f = \operatorname{argmin} \frac{1}{m} \sum_{k=1}^m \|f(\Delta\mathbf{V}_k) - \delta\sigma_k\|_2^2 + \operatorname{Reg}(\theta) \quad (4)$$

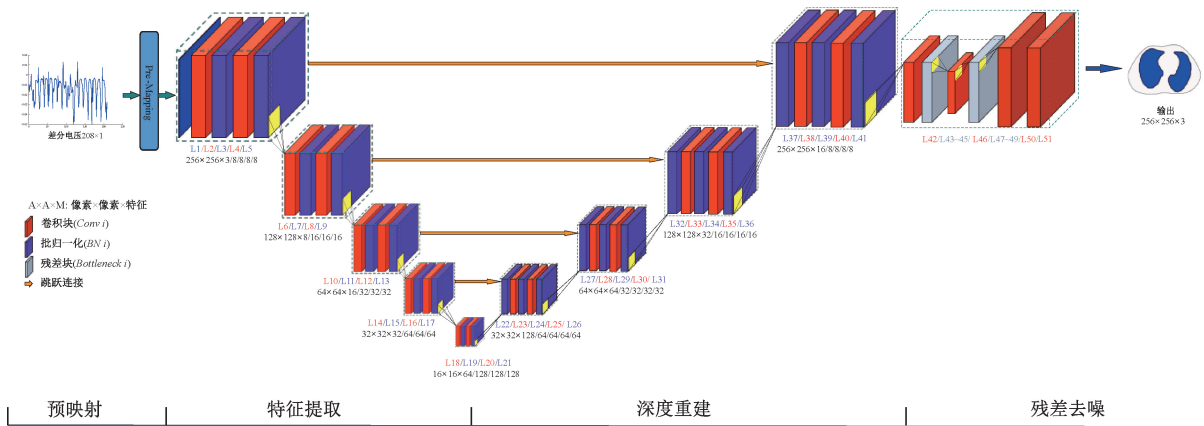


图2 V-ResNet 网络结构

Fig. 2 V-ResNet network structure

V-ResNet 是由预映射 (pre-mapping) 模块、特征提取 (feature extraction, FE) 模块、深度重建 (deep reconstruction, DR) 模块和残差去噪 (residual denoising, RD) 模块所构成的一种深度卷积神经网络。

网络的输入信息为差分处理后的边界电压 $\Delta\mathbf{V}$, 通过 Pre-Mapping 模块将所测得的边界电压 $\Delta\mathbf{V}$ 映射为待测场域内阻抗分布的初始特征图像。特征提取部分将 $256 \times 256 \times 3$ 的低维特征压缩为 $16 \times 16 \times 128$ 的高维特征, 深度重建模块将提取到的低维特征信息恢复成与输入像素相同的高维特征, 重构的特征图经残差模块滤波去噪, 可获得准确的重建图像。考虑到网络的复杂性, 在每一个特征提取块和与之对应的深度重建块之间加入跳跃连接。跳跃连接与残差模块加深了网络前馈信息流的传播, 有利于重建过程中特征传递的完整性, 并有效地解决了层数较深的网络出现梯度弥散问题。

为了克服 EIT 欠定性对逆问题求解的影响, 本文基于 TR 正则化算法原理, 构建了可训练的 pre-mapping 模块, 来降低灵敏度矩阵的条件数, 使得逆问题的解适定。

式中: f 代表学习输入量与输出量之间关系的网络模型; m 代表总训练样本个数; 输入量 $\Delta\mathbf{V}_k$ 是电压差分值, 且 $\Delta\mathbf{V}_k = \mathbf{V}_{ref} - \mathbf{V}_{in}$, 其中 k 为当前的训练样本; \mathbf{V}_{ref} 是空场 (呼气末, 此时肺部体积最小) 电压值; \mathbf{V}_{in} 是满场 (任一时刻吸气状态) 电压值; $f(\Delta\mathbf{V}_k)$ 表示空场与满场之间的场域电导率的差分分布; θ 表示网络参数; $\operatorname{Reg}(\theta)$ 表示网络参数的正则化。

1.2 V-ResNet 的网络结构

为提升 EIT 重建图像的分辨率及边界的精确表达, 提出一种拓扑形状近似字母“V”的 CNN 深度神经网络, 且在图像重建后加入了残差连接的卷积去噪模块, 故称之为 V-ResNet, 其结构如图 2 所示。

预映射模块的数学表达式为:

$$\sigma_{pre} = \operatorname{LeakyReLU}[(\mathbf{S}^T \mathbf{S} + \mathbf{J})^{-1} \cdot \mathbf{S}^T \Delta\mathbf{V}_k] \quad (5)$$

其中, σ_{pre} 是学习得到的初始电场分布特征; \mathbf{S} 是灵敏度矩阵; \mathbf{S}^T 是灵敏度矩阵的转置; \mathbf{J} 是可学习的正则化矩阵。利用 Leaky ReLU 函数将映射结果的范围限制在 $[0, 1]$ 内, 使数据更加规范化, 网络收敛速度更快。Pre-Mapping 模块拟合边界电压与电导率分布之间的非线性映射, L_0 为输入边界测量得到的差分电压信号 $\Delta\mathbf{V} \in \mathbb{R}^{208 \times 1}$, 经过 Pre-Mapping 模块输出维度为 $65\ 536 \times 1$ 的列向量, 考虑到其空间特征的分布, 将求解得到的列向量投影为特征分布矩阵 $\sigma_{pre} \in \mathbb{R}^{256 \times 256 \times 3}$, 其中, 256×256 表示特征图像的像素, 3 为图像的通道数, 并将其作为特征提取模块的输入 L_1 。

$L_1 \sim L_{21}$ 为 V-ResNet 的特征提取部分 (FE, $k = 1, 2, 3, 4, 5$), 该部分主要包含卷积 (Conv) 和批归一化 (batch normalization, BN) 模块, 每个 FE 模块包含 2 个卷积层 $\operatorname{Conv}_i (i = 2, 4, \dots, 18, 20)$ 和 2 个 BN 层 $\operatorname{BN}_i (i = 3, 5, \dots, 19, 21)$ 。该部分将输入信息 $L_1 \in \mathbb{R}^{256 \times 256}$ 压缩为 $L_{21} \in \mathbb{R}^{16 \times 16}$ 的抽象特征, 对应的特

征图数量从3逐渐增加至128。不同模块之间的连接使用最大池化的方式对经过2次Conv-BN运算后的特征进行下采样。

$L_{22} \sim L_{41}$ 为V-ResNet的深度重建模块部分(DR_k , $k=1,2,3,4$),在 DR_1 、 DR_2 、 DR_3 和 DR_4 这4个深度重建模块中,每个模块包含2个卷积层 $Conv_i$ ($i=23,25,28,30,33,35,38,40$)、3个BN层 BN_i ($i=22,24,26,27,29,31,32,34,36,37,39,41$),每个DR模块之间使用转置卷积(transposed convolution, TConv)^[24]进行连接。由于TConv直接利用卷积运算的转置形式,无需在像素之间插值,抑制了使用上采样运算造成的图像伪影。

特征提取模块中的特征输出(L5, L9, L13和L17)与深度重建模块的输入(L22, L27, L32和L37)之间使用跳跃连接方式,实现对特征提取信息与图像重建信息的融合,缩短网络训练的时间。

V-ResNet网络结构在FE-DR模块后加入一种残差去噪模块。残差即观测值与估计值之间的差,从数学角度表达为:

$$\begin{cases} y_l = h(x_l) + F(x_l, W_l) \\ x_{l+1} = f(y_l) \end{cases} \quad (6)$$

式中: x_l 和 x_{l+1} 代表残差单元的输入和输出; F 是学习到的残差; $h(x_l) = x_l$ 表示恒等映射; f 是激活函数。 y_l 和 W_l 分别是输出层上一层的残差学习结果和权重。那么,从浅层 l 到深层 L 学习的特征为:

$$x_L = x_l + \sum_{i=1}^{L-1} F(x_i, W_i) \quad (7)$$

这种结构一方面对输入图像起到低通滤波的作用,抑制高频噪声的干扰,使图像边界更加平滑;另一方面,能够有效克服在少量数据情况下训练产生过拟合现象。

ResNet^[25]去噪模块相比于浅层CNNs使用更少的参数,改善了前馈信息流和反向梯度流的传播,起到了一种隐形深度监督的作用。

提出的ResNet残差块采用的是“ $1 \times 1 + 3 \times 3 + 1 \times 1$ ”式的三次卷积, 1×1 卷积可以缩减或扩张特征维度,从而使 3×3 卷积的特征过滤不受上一层输入的影响,其输出也不会影响到下一层。第一个 1×1 的卷积层对输入的特征图进行降维处理,然后在 3×3 的卷积层进一步提取特征信息,下一个 1×1 的卷积层对上一层输出的特征信息进行还原,这样既可以保持模型精度又能减少网络参数和计算量,节省计算时间。设计的残差结构Bottleneck1特征图的输入尺寸为 $128 \times 128 \times 8$,经过三层卷积之后输出特征尺寸与输入特征尺寸保持一致,在与输入特征信息相融合之后作为Bottleneck1的总输出,为了提取更精细的目标特征,进行一次最大池化运算得到 $64 \times 64 \times 8$ 的特征图,然后通过转置卷积运算可得到 $128 \times 128 \times 32$ 的特征图。将所得的 $128 \times 128 \times 32$ 特征图作为残差结构

Bottleneck2的输入,再次进行与Bottleneck1相同操作之后可得到尺寸大小为 $128 \times 128 \times 32$ 的特征图,然后对其进行一次转置卷积运算得到 $256 \times 256 \times 32$ 的特征图,利用卷积运算调整输出结果的通道数,使其与标签分布一致,最终得到 $256 \times 256 \times 3$ 的重建图像。

2 网络模型训练

2.1 仿真数据集的建立

深度学习网络的训练需要大量的数据样本,而且样本的训练在一定的程度上会影响网络的泛化能力。基于EIT工作原理,本研究借助大量的人体胸部CT扫描图像建立了多种肺部仿真模型,使用COMSOL Multiphysics联合MATLAB建立人体肺部模型数据库。

基于CT扫描图建立不同的肺部仿真模型,充分考虑个体差异性,建立了不同胸腔边界及不同肺部健康状态的肺部仿真模型。在仿真建立过程中,皮下组织(含脂肪)电导率设置为 0.037 S/m ,肺部区域电导率设置为 $0.138 \sim 0.142 \text{ S/m}$,心脏的电导率设置为 0.67 S/m ^[26-27]。为更准确表达肺部边界信息,使得重建图像边界更加清晰,将场域内的截面剖分成 256×256 个网格,即基于V-ResNet的最终重建图像像素数是 256×256 。仿真模型剖分示意图如图3所示。其中图3(a)为空场剖分网格,图3(b)满场剖分网格。

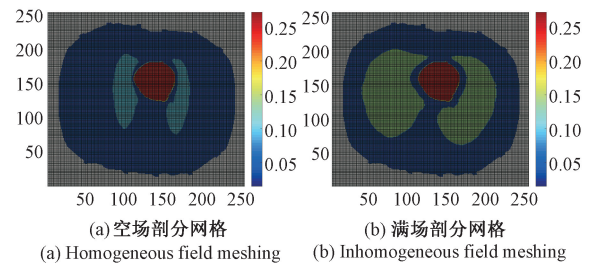


图3 仿真模型剖分示意图

Fig. 3 The meshing schematic diagram of the simulation model

为了更好地反映网络模型对于实际病变肺部图像的成像效果,以及网络模型的泛化能力,数据集中还包括多种肺部病变模型,不同的病变情况对应的电导率分布情况也不相同。数据集中包含12 000个肺部仿真模型,其中7 000个模型用于网络训练,3 000个模型用于网络验证并以此对网络参数进行调整,剩余的2 000个模型用于测试网络的泛化能力。

2.2 模型训练

基于V-ResNet的网络模型训练与测试采用所建仿真数据库中样本完成。训练过程可分为3个步骤,分别为数据归一化处理、模型学习和模型评价。

数据归一化处理数学公式为:

$$Z_i^* = \frac{Z_i - Z_{\min}}{Z_{\max} - Z_{\min}} \quad (8)$$

其中, Z_i^* 为归一化后的结果, Z_i 为原始数据(边界电压或标签电导率), Z_{\min} 、 Z_{\max} 分别表示向量 \mathbf{Z} 的最小值和最大值, $i \in [1, N]$, N 为向量 \mathbf{Z} 中元素的个数。归一化处理后样本数据在 $[0, 1]$ 内, 消除了不同量纲导致的不良影响。

训练过程中, 将训练集的 7 000 个模型随机打乱, 然后逐一进行训练学习。以每一组通过 V-ResNet 网络结构输出的场域的电导率分布与对应的真实电导率分布的标签信息作为损失函数的自变量, 进行约束与监督。遍历训练集中的每一组数据为一个训练周期, 共训练了 1 000 个周期。

损失函数在 V-ResNet 网络模型的训练中起到了重要的作用。考虑到 V-ResNet 网络的深度与复杂性, 定义了基于均方误差的损失函数, 即:

$$Loss(\mathbf{W}, \mathbf{b}) = \frac{1}{m} \sum_{i=1}^m \|f_{ERR}(\Delta \mathbf{V}_i) - \sigma_{\text{label}i}\|_2^2 \quad (9)$$

式中: \mathbf{W} 是网络中的权重矩阵; \mathbf{b} 是网络中的偏置向量; m 是训练样本的总个数; $f_{ERR}(\Delta \mathbf{V}_i)$ 为预测的电导率像素分布; $\sigma_{\text{label}i}$ 为对应的标签电导率像素分布。

模型的评价需要通过比较训练集与验证集的损失值曲线来完成, 使用 Adam^[28] 最优化方法来不断调整 V-ResNet 的参数, 重复上述步骤, 直至损失函数满足设定的收敛条件或达到最终的迭代次数来获得最优的网络模型。获得最优网络模型后, 使用测试数据样本, 求解出场域内电导率分布, 然后与模型原始设置值进行比较, 以此验证网络模型的图像重建效果。

3 结 果

3.1 评价指标

为比较 EIT 图像重建质量, 选择相对误差 (relative error, RE) 和结构相似度系数 (structural similarity, SSIM) 作为评价指标。定义公式如下。

$$RE = \frac{\|\alpha^* - \alpha\|}{\|\alpha\|} \quad (10)$$

其中, α^* 为原始图像电导率分布; α 表示重建图像的电导率分布。

$$SSIM = \frac{4\alpha_x \alpha_i^* * \alpha_{xy}}{(\bar{\alpha}_i^{*2} + \bar{\alpha}_i^2)(\alpha_x^2 + \alpha_y^2)} \quad (11)$$

其中, $\bar{\alpha}_i$ 和 $\bar{\alpha}_i^*$ 表示重建图像电导率分布和原始图像电导率分布的平均值; α_x 、 α_y 表示重建图像电导率分布 α_i 和原始图像电导率分布 α_i^* 的方差; α_{xy} 为协方差矩阵。

3.2 仿真实验

为考察研究所提出的 V-ResNet 网络模型的性能, 将测试集中的数据作为网络模型的输入进行训练, 并将 EIT 图像重建结果与常用的 TV^[29]、TR^[30]、CG^[31] 及 CNN^[32] 等算法所获得重建结果进行比较, 验证 V-ResNet 网络结构对 EIT 逆问题的非线性表征能力。5 种不同算法对应的部分仿真结果如图 4 所示, 其中第 1 列是仿真实验模型, 第 2、3、4、5、6 列分别对应 TV 算法、TR 算法、CG 算法、CNN 算法和 V-ResNet 算法对应的图像重建结果。

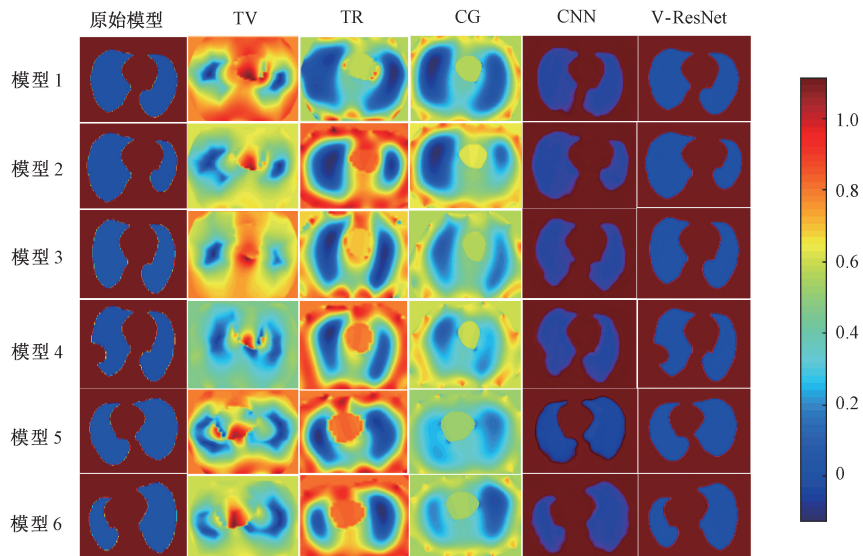


图 4 5 种算法的仿真成像结果

Fig. 4 Simulation imaging results of five algorithms

从仿真实验的图像重建结果可以得出,采用TV正则化算法可以大致体现出场域内电导率的分布,但是不能准确描述出场域的边界信息,重建图像中伴随严重伪影。相比于TV正则化算法,利用TR算法和CG算法重建的图像质量有一定的提升,但是在图像重建过程中受到各种因素的干扰,如模型误差、正则化系数等,其成像结果依然含有较为明显的伪影;对于部分肺部缺失模型,如模型4,TR和CG算法不能够精确表达其缺失部分的边界信息。基于深度学习的CNN算法,相比于EIT中上述的3种传统图像重建算法,重建图像的质量明显提升,边界清晰。但是其在重建复杂边界时会产生一定的误差,如模型4,虽然其对右肺缺失部分有较为清晰的表达,但是仍然存在一定的偏差。而采用提出的V-ResNet算法重建肺部特征空间分布的图像,不仅能够准确反映待测场域内肺部的形状,而且成像分辨率高,边界清晰,可视化效果好,且其对复杂病态肺部模型的重构优于其他4种算法。说明使用深度CNN网络结构结合残差模块可以明显改善成像质量,有较强的鲁棒性。

为定量描述不同算法下重建图像的质量,分别计算使用不同算法重建图像的平均RE和SSIM。结果如图5所示。

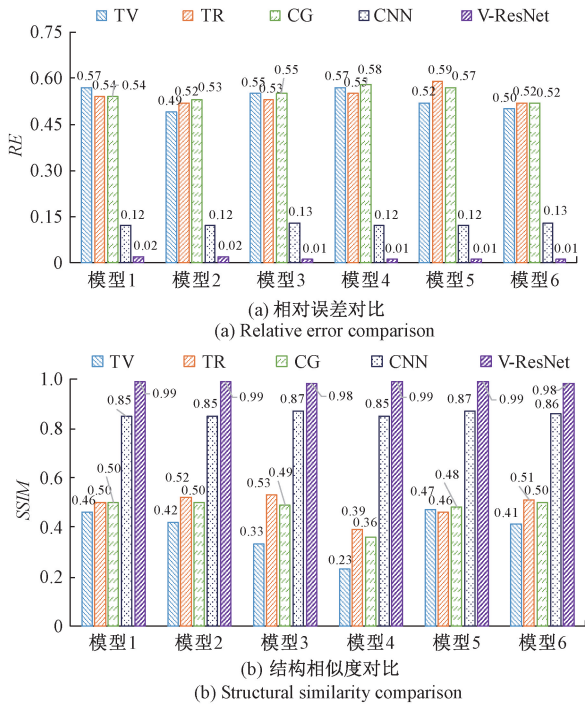


图5 不同模型的平均RE和SSIM

Fig. 5 Average RE and SSIM of different modules

图5的相关的评价指标表明,TV、TR和CG这3种传统成像算法重建图像的RE较高,说明这3种算法对边界变化的敏感度较高,容易受模型复杂度的影响。

基于深度学习的CNN算法,其重建图像的RE和SSIM相较于TV、TR和CG算法较为稳定且数值较高。所提出的V-ResNet图像重建算法所得结果的RE明显低于传统的成像算法与深度CNN网络模型,SSIM远远高于其他4种成像方法。可以得出V-ResNet图像重建算法相比于其他4种算法鲁棒性更强,不易受模型复杂度的影响。

3.3 Tank实验

基于V-ResNet网络模型的图像重建模型实验,采用16电极EIT系统进行目标数据的测量及采集。EIT系统及实验模型如图6所示。硬件系统包括一套胸腔模型模型,FPGA信号处理模块,电源和包含图形用户界面(graphical user interface, GUI)的个人计算机。



图6 EIT实验系统

Fig. 6 EIT experiment system

实验中,EIT系统的激励电流是幅值4.5 mA、频率为100 kHz的微弱交流电信号;根据CT扫描图像胸腔实际大小利用树脂构建胸腔模型,并在胸腔模型表面贴附16个钛电极作为电流传输介质。实验过程中,使用琼脂材料制作肺部和心脏的仿体模型,并向模型中加入不同浓度的NaCl增加电导率,其中背景为电导率0.037 S/m的盐水,心脏的电导率为0.68 S/m,肺部的电导率为0.139 S/m。结合仿真数据的采集过程,设置空场为含有心脏和残气量最少的两肺的仿体模型并测量边界电压,然后放入不同的肺部仿体作为满场并测量边界电压,实验结果如图7所示。

实验成像结果表明,在实际数据采集系统中获得的电压数据通常由于测量的误差、噪声等多种因素导致获得的电压数据与仿真结果并不一致,所以基于模型驱动的3种成像方法仅可以给出电导率分布的大致情况,但是边界的失真较为严重。浅层CNN网络成像结果明显优于依赖于模型精度的算法,但是重构的边界与ROI区域的大小有一定的误差。所提出的V-ResNet方法重建的肺部区域边界清晰,对于复杂边界的重建结果较为准确,与仿体模型的分布情况基本一致,说明该方法重建图像准确度较高。一方面,由于V-ResNet的网络结构较深,可以充分提取输入信息的全部特征,同时加入了ResNet连接的去噪模块,使得重建图像的边缘较为平滑,有效地去除复杂边界所导致的局部失真,另一方面,由

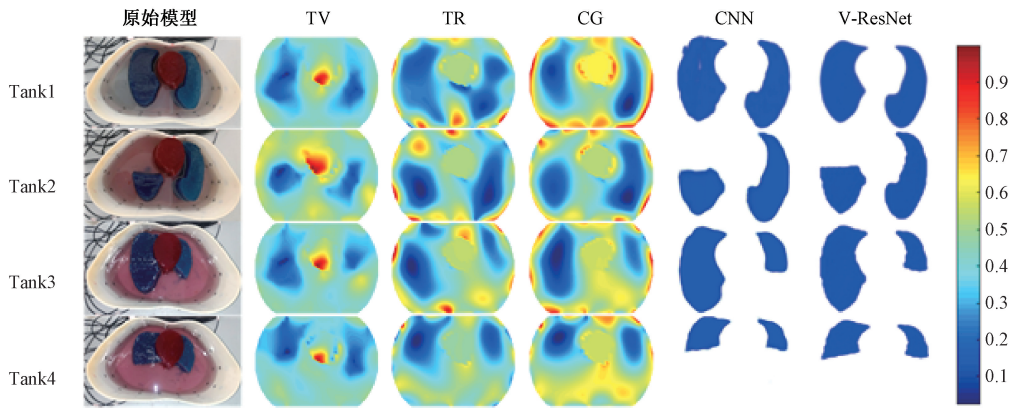


图 7 Tank 实验

Fig. 7 Tank experiments

于在训练集中包含多种肺部病变模型,所以 V-ResNet 对不同肺部疾病情况的重建具有更好地鲁棒性。表 1 给出了基于 Tank 模型重建结果的量化评价指标。

从表 1 指标分析可知,TV、TR 和 CG 方法对测量的噪声较为敏感,成像结果误差较大,ROI 区域的结构与期望值差异明显,说明数值求解算法的泛化能力和鲁棒性

较低。对 V-ResNet 指标分析可知,RE 相比于传统算法和 CNN 方法明显下降,SSIM 明显提高,尤其是表征重建图像的结构信息、图像亮度分布的 SSIM 指标相比于基于模型的重建方法有着明显的提升。说明 V-ResNet 方法对不同模型具有良好的泛化能力,且鲁棒性能明显好于模型驱动方法和浅层 CNN 网络。

表 1 Tank 实验评价指标

Table 1 Evaluation indexes of Tank experiments

Tank 模型	评价指标	TV	TR	CG	CNN	V-ResNet
Tank1	RE	0.600 2	0.593 5	0.509 1	0.405 2	0.102 1
	SSIM	0.287 2	0.363 8	0.491 0	0.640 9	0.979 1
Tank2	RE	0.524 4	0.570 1	0.561 0	0.365 9	0.157 7
	SSIM	0.367 7	0.402 7	0.402 5	0.702 6	0.940 9
Tank3	RE	0.584 8	0.537 0	0.513 7	0.316 5	0.133 2
	SSIM	0.276 1	0.406 1	0.391 5	0.752 5	0.941 3
Tank4	RE	0.609 3	0.595 9	0.518 7	0.386 5	0.167 4
	SSIM	0.240 3	0.325 7	0.434 0	0.706 2	0.983 7

4 结 论

针对人体肺部图像重建问题,提出一种基于深度学习的 V-ResNet 网络模型的图像重建算法。该算法通过深度卷积神经网络组成的特征提取模块、深度重建模块以及残差连接构成的图像去噪模块充分学习边界测量信息与场域内电导率分布的非线性映射,且 Pre-Mapping 模块有效地改善了 EIT 逆问题的欠定性,简化了网络训练过程。

基于 V-ResNet 网络模型的图像重建算法,对所建数据库模型进行不同肺部图像重建的仿真和实验。结果表

明 V-ResNet 图像重建算法与 EIT 中常用的 TV、TR、CG 和 CNN 算法相比,图像重建分辨率更高,可化效果好,边界清晰,没有伪影,但是 V-ResNet 图像重建的时间性还需进一步的研究改进。

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] LI F, TAN C, DONG F. Electrical resistance tomography image reconstruction with densely connected convolutional neural network [J]. IEEE Transactions on Instrumentation and Measurement, 2020, 70 (99):1-11.
- [3] 董峰,许燕斌. 电阻层析成像技术在两相流测量中的应用[J]. 工程热物理学报,2006,27 (5): 791-794.
DONG F, XU Y B. Application of electrical resistance tomography in two-phase flow measurement [J]. Journal of Engineering Thermophysics, 2006, 27(5):791-794.
- [4] 任尚杰,董峰,谭超,等. 基于边界元与有限元耦合的ERT图像重建算法 [J]. 工程热物理学报, 2014, 35(5):902-905.
REN SH J, DONG F, TAN CH, et al. A hybrid BEM/FEM method for reconstructing phase distribution within annular channel [J]. Journal of Engineering Thermophysics, 2014, 35(5):902-905.
- [5] GESELOWITZ D B. An application of electrocardiographic lead theory to impedance plethysmography [J]. IEEE Transactions on Bio-medical Engineering, 1971, 18(1):38-41.
- [6] LEHR J. A vector derivation useful in impedance plethysmographic field calculations [J]. IEEE Transactions on Biomedical Engineering, 1972, 2 (2): 156-157.
- [7] LI F, DONG F, TAN CH, et al. Landweber iterative image reconstruction method incorporated deep learning for electrical resistance tomography [J]. IEEE Transactions on Instrumentation and Measurement, 2020, 70: 1-11.
- [8] WOO E J, WEBSTER J G, TOMPKINS W J, et al. The improved Newton-Raphson method and its parallel implementation for static impedance imaging [C]. International Conference of the IEEE Engineering in Medicine & Biology Society. USA, 1990, 7 (6): 102-103.
- [9] BO Z, WANG H, CHEN X, et al. linearized solution to electrical impedance tomography based on the schur conjugate gradient method [J]. Measurement Science and Technology, 2007, 18(11):3373.
- [10] ZIFAN A, LIATIS P, CHAPMAN B E, et al. The use of the Kalman filter in the automated segmentation of EIT lung images [J]. Physiological Measurement, 2013, 34(6):671-694.
- [11] LUKASCHEWITSCH M, MAASS P, PIDCOCK M, et al. Tikhonov regularization for electrical impedance tomography on unbounded domains [J]. Inverse Problems, 2003, 19(3):585-610.
- [12] LIU J, LIN L, ZHANG W, et al. A novel combined regularization algorithm of total variation and Tikhonov regularization for open electrical impedance tomography [J]. Physiological Measurement, 2013, 34(7):823-838.
- [13] HINTON G E, SALAKHUTDINOV R R. Reducing the dimensionality of data with neural networks [J]. Science, 2016, 313(5786):504-507.
- [14] TIAN W, YAO Y, YANG C, et al. Auto-sorting system toward smart factory based on deep learning for image segmentation [J]. IEEE Sensors Journal, 2018, 18(20): 8493-8501.
- [15] REN S, HE K, GIRSHICK R, et al. Faster R-CNN: towards real-time object detection with region proposal networks [J]. IEEE Transactions on Pattern Analysis & Machine Intelligence, 2017, 39(6):1137-1149.
- [16] CHAO X, LIU L, ZHAO X, et al. Convolutional fusion network for face verification in the wild [J]. IEEE Transactions on Circuits & Systems for Video Technology, 2016, 26(3):517-528.
- [17] 李峰,谭超,董峰,等. 全连接深度网络的电学层析成像算法[J]. 工程热物理报,2019,40(7):1526-1531.
LI F, TAN CH, DONG F, et al. Fully connected deep network algorithm for electrical tomography [J]. Journal of Engineering Thermophysics, 2019, 40 (7): 1526-1531.
- [18] 陈瑞娟,吴伟巍,李芳,等. 基于结构先验信息的磁探测电阻抗成像算法研究 [J]. 仪器仪表学报, 2019, 40(1):257-264.
CHEN R J, WU W W, LI F, et al. Research on magnetic detection electrical impedance tomography based on structural prior information [J]. Chinese Journal of Scientific Instrument, 2019, 40(1):257-264.
- [19] ZHENG J, PENG L H. An autoencoder-based image reconstruction for electrical capacitance tomography [J]. IEEE Sensors Journal, 2018, 18(13): 5464-5474.
- [20] 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):1-9.
- [21] 叶明,李晓丞,刘凯,等. 一种基于 U²-Net 模型的电阻抗成像方法 [J]. 仪器仪表学报, 2021, 42(2):235-243.
YE M, LI X CH, LIU K, et al. Image reconstruction method for electrical impedance tomography using U²-Net [J]. Chinese Journal of Scientific Instrument, 2021, 42(2):235-243.
- [22] WEI Z, LIU D, CHEN X D, et al. Dominant-current deep learning scheme for electrical impedance

- tomography[J]. IEEE Transactions on Biomedical Engineering, 2019, 66(9): 2546-2555.
- [23] 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.
- [24] DURALL R, KEUPER M, KEUPER J, et al. Watch your up-convolution: CNN based generative deep neural networks are failing to reproduce spectral distributions[C]. 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), 2020:7887-7896.
- [25] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition [C]. 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). IEEE, 2016.
- [26] GELIDI S D, SEIFNARAGHI N, BARDILL A, et al. Towards a thoracic conductive phantom for EIT [J]. Medical Engineering & Physics, 2020, 77:88-94.
- [27] WANG H, HU L, WANG J, et al. An image reconstruction algorithm of EIT based on pulmonary prior information [J]. Frontiers of Electrical and Electronic Engineering in China, 2009, 4(2):121-126.
- [28] KINGMA D, BA J. Adam: A method for stochastic optimization [J]. Computer Science, 2014, 9:273-297.
- [29] WANG H, LEI T, ZHANG C, et al. An image reconstruction algorithm based on total variation with adaptive mesh refinement for ECT [J]. Flow Measurement and Instrumentation, 2007, 18(5-6): 262-267.
- [30] XU Y, PEI Y, DONG F, et al. An adaptive Tikhonov regularization parameter choice method for electrical resistance tomography [J]. Flow Measurement and Instrumentation, 2016, 50:1-12.
- [31] WANG H X, ZHU X M, ZHANG L F, et al. Conjugate gradient algorithm for electrical capacitance tomography[J]. Journal of Tianjin University, 2005, 38(1): 1-4.
- [32] GAO Y, LU Y, LI H, et al. EIT-CDAE: A 2-D electrical impedance tomography image reconstruction method based on auto encoder technique[C]. 2019 IEEE Biomedical Circuits and Systems Conference (BioCAS), 2019:1-4.

作者简介



付荣, 2018年于江苏海洋大学获得学士学位, 现为天津科技大学硕士研究生, 主要研究方向为基于EIT的人体肺部图像重建、多相流和深度学习。

E-mail: 1900466012@qq.com.

Fu Rong received her B. Sc. degree in Jiangsu Ocean University in 2018. Now, she is studying for her M. Sc. degree in Tianjin University of Science and Technology. Her main research interests include the image reconstruction algorithms of human lungs based on Electrical Impedance Tomography, Multiphase flow and Deep Learning.



陈晓艳(通信作者), 2009年于天津大学获得博士学位, 现为天津科技大学教授, 主要研究方向为深度学习、图像处理、电阻抗层析成像和多相流等。

E-mail: cxywxr@tust.edu.cn

Chen Xiaoyan (Corresponding author) received her Ph. D. degree from Tianjin University in 2009. Now she is a professor in Tianjin University of Science and Technology. Her main research interests contain Deep Learning, Image Processing, Electrical Impedance Tomography and Multiphase flow.