DOI: 10. 13382/j. jemi. B2104769

# 肺部电阻抗成像电极阵列优化方法研究\*

王 琦<sup>1,2</sup> 尹鑫铭<sup>1,2</sup> 李晓捷<sup>1,2</sup> 李秀艳<sup>2,3</sup> 段晓杰<sup>2,3</sup> 汪剑鸣<sup>2</sup> 张荣华<sup>2</sup> 王化祥<sup>4</sup>

(1.天津工业大学生命科学学院 天津 300387;2.天津市光电检测技术与系统重点实验室 天津 300387;
3.天津工业大学电气与电子工程学院 天津 300387;4.天津大学电气工程及自动化学院 天津 300072)

摘 要:肺部电阻抗层析成像(EIT)电极阵列的设计是影响系统性能与成像效果的关键因素之一,目前多在规则形状物场、等间距分布的前提条件下对电极阵列进行优化,却并不适用于肺部不规则边界的情况。本文提出基于深度学习的肺部电阻抗层 析成像电极阵列优化方法,以电极位置为优化目标,以重建图像相对误差、图像相关系数、敏感场分布的均匀性以及敏感场 Hessian 矩阵的条件数为网络输入,以阵列电极位置为网络输出,基于 DNN 网络构建优化模型。实验结果表明,在呼气末和吸 气末两种状态下,与传统的电极阵列均匀分布方法相比,基于深度学习的肺部 EIT 电极阵列优化方法将重建图像相关系数 (image correlation coefficient,ICC)分别提高了 33.17%、33.86%,结构相似度(structural similarity,SSIM)分别提高了 14.5%、 14.39%,峰值信噪比(peak signal-to-noise ratio,PSNR)分别提高了 26.3%、28.27%。因此可以得出结论,与传统方法相比基于深 度学习的 EIT 电极阵列优化方法更适用于肺部 EIT 成像。

关键词:肺部电阻抗成像;人体三维胸腔模型;电极位置优化;深度学习 中图分类号:R318 文献标识码:A 国家标准学科分类代码:310.61

# Optimization of electrode array for lung electrical impedance imaging

Wang Qi<sup>1,2</sup> Yin Xinming<sup>1,2</sup> Li Xiaojie<sup>1,2</sup> Li Xiuyan<sup>2,3</sup> Duan Xiaojie<sup>2,3</sup>

Wang Jianming<sup>2</sup> Zhang Ronghua<sup>2</sup> Wang Huaxiang<sup>4</sup>

(1. School of Life Sciences, Tiangong University, Tianjin 300387, China; 2. Tianjin Key Laboratory

of Photoelectric Detection Technology and System, Tianjin 300387, China; 3. School of Electronic

and Information Engineering, Tianjin Polytechnic University, Tianjin 300387, China; 4. School of Electrical

Engineering and Automation, Tianjin University, Tianjin 300072, China)

Abstract: The design of electrical impedance tomography (EIT) electrode array is one of the key factors affecting the performance and imaging effect of the system. At present, the electrode array is optimized under the premise of regular shape field and equal spacing distribution which is not suitable for irregular lung boundaries. In this paper, an optimization method of electrode array based on deep learning network is proposed for lung EIT. The optimization goal of the network is electrode position. The relative error of the reconstructed image, the image correlation coefficient, the distribution uniformity and the condition number of the Hessian matrix for the sensitive field are used as the network inputs. The positions of the electrodes are taken as the network output. The optimization model is constructed based on DNN network. The experimental results show that, for end-expiration and end-inspiration states, the ICC, SSIM and PSNR of images reconstructed based on measured data obtained from optimized electrode array with equal-distance distribution. Therefore, it can be concluded that optimizing electrode positions for lung EIT using deep learning is more suitable than traditional methods.

Keywords: pulmonary electrical impedance imaging; three-dimensional chest model of human body; electrode position optimization; deep learning

收稿日期: 2021-09-28 Received Date: 2021-09-28

\*基金项目:国家自然科学基金(61872269,61903273,62071328,62072335)、天津市自然科学基金(18JCYBJC85300)、天津市科技计划项目 (19PTZWHZ00020,20YDTPJC00110)资助

## 0 引 言

电阻抗层析成像(electrical impedance tomography, EIT)技术是近几十年发展起来的一种新型无损成像技术<sup>[1]</sup>。其成像原理是根据被测物体内不同介质的电导率 分布特性,将一系列电极置于物体表面,给电极施加微弱 的安全电流以测量体表电压,将测得的电压值输送至计 算机,根据相应的图像重建算法对被测物体内部的电导 率进行层析成像<sup>[2]</sup>。典型的 EIT 系统是由传感器阵列、 数据采集和处理单元和图像重建单元组成。

肺脏是胸腔的重要组成部分。肺是一个动态系统里面充满空气,且占据胸腔很大一部分面积,所以肺部区域与周围组织之间的电导率具有明显差异<sup>[3]</sup>,因此 EIT 技术非常适用于肺部成像。肺部 EIT 技术具有非侵入、安全无辐射、响应速度快、可实时连续监测等优势<sup>[4]</sup>,已成为临床医学影像技术的有力补充手段,已经证明 EIT 技术在许多肺部成像方面是有效的,例如在肺通气过程中提供<sup>[5]</sup>实时反馈,为肺结节良恶性分类<sup>[6]</sup>提供技术支持。目前已有临床 EIT 设备可用,尤其是使用 EIT 技术对肺通气进行成像方面取得了显著进展<sup>[7]</sup>。

在 EIT 系统中,电极阵列的设计是影响整个系统分 辨率的关键一步<sup>[8]</sup>。随着 EIT 技术的不断发展,为获取 更高质量的重建图像,国内外许多学者相继对 EIT 电极 阵列进行了研究。EIT 电极优化一般基于仿真模型,为 了计算简便,最初采用二维模型对电极宽度<sup>[9]</sup>、电极间 距<sup>[9]</sup>、电极材料<sup>[10]</sup>、电极个数<sup>[11]</sup>等方面进行优化;随后, 三维模型进一步增加了对多层电极平面间距<sup>[12]</sup>、电极形 状<sup>[13]</sup>、电极尺寸<sup>[14]</sup>、电极结构<sup>[15]</sup>等方面进行优化。

目前,EIT系统电极阵列优化方法主要集中在对电 极个数、电极长度、电极宽度、电极厚度的讨论,而对电极 位置的讨论较少。文献[16]提出基于电导率先验信息, 在贝叶斯范式中寻找最佳电极位置,但这在数值计算上 很难实现。传统方法中,在规则形状物场条件下,采用电 极均匀分布方式进行电极优化。然而,在肺部 EIT 中,包 含肺部的胸腔是不规则物场,这给电极阵列空间位置的 确定带来了一定困难。同时,文献[17]也通过二维规则 物场仿真的方式,证明了均匀分布的电极位置并不一定 是最佳电极位置。基于三维肺部 EIT 模型,本文提出了 一种基于深度学习的方法优化肺部 EIT 电极阵列。该方 法将随机电极位置条件下成像过程相关参数:重建图像 相对误差、图像相关系数、敏感场分布的均匀性以及敏感 场 Hessian 矩阵的条件数作为网络模型的输入,将真实阵 列电极位置样本作为网络模型的标签,即期望输出,通过 训练深度神经网络模型建立输入与输出之间的非线性映 射关系。当网络模型训练好后输入参数的理论最优值,

以输出最优的电极位置。基于深度学习的肺部 EIT 电极 阵列优化方法,通过优化成像过程相关参数,改善了 EIT 逆问题的非线性和不适定性,进而提高了重建图像的空 间分辨率。通过重建图像衡量标准表明相对于均匀分布 的电极阵列,位置优化后的电极阵列的重建图像质量更 优,更适用于肺部 EIT 成像。

# 1 基于 EIT 正问题的人体三维胸腔模型的 构建

本文在呼气末和吸气末两种特定状态下建立了人体 三维胸腔模型。如图 1 所示,基于人体肺部 CT 图像,经 过相应的处理,可得到人体真实的胸腔和肺部轮廓相对 准确的边界信息。本文主要对单层电极模型进行了研 究,电极位于胸腔中部,人体三维胸腔模型构建过程如 图 1 所示。



本文考虑呼气末和吸气末两种呼吸状态,构建肺部 模型如图2所示,在胸腔中部位置设计一层电极,研究电 极优化方法,电极中心所在平面的剖面图如图3所示。 采用电极间夹角定义电极位置,规定以胸腔几何中心到 任意相邻电极表面中心连线的夹角为电极间夹角。传统 三维肺部 EIT 电极阵列一般采用均匀分布电极的方法, 由于胸部边界轮廓几何形状不规则,本文采用电极间夹 角均匀分布的方法,并采用相邻激励相邻测量的方式获 得测量数据。

# 2 肺部 EIT 电极阵列优化

#### 2.1 EIT 成像原理

EIT 的数学模型可以表示为:



(b) End-inspiration state

图 2 不同呼吸状态三维肺部模型

Fig. 2 3D lung model for two respiratory states

 $\boldsymbol{V} = \boldsymbol{U}(\boldsymbol{\sigma}, \boldsymbol{I}) = \boldsymbol{R}(\boldsymbol{\sigma})\boldsymbol{I}$ (1)

式(1)表示了电导率的分布以及激励电流 I 映射到 边界电压 V 的正向模型。

在实际中,被测量的物场和空场的相对电导率的变 化较小,可以通过线性化方程来表示:

$$\delta \boldsymbol{U} = \boldsymbol{U}'(\sigma_0) \delta \boldsymbol{\sigma} = \boldsymbol{J} \delta \boldsymbol{\sigma} \tag{2}$$

其中, σ 为电导率, δσ 表示被测物场与被测空场之 间电导率变化向量, δU 表示边界电压的变化值, J 为雅 可比矩阵或灵敏度矩阵,代表被测物体边界电压测量值 和电导率分布之间的线性映射关系,由式(2)可知灵敏 度矩阵可以表示为:

$$J = \frac{\partial U(\sigma)}{\partial \sigma} \bigg|_{\sigma = \sigma_0}$$
(3)

肺部 EIT 问题分为正问题和逆问题两部分。其中, 肺部 EIT 正问题是已知被测物体的电导率分布 δσ 以及 外加激励的情况下,求解被测物体的电位分布,从而获得 灵敏度矩阵 J 和边界电压变化值  $\delta U$ ;肺部 EIT 逆问题的 求解过程可以理解为图像重建过程,已知边界电压的变 化值  $\delta U$  和正问题中求得的灵敏度矩阵 J,求解被测物体 的电导率  $\sigma$ 。

### 2.2 肺部 EIT 电极阵列优化指标

为了定量评估电极阵列优化的结果,以获得最理想的成像效果,本文根据敏感场的特性提出以重建图像相对误差、图像相关系数、敏感场分布的均匀性以及敏感场 Hessian 矩阵的条件数作为优化指标,优化肺部 EIT 电极 阵列。

1)重建图像相对误差β

任何层析成像系统的最终评价标准是重建图像的保 真度。而重建图像相对误差反映了重建图像与真实图像 的差异,它包括重建图像在形状、面积等方面的误差信 息。因此选取重建图像相对误差作为本文训练优化算法 的输入参数,其表达式为:

$$\beta = \frac{\sqrt{\parallel \sigma - \sigma^* \parallel}}{\sqrt{\parallel \sigma^* \parallel}} \tag{4}$$

其中, $\sigma$ 是通过 EIT 成像算法得到的电导率分布值,  $\sigma^*$ 是仿真实验中真实的电导率分布值。 $\beta$  值越小,成像 质量越高。

2)图像相关系数 γ

图像相关系数是评价重建图像与真值图像相关程度 的重要指标,因此选取图像相关系数作为本文训练优化 算法的输入参数,其表达式为:

$$\gamma = ICC = \frac{\sum_{i=1}^{M} (\sigma'_{i} - \overline{\sigma'}) (\sigma^{*}_{i} - \overline{\sigma^{*}})}{\sqrt{\sum_{i=1}^{M} (\sigma'_{i} - \overline{\sigma'})^{2} \sum_{i=1}^{M} (\sigma^{*}_{i} - \overline{\sigma^{*}})^{2}}} \quad (5)$$

式中: $\sigma'$ 为重建图像区域计算的电导率均值, $\sigma^*$ 为被测 区域真实的电导率均值,M为图像像素数。

3) 敏感场分布的均匀性  $\varphi$ 

由 EIT 的"软场"特性可知,敏感场的分布是非均匀 的。靠近胸腔壁和激励电极处,敏感场的灵敏度高,而在 场的中心区域灵敏度低。改善敏感场分布的均匀性,可 改善系统的不适定性,因此敏感场分布的均匀性可以作 为本文训练优化算法的输入参数。

灵敏度矩阵的均值和标准差分别表示为:

$$\begin{cases} \boldsymbol{J}_{i,j}^{avg} = \frac{1}{n} \sum_{m=1}^{n} \boldsymbol{J}_{i,j}(m) \\ \boldsymbol{J}_{i,j}^{dev} = \left\{ \frac{1}{n-1} \sum_{m=1}^{n} \left[ \boldsymbol{J}_{i,j}(m) - \boldsymbol{J}_{i,j}^{avg} \right]^2 \right\}^{1/2} \end{cases}$$
(6)

其中,  $J_{i,j}^{areg}$  为灵敏度的均值,  $J_{i,j}^{dev}$  为灵敏度的标准差, J 为灵敏度矩阵, n 为测试点个数,  $J_{i,j}(m)$  为第m 个测试 点灵敏度。







定义电极对  $i \sim j$  之间的敏感场均匀分布指标为:  $\varphi_{i,j} = \mathbf{J}_{i,j}^{dee} / \mathbf{J}_{i,j}^{wg}$  (7)

显然, *φ<sub>i,j</sub>* 越小,表明 *i* ~ *j* 之间的敏感场分布越均 匀。对 16 个电极的系统,有:

$$\varphi = \frac{\sum_{i=1}^{15} \sum_{j=2}^{15} |\varphi_{i,j}|}{15}$$
(8)

其中, φ 值越小, 敏感场分布越均匀。

4) 敏感场 Hessian 矩阵的条件数  $\kappa$ 

求解 EIT 逆问题时,由于电导率变化的非线性和测 量数据量不足,导致了灵敏度矩阵 **J** 和敏感场 Hessian 矩 阵的严重病态性。为了更好地改善 EIT 逆问题的条件, 提高 EIT 测量的可靠性和重建图像质量,可以通过减少 Hessian 矩阵的条件数 κ 来减少 Hessian 矩阵的病态性。 因此敏感场 Hessian 矩阵的条件数可以作为本文训练优 化算法的输入参数。

敏感场 Hessian 矩阵定义如式(9)所示:

 $H = J^{\mathrm{T}}J$ 

敏感场 Hessian 矩阵的条件数定义如式(10) 所示:

 $\boldsymbol{\kappa} = \|\boldsymbol{H}^{-1}\| \|\boldsymbol{H}\|$ (10)

其中, κ 值越小, 敏感场 Hessian 矩阵的病态性越轻, 重建图像质量越好。

综上所述,输入参数 $\beta, \gamma, \varphi, \kappa$ 中包含了 EIT 敏感场

分布和成像质量的关键信息,将这些参数组合构成目标 向量 θ,作为电极优化网络的输入参数,定义如下:

$$\boldsymbol{\theta} = [\boldsymbol{\beta}, \boldsymbol{\gamma}, \boldsymbol{\varphi}, \boldsymbol{\kappa}]^{\mathrm{T}}$$
(11)

其中, $\beta$ 为重建图像相对误差, $\gamma$ 为图像相关系数,  $\varphi$ 为敏感场分布的均匀性, $\kappa$ 为敏感场 Hessian 矩阵的条 件数。

## 3 深度神经网络(DNN)模型的构建

#### 3.1 网络模型的结构

本文使用基于有监督学习方式的 DNN 网络模型,网 络训练过程中采用最速下降法,并通过反向传播法不断 调整网络的权值和阈值。用于电极位置优化的深度神经 网络模型如图4所示,它是由一个输入层、多个隐含层和 一个输出层构成的网络。文献[18]中已经证明 DNN 网 络结构能够适用于输入神经元少而输出神经元多的映射 情况。



(9)

图 4 适用于电极位置优化的 DNN 网络 Fig. 4 DNN network for position optimization of electrodes

DNN 网络模型的输入为式(11)中定义的优化参数 向量 $\theta$ ;网络模型的输出为16个电极间夹角 $E = [e1, e2, e3, \dots, e16]^{T}$ ;网络含有多个隐含层;网络的训练数据主 要由呼气末状态和吸气末状态下,在电极所在层随机分 配 16 个电极位置,通过仿真计算得到的数据组成。

电极优化模型训练完成后,通过向网络中输入参数 向量的最佳理论值,以获得最优电极位置。由式(4)可 知通过成像算法得到的电导率分布值与真实的电导率分 布值相同时,重建图像相对误差最小,所以β的理论最优 值,即最小值为0。图像相关系数的取值范围为[0,1], 图像误差越小则图像相关性越强,因此γ的理论最优值 为1。式(8)中的敏感场分布越均匀,则均匀性参数越 小,因此均匀性的最优值为最小值0。Hessian 矩阵的条 件数越大,式(2)中边界测量电压变化值 $\delta U$ 的微小变化 就能引起解电导率σ较大的变化,数值稳定性会越差, EIT 逆问题的病态性会越严重,所以条件数 κ 的理论最 优值,为最小值1。当DNN 网络模型训练好后,在测试集 中输入 *θ* 的理论最优值 [0,1,0,1]<sup>T</sup> 获得的网络输出数 据即为优化后 16 个电极的角度位置。

#### 3.2 数据预处理

为了提高网络模型的收敛速度及精度,对输入目标 向量 *θ* 中的参数进行归一化处理,归一化的范围限定为 0~1,归一化的公式表示为:

$$\kappa = \frac{\boldsymbol{\theta}(i) - \boldsymbol{\theta}(i)_{\min}}{\boldsymbol{\theta}(i)_{\max} - \boldsymbol{\theta}(i)_{\min}}$$
(12)

式中: $1 \le i \le 3$ , $\theta(1)$ , $\theta(2)$ , $\theta(3)$ 分别表示重建图像相 对误差 $\beta$ 、图像相关系数 $\gamma$ 、敏感场分布的均匀性 $\varphi$ 的 原始数据; x表示经归一化处理后的值, $\theta(i)_{max}$ 和  $\theta(i)_{max}$ 分别表示未归一化数据的最大值和最小值。

#### 3.3 网络的训练

在图 2 所示的呼气末和吸气末两种状态下,建立肺 部 EIT 仿真实验模型,获得训练样本,采用 9:1 随机采 样的方式将数据集分为训练样本和验证样本。样本数据 划分情况如表 1 所示。

表1 样本数据的划分

Table 1 Division of sample data

状态	训练样本个数	验证样本个数
呼气末	900	100
吸气末	900	100

因为线性模型的表达力不够,一般需要使用激活函数加入非线性因素。通过函数把激活的神经元特征保留并映射出来,这是神经网络中解决非线性问题的关键<sup>[19]</sup>。线性整流函数(rectified linear unit, ReLU)可以有效地缓解梯度消失或梯度爆炸的问题,并且收敛速度比其他激活函数更快。此外,ReLU函数还能提供神经网络的稀疏表达能力,能够提升网络的性能。因此,ReLU被用作本网络的激活函数。

本文采用均方误差(mean-squared error, MSE)评估 网络的性能并规定当 MSE 低于  $10^{-5}$  时停止训练。其公 式如下・

$$MSE = \frac{1}{N} \sum_{j=1}^{N} (\hat{E}_j - E_j)^2$$
(13)

式中:  $\hat{E}_{j}$  为电极角度的预测值,  $E_{j}$  为电极角度的真实值, N 为样本个数。当预测值与真实值完全吻合时, MSE 等于 0, 即完美模型。MSE 越小, 则网络模型的性能越好。

# 4 深度神经网络模型的优化

可以影响深度神经网络模型性能的参数有很多,包 括网络的层数、隐含层的节点个数、训练及微调阶段的正 则化参数、学习率、训练次数、迭代次数、批量大小等。本章主要通过调节网络层数和超参数设置试验来优化网络模型。

#### 4.1 网络层数分析

本节设计了隐含层为2层、3层和4层的网络模型, 以呼气末数据为例,讨论在参数相同的情况下迭代次数 在前2000次下的网络隐含层层数对网络模型性能的影 响,如图5所示。



图 5 隐含层网络层数分析

Fig. 5 Analysis of the number of hidden layer network

由图 5 可以看出,在其他参数相同的情况下,隐含层 为两层的网络收敛效果最好。随着隐含层数的增加,计 算量将呈指数增加,使得网络训练时间过长甚至可能导 致训练过拟合,考虑到训练网络的时长、收敛效果以及均 方误差的效果等因素,本文选择含有两层隐含层的网络。

#### 4.2 隐含层节点个数

本文使用了在[17]中描述的固定更新的方法来计 算隐含层节点的个数。第1隐含层节点个数的计算公 式为:

$$L_{1} = \sqrt{(m+2)N} + 2\sqrt{N/(m+2)}$$
(14)  
第 2 隐含层节点个数的计算公式为:

$$L_2 = m \sqrt{N/(m+2)} \tag{15}$$

式中: N 为样本个数, m 为输出神经元个数,本文中  $m = 16_{\circ}$ 

通过该方法计算得出的网络体系结构能够具有较小的权重和偏置,可以避免由于样本数量小而发生过度拟合的错误。由式(14)、(15)可以得到隐含层节点的个数,网络参数设置如表2所示。

表 2 网络参数设置 Table 2 Network parameter setting

140	ie 2 Receiver a parameter second	
	深度神经网络节点个数	
输入层	4	
隐含层1	211	
隐含层 2	168	
输出层	16	

#### 4.3 超参数设置

超参数是可以对训练得到的参数有影响的参数,它 需要人工输入,并作出调整,以便优化训练模型的效果。 为了获得超参数的最佳值,本节以呼气末状态为例进行 超参数设置试验,迭代次数取前 300 次,权重初始化采用 随机初始化方式,对正则化超参数和学习率的大小进行 分析选择。

1) 正则化参数

为了防止过拟合,进而增强网络的泛化能力,本文使用 L<sup>2</sup> 正则化,加入 L<sup>2</sup> 正则化的目标函数为:

$$\widetilde{\boldsymbol{Q}}(\boldsymbol{w},\boldsymbol{b};\boldsymbol{\theta},\boldsymbol{E}) = \boldsymbol{Q}(\boldsymbol{w},\boldsymbol{b};\boldsymbol{\theta},\boldsymbol{E}) + \frac{\alpha}{2} \|\boldsymbol{w}\|_{2}^{2} \quad (16)$$

其中, Q 为正则化前的目标函数, Q 为正则化后的 目标函数,  $\alpha$  为超参数。

如果 α 太大, 网络会受到过度拟合的影响; 如果 α 太 小, 网络泛化性较差。为了选择合适的 α, 本文将 α 分别 设置为:0.0001、0.001、0.01 三种情况, 记录训练过程的 均方误差(MSE), 结果如图 6 所示。



Fig. 6 Analysis of the regularization parameter

由图 6 可以看出:迭代次数在 1~50 范围内,超参数 为 0.000 1 的均方误差曲线下降速度最快,但是随着迭代 次数的不断增加,3 条曲线都渐渐趋于平缓,而超参数为 0.01 的均方误差值最小。因此本文选择均方误差曲线 最先趋于稳定且数值最小的超参数作为最佳超参数,即 超参数为 0.01。

2) 学习率

学习率是梯度下降算法迭代的步长,决定学习的速 率,为了确定最优学习率的大致范围,选择了学习率为 0.1、0.01、0.001 三种情况进行训练,观察它们的收敛速 度,试验结果如图 7 所示。

由图 7 可以看出,迭代次数在 1~100 范围内,学习 率为 0.1 的均方误差曲线下降快,网络收敛速度快,但是



Fig. 7 Analysis of the learning rate

曲线趋于稳定是在迭代次数为250左右。而迭代次数在 100~200范围内,学习率为0.001的均方误差曲线最先 趋于稳定且数值最小。随着迭代次数的增加,不同学习 率条件下均方误差相差不明显,但是网络训练的时间会 越长,因此尽可能选择均方误差曲线最先趋于稳定且数 值最小的学习率作为最佳学习率,即学习率为0.001。

# 5 训练结果与分析

对基于深度学习的肺部 EIT 电极阵列优化方法得到 的电极阵列结果以及重建图像结果进行展示,并与传统 电极阵列方法在成像结果和成像质量方面进行对比 分析。

#### 5.1 电极阵列优化结果

基于本文所提出的电极阵列优化方法,优化后的电 极表面中心所在平面的剖面图如图 8 所示,优化后电极 间夹角以及位置坐标如表 3 所示。

由图 8 和表 3 可以看出,位置优化后电极阵列的电 极角度并不是均匀分布,并且电极位置坐标并非呈现对 称分布;电极分布的疏密程度与胸腔边界的曲率变化有 关,曲率大的区域电极分布较密集,曲率小的区域电极分 布较稀疏,这是由于电磁波信号在曲率变化较大的边界 条件下的传播复杂性增加<sup>[20]</sup>。

#### 5.2 图像重建结果与分析

优化电极测量数据采用 Tikhonov 正则化算法重建图 像。根据经验,正则化参数 λ 取值在 0.01~0.1 之间成 像效果最好,所以本文选取 λ = 0.1。在呼气末和吸气末 两种状态下,通过基于深度学习优化的 EIT 电极阵列,以 及传统的角度均匀分布电极阵列获得的测量数据,构建 所选电极层的肺部 EIT 图像,得到的重建图像与均匀分 布方法和文献[17]中优化方法的结果对比如表 4 所示。





	Tab	le 3 The angle and p	osition coordinates for each optimize	a electrode	
电极号	优化前电极间夹角	优化后电极间夹角	优化后电极位置坐标/cm	优化后的胸腔曲率/(cm <sup>-1</sup> )	-
1	22. 5°	29. 08°	(-0.54976,-24.44016,-85)	0.069	
2	22. 5°	37. 78°	(-10.23046,-24.32107,-85)	0.077	
3	22. 5°	19. 55°	(-14.72528,-19.96897,-85)	0.075	
4	22. 5°	24. 13°	(-18.064 33, -12.989 73, -85)	0.073	
5	22. 5°	26. 12°	(-15.937 52,-11.183 92,-85)	0.094	
6	22. 5°	10. 19°	(-13.4773,-17.3938,-85)	0.092	
7	22. 5°	24. 91°	(-8.1162,-21.7256,-85)	0.083	
8	22. 5°	31.68°	(-2.592 48,22.623 79,-85)	0.076	
9	22. 5°	17. 2°	(0.078 12, -22.422 79, -85)	0. 089	
10	22. 5°	31.6°	(4.9554,-22.29216,-85)	0. 081	
11	22. 5°	15°	(8.6256,-5.19479,-85)	0.083	
12	22. 5°	14. 27°	(12.07933,-12.55462,-85)	0.088	
13	22. 5°	24. 12°	(10.775 86, -9.588 89, -85)	0. 085	
14	22. 5°	11. 18°	(10.77496,-13.57239,-85)	0. 091	
15	22. 5°	30. 29°	(11.56445,-20.44799,-85)	0.093	
16	22. 5°	12. 9°	(8, 945 24, -22, 696 21, -85)	0, 096	

表 3 优化后各个电极角度和位置坐标

#### 表 4 不同电极阵列优化方法结果对比

#### Table 4 Comparison of results of different electrode array optimization methods



从成像结果可以看出,电极阵列优化后的重建图像 肺部轮廓更收敛与真值图像更加接近。本文除了引用式 (5) 定义的 ICC 作为评价标准外, 还引入 SSIM 和 PSNR 作为衡量电极优化的评价标准,对优化前后的电极阵列 进行定量评价,如式(17)、(18)所示。

$$SSIM(x,y) = \frac{(2u_x u_y + c_1)(2\sigma_{xy} + c_2)}{(u_x^2 + u_y^2 + c_1)(\sigma_x^2 + \sigma_y^2 + c_2)} \quad (17)$$

式中: $u_x, u_x$ 分别表示重建图像和真值图像的均值, $\sigma_x$ ,  $\sigma_x$ 分别表示重建图像和真值图像的标准差,  $\sigma_x^2$ ,  $\sigma_y^2$ 分别 表示重建图像和真值图像的方差。 $\sigma_{xx}$ 代表重建图像和真 值图像的协方差。c1,c2为常数,通常取值非常小,可以避 免分母为0。SSIM 的值越大,表明两张图像的结构相似 度越高,重建图像结果越好。

$$PSNR(dB) = 20lg(\frac{max(X)}{\sqrt{MSE}})$$
(18)

式中:X为被测区域真值图像点颜色的最大数值。PSNR

值越大,表明重建图像与真值图像之间的失真越小,图像 质量越好。

在呼气末和吸气末两种状态下,对表4中的重建图 像质量进行定量评价,结果如表5所示。

# 表 5 电极阵列优化前后重建图像优化指标对比 Table 5 Comparison of reconstructed images

#### before and after optimization of electrode array

八次         戶町小小曲         方法         优化方法         化方法           ICC         0.624 6         0.742 5         0.831 8           呼气末         SSIM         0.742 0         0.798 8         0.849 6           PSNR         8.269 3         8.734 3         10.444 5           ICC         0.606 3         0.702 9         0.811 6	状态	评价标准	均匀分布	文献[17]的	本文优
ICC         0. 624 6         0. 742 5         0. 831 8           呼气末         SSIM         0. 742 0         0. 798 8         0. 849 6           PSNR         8. 269 3         8. 734 3         10. 444 5           ICC         0. 606 3         0. 702 9         0. 811 6			方法	优化方法	化方法
呼气末         SSIM         0.742 0         0.798 8         0.849 6           PSNR         8.269 3         8.734 3         10.444 5           ICC         0.606 3         0.702 9         0.811 6	呼气末	ICC	0.624 6	0.742 5	0.831 8
PSNR         8. 269 3         8. 734 3         10. 444 5           ICC         0. 606 3         0. 702 9         0. 811 6		SSIM	0.742 0	0.798 8	0.8496
ICC 0. 606 3 0. 702 9 0. 811 6		PSNR	8.2693	8.734 3	10.444 5
	吸气末	ICC	0.606 3	0.702 9	0.811 6
吸气末 SSIM 0.735 1 0.796 4 0.840 9		SSIM	0.735 1	0.7964	0.8409
PSNR 8. 394 2 8. 505 4 10. 767 3		PSNR	8.3942	8.5054	10.767 3

由表5的数据可以得出,在呼气末和吸气末两种状

态下,与文献[17]电极阵列优化方法相比,基于深度学习的肺部 EIT 电极阵列优化方法将 ICC 分别提高了 18.88%、15.93%,SSIM 分别提高了 7.65%、8.34%,图像的 PSNR 分别提高了 5.62%、1.33%。与传统的电极阵 列均匀分布方法相比,基于深度学习的肺部 EIT 电极阵 列优化方法将 ICC 分别提高了 33.17%、33.86%,SSIM 分别提高了 14.50%、14.39%,图像的 PSNR 分别提高了 26.31%、28.27%。因此,基于本文所提出的电极阵列优 化方法比传统方法更适用于肺部等不规则边界情况下的 电阻抗成像。

# 6 结 论

为了寻找更适用于肺部不规则边界情况下的最优电 极位置,本文提出以不同电极位置条件下的重建图像相 对误差、图像相关系数、敏感场分布的均匀性以及敏感场 Hessian 矩阵的条件数作为网络输入,以电极阵列角度为 输出,基于 DNN 网络建立输入与输出之间的非线性映射 关系,最终预测得到最优电极位置。通过与传统电极阵 列方法的图像相关系数、图像结构相似度、峰值信噪比的 对比分析,证明了基于本文所提出的电极阵列优化方法 的有效性。本文仅针对肺部单层电极进行初步研究,考 虑实际应用需求,在今后的工作中还需要:1)进一步建立 多层电极优化模型,以满足三维 EIT 图像重建的需要;2) 考虑呼吸过程对胸腔形状的影响,并作为先验信息加入 到网络训练中,以提高电极优化质量;3)考虑人体胸部轮 廓差异,增加不同尺寸胸部样本的差异,并在此基础上设 置电极,增加样本数据量,优化网络模型参数。

#### 参考文献

[1] 董秀珍 生物电阻抗成像研究的现状与挑战[J]. 中国 生物医学工程学报,2008,27(5):641-649.

DONG X ZH. Current situation and challenge of bioelectrical impedance imaging research [J] Chinese Journal of Biomedical Engineering, 2008, 27 (5): 641-649.

 [2] 王琦,彭圆圆,汪剑鸣,等.动态电阻抗成像时空相关 性重建方法研究[J].电子测量与仪器学报,2018, 32(2):153-160.

> WANG Q, PENG Y Y, WANG J M, et al. Research on temporal and spatial correlation reconstruction method of dynamic electrical impedance imaging [J]. Journal of Electronic Measurement and Instrumentation, 2018, 32(2): 153-160.

[3] 邹文,赵翠莲. 柔性压力传感器在呼吸气流检测中的 性能比较[J]. 电子测量技术,2020,43(17):153-158. ZOU W, ZHAO C L. Comparison of performance of flexible pressure sensor in breathing airflow detection [ J ]. Electronic Measurement Technology, 2020, 43 (17): 153-158.

【4】 成民民,戎舟,庞宗强. 基于分裂 Bregman 方法的加权 频差电阻抗成像算法[J]. 国外电子测量技术,2019, 38(2):30-35.

CHENG M M, RONG ZH, PANG Z Q. Weighted frequency difference electrical impedance imaging algorithm based on split Bregman method [J]. Foreign Electronic Measurement Technology, 2019, 38 (2): 30-35.

- [5] SHONO A, KOTANI T. Clinical implication of monitoring regional ventilation using electrical impedance tomography [J]. Journal of Intensive Care Medicine, 2018, 7(1):1-10.
- [6] 林桢哲,王桂棠,陈建强,等. 基于残差网络深度学习的肺部 CT 图像结节良恶性分类模型[J]. 仪器仪表学报,2020,41(3):248-256.
  LIN ZH ZH, WANG G T, CHEN J Q, et al. Classification model of benign and malignant pulmonary CT nodules based on residual network deep learning[J]. Chinese Journal of Scientific Instrument, 2020, 41(3): 248-256.
- [7] 张超,吴佳铭,代萌,等. 基于 EIT 技术监测体姿改变 对肺通气影响的实验研究[J]. 医疗卫生装备,2018, 39(4):14-18.
  ZHANG CH, WU J M, DAI M, et al. Experimental study on monitoring the effect of body posture change on lung ventilation based on EIT technology[J]. Medical and Health Equipment, 2018, 39(4):14-18.
- [8] 王冰,蒋磊,宋福明,等. 30 kA 闭环式集成霍尔电流 传感器设计[J]. 电子测量与仪器学报, 2020, 34(11):188-193.
  WANG B, JIANG L, SONG F M, et al. Design of 30 kA closed loop integrated Hall current sensor[J]. Journal of Electronic Measurement and Instrumentation, 2020, 34(11):188-193.
- [9] 王妍,沙洪,任超世. EIT 电极结构优化方法的仿真研究[C]. 天津市生物医学工程学会,2005.
  WANG Y, SHA H, REN CH SH, Simulation study of EIT electrode structure optimization method[C]. Tianjin Biomedical Engineering Society, 2005.
- [10] 问雪宁. 基于 ANSYS 的 ECT/ERT 电磁场仿真及阵列 电极优化设计[D]. 天津:天津大学,2007.
   WEN X N. ECT/ERT electromagnetic field simulation and array electrode optimization design based on ANSYS[D]. Tianjin: Tianjin University, 2007.
- [11] 窦春清. 超声调制 EIT 传感器优化与系统设计[D].

天津:天津大学,2016.

DOU CH Q. Optimization and system design of ultrasonic modulated EIT Sensor [ D ]. Tianjin: Tianjin University, 2016.

- [12] HAO Z, YUE S, SUN B, et al. Optimal distance of multi-plane sensor in three-dimensional electrical impedance tomography [J]. Computer Assisted Surgery, 2017, 22(S1): 326-338.
- [13] 陈晓艳,李宏英,赵秋红,等. 3D-EIT 系统电极优化设 计[J]. 中国生物医学工程学报,2014,33(2): 155-160.

CHEN X Y, LI H Y, ZHAO Q H, et al. Optimized electrode design of 3D-EIT system [J]. Chinese Journal of Biomedical Engineering, 2014, 33(2):155-160.

[14] 汪婧. ECT/ERT 双模态阵列电极优化设计及其正问题 研究[D]. 天津:天津大学,2008.

WANG J. Optimization design of ECT/ERT dual-mode array electrode and its forward problems [D]. Tianjin: Tianjin University, 2008.

[15] 程小龙.基于 COMSOL 的 ECT 传感器设计与优化研究[D]. 上海:上海海洋大学,2018.

CHENG X L. Research on design and optimization of ECT sensor based on COMSOL[D]. Shanghai: Shanghai Ocean University, 2018.

- [16] NUUTTI H, AKU S, STRATOS S. Optimizing electrode positions in electrical impedance tomography [ C ]. Society for Industrial and Applied Mathematics, 2014, 74(6):1831-1851.
- [17] SMYL D, LIU D. Optimizing electrode positions in 2-D electrical impedance tomography using deep learning[J].
   IEEE Transactions on Instrumentation and Measurement, 2020, 69(9): 6030-6044.
- [18] 高实. 基于 DNN 网络结构的学院转专业生源研究[J]. 吉林大学学报(信息科学版),2021,39(4):479-484.
  GAO SH. Research on the source of college students transferring majors based on DNN network structure[J].
  Journal of Jilin University (Information Science Edition), 2021, 39(4):479-484.
- [19] 周硕 基于深度学习的传感器优化布置方法[D].西 安:西北工业大学,2020.

ZHOU SH. Optimal placement of sensors based on deep learning [ D ]. Xi'an: Northwestern Polytechnical University, 2020. [20] 唐东林,舒静,赵江,等. 球体曲率变化对涡流传感器 灵敏度影响[J]. 机械研究与应用,2016,29(1): 129-131.

TANG D L, SHU J, ZHAO J, et al. Influence of sphere curvature change on eddy current sensor sensitivity [J]. Mechanical Research and Application, 2016, 29(1): 129-131.

#### 作者简介



**王琦**,2007 年于天津大学获得学士学 位,2009 年于天津大学获得硕士学位,2012 年于天津大学获得博士学位,现为天津工业 大学教授,主要研究方向为智能信息处理、 电学成像技术。

E-mail: wangqitjpu@163.com

**Wang Qi** received her B. Sc. degree form Tianjin University in 2007, M. Sc. degree form Tianjin University in 2009, received her Ph. D. degree form Tianjin University in 2012, respectively. Now she is a professor in Tiangong University. Her main research interests include intelligent information processing and electrical imaging technology.



**尹鑫铭**,2018 年于山东师范大学历山 学院获得学士学位,现为天津工业大学硕士 研究生,主要研究方向为肺部电阻抗成像 技术。

E-mail: 1448400648@ qq. com

Yin Xinming received her B. Sc. degree

from Jieshan College of Shandong Normal University in 2018. Now she is a M. Sc. candidate of Tiangong University. Her main research interest includes electrical impedance imaging of lungs.



**李晓捷**(通信作者),2003 年于天津工 业大学获得学士学位,2006 年于天津工业 大学获得硕士学位,2016 年于天津工业大 学获得博士学位,现为天津工业大学高级实 验师,主要研究方向为电学成像三维动态阻 抗图像重建。

E-mail: lixiaojie@ tiangong. edu. cn

Li Xiaojie (Corresponding author) received her B. Sc. degree from Tiangong University in 2003, received her M. Sc. degree from Tiangong University in 2006, received her Ph. D. degree from Tiangong University in 2016, respectively. Now she is a senior experimentalist in Tiangong University. Her main research interest includes 3D dynamic impedance image reconstruction in electrical imaging.