

基于 S-PNet 的触觉电阻抗成像后处理算法研究

袁晶晶 戎舟

(南京邮电大学自动化学院、人工智能学院 南京 210023)

摘要:电阻抗成像技术(EIT)因其非侵入式的特性为机器人柔性触觉传感器的压力点分布可视化提供了一种可行的方法。然而 EIT 逆问题具有高度的非线性和病态性,当多压力点相近时,重建图像的伪影会导致压力点间存在粘连。为解决上述问题,提出一种由特征提取、特征重建以及加强特征提取 3 个模块构成的 S-PNet 电阻抗成像后处理算法,实现对粘连压力点的分割以及形状重建。该算法使用金字塔池化结构加强特征提取,在增加极小计算量的情况下,能够提取到区分相近压力点边界的多尺度特征。采用均方根误差(RMSE)和结构相似度(SSIM)来评价后处理图像质量,实验得出 RMSE 的平均值为 0.02,SSIM 的平均值为 0.97。仿真与实测结果均表明,与现有算法相比,基于 S-PNet 的后处理算法能够得到边界清晰且形状准确的结果。

关键词:电阻抗成像;逆问题;图像后处理;深度学习

中图分类号: R318; TN911.73 **文献标识码:** A **国家标准学科分类代码:** 310.61

Research on post-processing algorithm of tactile electrical impedance tomography based on S-PNet

Yuan Jingjing Rong Zhou

(College of Automation & College of Artificial Intelligence, NanJing University of Posts and Telecommunications, Nanjing 210023, China)

Abstract: Electrical impedance tomography (EIT) provides a feasible method for visualizing the distribution of pressure points in flexible tactile sensors of robots due to its non-invasive characteristics. However, the inverse problem of EIT is highly nonlinear and ill-posed. When multiple pressure points are close to each other, the artifacts of the reconstructed image will lead to adhesion between pressure points. To solve the above problems, a post-processing algorithm named S-PNet for EIT is proposed, which is composed of three modules: Feature extraction, feature reconstruction and enhanced feature extraction, to achieve the segmentation and shape reconstruction of adhesive pressure points. The algorithm uses a pyramid pooling structure to enhance feature extraction and can extract multi-scale features to distinguish the boundaries of close pressure points with minimal additional calculation. The post-processing image quality is evaluated by root mean square error (RMSE) and structural similarity (SSIM). The average value of RMSE is 0.02 and the average value of SSIM is 0.97. Both simulation and measured results show that compared with the existing algorithms, the post-processing algorithm based on S-PNet can obtain images with clear boundaries and accurate shapes.

Keywords: electrical impedance tomography; inverse problem; image post-processing; deep learning

0 引言

电阻抗成像^[1] (electrical impedance tomography, EIT)是一种无损伤的功能性成像技术^[2],即根据目标物体的边界测量电压,通过算法处理将物体内部的电导率分布以图像形式呈现。由于 EIT 具有非侵入式、无损检测、成

本低廉等特点^[3],因此该技术在许多领域获得了广泛应用^[4-5]。近十五年来,有不少学者将 EIT 技术应用于机器人柔性触觉传感器的实验研究^[6-9]。基于 EIT 技术的机器人柔性触觉传感器内部结构简单且制造成本低廉,具有工业生产的可行性。但是,EIT 逆问题的非线性和不适定性极大降低了重建图像的精度,一定程度上限制了 EIT 柔性

触觉传感器的发展^[10]。

电阻抗成像算法可分为直接求解算法、近似迭代算法和智能求解算法^[11]。直接求解算法是指在成像区域内电导率的扰动比较微小时,对非线性问题进行线性化处理,例如滤波反投影法(filtered back-projection method, FBP)^[12]、截断奇异值分解法(truncated singular value decomposition method, TSVD)^[13]等,此类算法的成像精度往往较低。而解决 EIT 成像问题较为经典的迭代算法有粒子群优化算法(particle swarm optimization, PSO)^[14]、遗传算法(genetic algorithm, GA)^[15]等。迭代算法通过不断的迭代修正,虽然可以得到精度较高的重建图像,但是其对于测量噪声和建模误差都极其敏感,这会导致重建图像存在较多伪影。随着深度学习的发展,越来越多的学者将神经网络算法引入到 EIT 的图像重建上,称之为 EIT 的智能求解算法。智能求解法避免了 EIT 正问题敏感度矩阵的计算和逆问题的线性化假设,并且其自适应能力较强,可以有效地提高图像重建算法的准确性和鲁棒性。代月霞^[16]提出了基于深度学习模型的 EIT 图像重建算法,该方法有效地解决了浅层神经网络中存在的易过拟合、对复杂函数表示能力有限等问题。付荣等^[17]使用基于 V-ResNet 的电阻抗成像算法实现对人体肺部空间的可视化监测。

但是经过 EIT 智能求解法重建后的图像仍存在一些细节问题,例如目标物体的形状描述不准确、目标物体之间存在伪影导致粘连等情况。故不少学者提出了电阻抗成像后处理算法,以减少 EIT 重建算法的重建误差,消除重建图像的伪影,提高图像质量。Duan 等^[18]使用 U-net 网络模型对压力点分布成像进行后处理,成像效果得到了一定改善,但是仅进行了双压力点实验,未考虑三压力点相近的情况。Haddad 等^[19]同样也使用经典的 U-net 语义分割模型,其利用 U-net 网络对重构的 EIT 胸腔图像进行后处理,该模型在测试数据集上的准确率为 74.23% 左右,后处理效果一般。王鹏^[20]提出一种基于 MobileNetV2 + 网络的 PSPNet 语义分割模型以消除成像伪影,并进行水槽成像实验以验证该算法的有效性。叶建安等^[21]提出一种多分支一维卷积神经网络模型(multi-branch one-dimensional convolutional neural networks, MB-1DCNN)对 EIT 重建图像进行了后处理,该网络采用多分支结构,并利用残差卷积模块对数据进行特征提取,减少了传统算法重构图像中存在的部分伪影。2022 年,丁亚等^[22]提出一种 O-Net 卷积神经网络对人体胸腔重建图像进行后处理。该网络模型在输入和输出层增加了跳层连接,与 U-net 相比,其后处理结果的精确度有所提升,但是 O-Net 模型仅对仿真数据进行了验证,缺少实测数据的支撑。

然而,现有的这些后处理算法^[23-24]无法解决后处理结果仍存在一定的伪影的问题,为此本文提出了一种基于 S-PNet(segmentation-pyramid network)网络模型的触觉

电阻抗成像后处理算法。该算法以二维卷积神经网络(two dimensional convolutional neural network, 2DCNN)^[25]重建的含有伪影和误差的初始图像作为输入,通过一种具有“编码-解码”结构的深度卷积神经网络对输入图像进行特征提取与重建,并使用金字塔池化结构加强特征提取,以减少 EIT 重建结果的伪影,优化重建效果。

1 EIT 数理模型

本文的机器人柔性触觉传感器使用二维 EIT 模型,成像区域是一个半径为单位 1 的圆,模型四周等间距放置 16 个电极。采用相邻激励-相邻测量的模式,即选取其中的一组相邻电极对作为激励,然后依次测量剩余相邻电极对之间的电压,按逆时针顺序依次选取相邻电极对作为激励,并完成电压测量。重复上述步骤,直至遍历所有相邻电极对,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

EIT 的正问题是已知电导率分布和相关边界条件求解场域的电位分布。图 1 场域内部的电位分布函数 ϕ 与电导率分布函数 σ 满足拉普拉斯方程:

$$\nabla \cdot [\sigma(x, y) \nabla \phi(x, y)] = 0, (x, y) \in \partial\Omega \quad (1)$$

同时还满足基本边界条件和自然边界条件:

$$\phi(x, y) = f(x, y), (x, y) \in \partial\Omega \quad (2)$$

$$\sigma(x, y) \frac{\partial \phi(x, y)}{\partial n} = j(x, y), (x, y) \in \partial\Omega \quad (3)$$

式中: $\partial\Omega$ 表示场域 Ω 的边界; f 表示已知边界电位; j 表示流入场域 Ω 的电流密度; n 表示场域 Ω 的外法向单位向量。

EIT 的逆问题是指在已知注入激励和部分场域条件的情况下求解场域内电导率 σ 的分布。对于一个固定的输入电流模式和确定形状的场域,边界电压的测量值 V 可以描述成电导率的函数:

$$V = f(\sigma) \quad (4)$$

2 基于 S-PNet 的后处理算法

图像的上下文信息对于分割任务至关重要。在某

一尺度下,可以利用较大范围的上下文信息来推断目标物体的基本位置。而在另一尺度下,可能能够更好地捕捉到相近目标物体之间的边界信息。因此,多尺度特征能够综合不同尺度下的上下文信息,提供更加全面的特征表达。

U-net 网络^[26]在医学图像分割上表现出不错的性能,但是若将其直接运用于分割存在粘连的多压力点,效果欠佳。这是由于相近的压力点在特征上往往高度相似,而 U-net 网络无法提取到——能够区分相近压力点边界的多尺度特征。因此,本文改进了原始的 U-net 网络,在此基础上增加了能够提取多尺度特征的加强特征提取模块,提出一种具有金字塔池化(pyramid pooling)结构的语义分割(semantic segmentation)网络模型,故称之为 S-PNet。

2.1 S-PNet 网络结构

S-PNet 网络是一种由特征提取(feature extraction, FE)模块、特征重建(feature reconstruction, FR)模块和加强特征提取(enhanced feature extraction, EFE)模块构成的深度卷积神经网络,其网络结构如图 2 所示。为了避免 EIT 逆问题的线性化假设给图像重建带来的影响,本文使用 2DCNN 网络重建阻抗分布,并将阻抗分布转为 EIT 初始重建图像。将初始重建图像作为 S-PNet 网络的输入,大小为 $448 \times 448 \times 3$ 。特征提取模块将 $448 \times 448 \times 3$ 的输

入图像压缩成 $28 \times 28 \times 512$ 的高维度特征图。特征重建模块将提取到的高维度特征信息恢复至与输入图像分辨率相同。为融合底层特征的位置信息与深层特征的语义信息,利用加强特征提取模块,将特征重建的结果与经过金字塔池化加强提取的特征拼接起来。

L1~L16 为 S-PNet 的特征提取模块(FE, $i=1,2,3,4,5$),每个 FE 子模块主要包含 3×3 卷积(conv 3×3)、批量归一化(Batch Normalization, BN)、RELU 激活函数和最大池化(maxpool 2×2)操作。特征提取模块将输入图像压缩为 28×28 的抽象特征,对应的通道数从 3 逐渐增加到 512。不同 FE 子模块之间使用最大池化操作对经过卷积后的特征进行下采样。

L17~L28 为 S-PNet 的特征重建模块(FR, $i=1,2,3,4$),每个 FR 子模块主要包括转置卷积(upconv 2×2)、 3×3 卷积(conv 3×3)、批量归一化(batch normalization, BN)和 RELU 激活函数操作。特征重建模块将抽象特征逐步恢复成与输入图像大小相同的特征图。不同 FR 子模块之间使用转置卷积操作对经过卷积后的结果进行上采样。

特征提取模块中的输出(L4、L7、L10 和 L13)与特征重建模块的输入(L26、L23、L20 和 L17)之间使用跳连接(concat)起来,实现对特征提取信息与特征重建信息的融合,同时缩短网络的训练时间。




图 2 S-PNet 网络结构

Fig. 2 S-PNet network structure

L29~L38 为 S-PNet 的加强特征提取模块。首先,使用平均池化(average pool)操作将特征重建后的结果划分成 4 个不同的区域,聚合不同区域的上下文信息,从而提高 S-PNet 网络获取全局信息的能力。然后,利用转

置卷积将经过平均池化后的特征恢复至与输入图像相同大小,目的是使其能够和特征重建的结果再次进行特征融合,增强特征提取,提取到相近压力点之间的边界信息。最后,利用 1×1 卷积(Conv 1×1)完成网络输出。

2.2 模型训练

本文提出的 S-PNet 网络模型的开发环境如下:使用 Python 语言和 PyTorch 深度学习框架,对应版本分别为 Python3.7.16 和 PyTorch1.10.0。实验运行的计算机为 CentOS 操作系统, GPU 为 NVIDIA Tesla V100-PCIE 32GB。通过不断训练与参数优化,对 S-PNet 网络超参数设置如表 1 所示。

表 1 超参数设置

Table 1 Hyperparameter setting

参数名	值
epochs	100
batch_size	8
learning_rate	0.001
optimizer	RMSprop
criterion	BCE

3 实验数据及结果

3.1 仿真数据集的建立

因为样本个数和种类的多少在一定程度上会影响神经网络的泛化性能和抗噪声性能,所以网络的训练需要大量数据样本。而实际的电阻抗成像测量系统很难测得大规模的数据。为此,基于 EIT 的工作原理,本文使用 EIDORS 软件联合 MATLAB 建立了 EIT 机器人柔性触觉传感器仿真模型数据集。

基于 EIT 机器人柔性触觉传感器建立的仿真模型,充分考虑了触觉传感器的物理参数以及压力点相近时的各种情况。

1)本文主要仿真双压力点和三压力点相近的情况,仿真模型如图 3 所示,其中图 3(a)为双压力点相近的仿真示意图,图 3(b)为三压力点相近的示意图。同时为了准确地表达压力点的边界信息,将场域剖分成 1 024 个三角单元。

2)根据柔性传感器表面电阻率的实际可变范围,本研究将背景电导率设定为 0.05 S/m,每个压力点的电导率随机设定在 0.05~0.125 S/m。

3)由于 EIT 机器人柔性触觉传感器的实物是一个半径为 10 cm 的圆形物体,施加压力的手指指腹可近似为一个半径在 0.5~0.8 cm 的圆。将上述尺寸进行等比例缩小,则可以使用半径为单位 1 的模型仿真 EIT 触觉传感器,使用径为 0.05~0.08 的目标物体仿真手指按压时的压力点分布。

以上仿真数据均使用 2DCNN 网络进行初始图像重建,并将其作为 S-PNet 网络的输入图像。2DCNN 网络结构主要包括卷积层和长短期记忆网络层,其中,长短期记忆层可解决长序列训练过程中的梯度消失和梯度爆炸问题。




图 3 仿真模型示意图

Fig. 3 The diagram of the simulation model

为了提升 S-PNet 网络模型的泛化性能,数据集中包含 30 465 组压力点分布仿真模型,其中,25 000 组模型用于网络训练,3 465 组模型用于超参数调整,剩余的 2 000 组用于测试网络的泛化性能。

3.2 评价指标

为客观评价 EIT 后处理图像的质量,选择均方根误差(root mean square error, RMSE)和结构相似度(structural similarity, SSIM)作为图像质量评价(image quality assessment, IQA)的指标。

给定一个大小为 $M \times N$ 的仿真图像 F 和经算法后处理的图像 P ,其均方根误差的定义式为:

$$RMSE = \sqrt{\frac{1}{MN} \sum_{i=1}^M \sum_{j=1}^N [F(i, j) - P(i, j)]^2} \quad (5)$$

结构相似度可以根据图像像素间的相关性构造出仿真图像 x 与后处理图像 y 之间的结构相似度,其定义公式如下:

$$SSIM(x, y) = \frac{(2\mu_x\mu_y + c_1)(2\sigma_{xy} + c_2)}{(\mu_x^2 + \mu_y^2 + c_1)(\sigma_x^2 + \sigma_y^2 + c_2)} \quad (6)$$

式中: μ_x 、 μ_y 分别表示图像 x 和图像 y 的标准差; σ_x 、 σ_y 分别表示图像 x 和图像 y 的协方差; σ_{xy} 表示图像 x 和图像 y 之间的协方差; c_1 、 c_2 、 c_3 均为常数。SSIM 值在 $[0, 1]$, SSIM 值越大则表示两幅图之间越相似,经过后处理的图像质量越好。

3.3 仿真实验

为真实评估所提出的 S-PNet 网络模型的图像处理性能,对测试集中的 2 000 组数据进行无噪声下的评估和有噪声下的评估,以此来验证该网络模型的准确性和鲁棒性。

1)无噪声下的评估结果

在不施加噪声的情况下,首先将 2DCNN 算法重建的初始图像作为输入,然后分别使用 S-PNet 网络、U-net 网络、PSPNet 网络和 CNN 网络对初始重建图像进行后处理。如图 4 所示,无噪声时,经过 S-PNet 网络模型后处理的图像,边界清晰,形状准确。而 U-net 网络未能较好地处理三压力点粘连的情况,并且其对于压力点的形状描述不够准确。PSPNet 和 CNN 网络模型则完全无法区分压力点之间的边界,压力点粘连的情况严重。




图4 不同网络模型的后处理结果对比

Fig. 4 Comparison of post-processing results of different network models

为定量分析在无噪声情况下,各网络模型后处理图像的质量,分别计算了4种模型对于测试集后处理结果的平均 RMSE 和 SSIM 值,如图 5 所示。




图5 不同模型的平均 RMSE 和 SSIM 值

Fig. 5 Average RMSE and SSIM for different models

图 5 的图像质量评价指标表明,PSPNet 和 CNN 这 2 种网络模型后处理图像的 RMSE 值偏高且 SSIM 值偏低,说明这 2 种模型提取有效特征的能力较差,以致无法准确区分压力点和伪影。U-net 网络模型后处理图像的 RMSE 和 SSIM 值优于 PSPNet 和 CNN 网络。而本研究提出的 S-PNet 网络模型的 RMSE 明显最低,SSIM 值也远高于其他 3 种网络模型。

综合以上的定性分析与定量分析,提出的 S-PNet 网络模型在无噪声情况下能够消除初始图像存在的伪影,尤其是消除相近压力点之间的伪影,并能准确地描述各压力点的形状。

2)有噪声下的评估结果

在实际测量过程中,实测电压数据中总存在各种噪声。为评估 S-PNet 网络模型的鲁棒性,对测试集中的电压数据分别加入信噪比(signal to noise ratio,SNR)为 50、40、30、20 dB 的高斯噪声。信噪比定义式如下:

$$SNR = 10 \lg \frac{RMS(S)}{RMS(N)} \quad (7)$$

式中: $RMS(\cdot)$ 表示求解均方根; S 表示不含噪声的电压信号; N 表示噪声信号。SNR 值越大表示电压信号中含有的噪声越少。

这里,选取 SNR 为 50 和 20 dB 时,4 种网络模型的后处理效果展示,如图 6 和 7 所示。

当信噪比为 50 dB 时,S-PNet 网络模型能够消除使压




图6 SNR 为 50 dB 时各模型的后处理图像

Fig. 6 Post-processing images of each network model when SNR is 50 dB




图7 SNR 为 20 dB 时各网络模型的后处理图像

Fig. 7 Post-processing images of each network model when SNR is 20 dB

力点之间粘连在一起的伪影,同时,能够较为准确地描述各压力点的形状。而 U-net 网络的后处理能力不稳定,该网络能够较好地处理双压力点相近的情况,但是当三压力点相近时,其后处理图像存在一定的粘连且形状描述不准确。PSPNet 和 CNN 网络模型的后处理图像存在较为严重的粘连。

当信噪比为 20 dB 时,电压信号中存在大量噪声,U-net、PSPNet 和 CNN 网络模型的后处理结果均出现了不同程度的粘连与失真。而 S-PNet 网络仍然能够较为准确地消除压力点之间存在的伪影,图像失真较小。

在不同噪声水平下,各网络模型后处理图像的平均 RMSE 和 SSIM 值如图 8 所示。可以看出,S-PNet 网络模型在各个噪声水平下的 RMSE 和 SSIM 值均明显优于其他 3 种网络。




图8 IQA 指标与噪声的关系曲线

Fig. 8 The relationship curve between IQA index and noise

由图 6~8 可知,基于 S-PNet 网络的触觉电阻抗成像后处理算法具有良好的抗噪声性能。

3.4 实测实验

为评估本研究所提出的网络模型对实际测量数据的后处理效果,设计了如下实验:以 EIT 机器人柔性触觉传感器为测试平台,采用 16 电极的电阻抗成像数据采集系统测量边界电压数据,激励电流幅值为

1 mA,频率为 5 kHz。选取不施加任何压力的柔性触觉传感器为空载状态,以在触觉传感器上施加不同点数的压力作为目标物体,设置了按压相近双压力点和按压相近三压力点的两个实验。后处理结果如图 9 所示。




图 9 实测压力点分布的后处理结果

Fig. 9 Post-processing results of measured pressure point distribution

以相近的双压力点为目标物体时,S-PNet 和 U-net 网络模型能够较为准确地区分压力点之间的边界,但 U-net 网络的稳定性不佳且对于压力点的形状描述能力较差。PSPNet 和 CNN 网络后处理的结果不仅存在粘连,甚至连部分压力点之外的伪影都未消除。因此,目标物体为相近的双压力点时,S-PNet 网络的后处理效果最佳。

以相近的三压力点为目标物体时,仅有提出的 S-PNet 网络模型能够基本消除存在于压力点之间和压力点之外的伪影,并且能够比较准确地描述各压力点的形状。其余 3 种网络模型的后处理图像都存在不同程度的粘连与失真,后处理效果不理想。

3.5 时效性验证

本文所提出的 S-PNet 网络模型与其他 3 种后处理算法的运行时间对比如表 2 所示。运行时间是按照各算法完成一次 EIT 重建图像的后处理 GPU 所需时间来计算的。

表 2 各模型的平均运行时间

Table 2 The average running time of each model

后处理算法	运行时间/s
S-PNet	0.37
U-Net	2.14
PSPNet	5.87
CNN	1.19

从表 2 可以看出,S-PNet 网络模型进行后处理的运行时间在 4 种算法中是最短的,其运行时间比耗时第 2 短的 CNN 模型快了 2 倍以上,并且其图像后处理效果明显优于 CNN 模型。因此,S-PNet 网络模型具有良好的时效性。

4 结 论

针对向 EIT 机器人柔性触觉传感器施加相近压力时,初始重建图像存在粘连这一问题,提出了一种基于 S-PNet 网络模型的触觉电阻抗成像后处理算法。该深度卷积神经网络由特征提取模块、特征重建模块和加强特征提取模块组成,其中,加强特征提取模块能够有效地融合多尺度特征,基于相近压力点的边界特征进行预测,提高分割结果的精确度。

使用基于 S-PNet 的图像后处理算法,对仿真数据和实测数据进行实验。结果表明,相较于常用的 U-net、PSPNet 和 CNN 网络模型,基于 S-PNet 的触觉电阻抗成像后处理算法能够更加准确地消除使压力点之间存在粘连的伪影和压力点之外的伪影,并且其对于压力点的形状描述能力也明显优于其他 3 种网络模型。此外,该算法具有良好的抗噪声性能和时效性。但是,有关于 S-PNet 进行图像后处理的耗时能否进一步缩短,这有待研究改进。

参 考 文 献

- [1] BARBER D C, BROWN B H. Applied potential tomography [J]. *Journal of Physics E: Scientific Instruments*, 1984, 17(9): 723-733.
- [2] 马刚. 电阻抗成像技术及其在人机交互中的应用 [D]. 合肥: 中国科学技术大学, 2021.
- MA G. Electrical impedance tomography technology and its application in human-computer interaction [D]. Hefei: University of Science and Technology of China, 2021.
- [3] LIU K, WU Y. Artificial sensitive skin for robotics based on electrical impedance tomography [J]. *Advanced Intelligent Systems*, 2020, 2(4): 1-13.
- [4] ZHANG H Y, MU J L, YANG Y J, et al. A positive data extraction method for electrical impedance tomography (eit) based on the novel MSA-Net [J]. *IEEE Sensors Journal*, 2023, 23(14): 15753-15761.
- [5] YAN X H, HUANG S F, SMOLIK W T, et al. A detection method for fast electrical impedance imaging of grounding grid based on optimized differential-multigrid-homotopy algorithm [J]. *IEEE Transactions on Instrumentation and Measurement*, 2023, 72(5): 1110-1114.
- [6] KATO Y, MUKAI T, HAYAKAWA T, et al. Tactile sensor without wire and sensing element in the tactile region based on EIT method [C]. 2007 IEEE Sensors Conference, 2007: 792-795.
- [7] RUSSO S, ASSAF R, NEFTI-MEZIANI S. Towards a practical implementation of EIT-based sensors using artificial neural networks [C]. 2017 IEEE SENSORS Conference, 2017: 1024-1029.
- [8] LIU K, QIN Z J, WU Y, et al. Fabrication of a tactile sensor for artificial skin based on electrical impedance tomography [J]. *Biosensors and Bioelectronics*, 2022, 10(5): 100116-100122.
- [9] YANG Y, ZHOU W B, CHEN X Y, et al. A flexible touching sensor with the variation of electrical impedance distribution [J]. *Measurement*, 2021, 183(6): 109778-109791.
- [10] HUSAIN Z, MADJID N A, LIATSIS P. Tactile sensing using machine learning-driven electrical impedance tomography [J]. *IEEE Sensors*, 2021, 21(10): 11628-11642.
- [11] 王欢. 面向机器人柔性皮肤的电阻抗成像方法研究 [D]. 南京: 南京航空航天大学, 2021.
- WANG H. Research on image reconstruction methods for electrical impedance tomography for robot flexible skin [D]. Nanjing: Nanjing University of Aeronautics and Astronautics, 2021.
- [12] CHENEY M, ISAACSON D, NEWELL J C, et al. NOSER: An algorithm for solving the inverse conductivity problem [J]. *International Journal of Imaging Systems and Technology*, 1990, 2(2): 66-75.
- [13] TIDSWELL T, GIBSON A, BAYFORD R H, et al. Three-dimensional electrical impedance tomography of human brain activity [J]. *NeuroImage*, 2001, 13(2): 283-294.
- [14] 陈民铀, 杨艳利, 何为, 等. 基于粒子群优化算法的电阻抗图像重建 [J]. *重庆大学学报*, 2011, 34(1): 82-87.
- CHEN M Y, YANG Y L, HE W, et al. Image reconstruction of electrical impedance tomography based on particle swarm optimization algorithm [J]. *Journal of Chongqing University*, 2011, 34(1): 82-87.
- [15] 侯卫东, 莫玉龙. 基于遗传算法的电阻抗图像重建 [J]. *生物医学工程学杂志*, 2003, 20(1): 107-110.
- HOU W D, MO Y L. Image reconstruction in electrical impedance tomography based on genetic algorithm [J]. *Journal of Biomedical Engineering*, 2003, 20(1): 107-110.
- [16] 代月霞. 基于深度学习的 EIT 图像重建算法研究 [D]. 天津: 天津工业大学, 2017.
- DAI Y X. Research on EIT image reconstruction algorithm based on deep learning [D]. Tianjin: Tianjin Polytechnic University, 2017.
- [17] 付荣, 张新宇, 王子辰, 等. 基于 V-ResNet 的电阻抗层析成像方法 [J]. *仪器仪表学报*, 2021, 42(9): 279-287.
- FU R, ZHANG X Y, WANG Z CH, et al. Electrical impedance tomography method based on V-ResNet [J]. *Chinese Journal of Scientific Instrument*, 2021, 42(9): 279-287.
- [18] DUAN X, TAURAND S, SOLEIMANIL M. Artificial skin through super-sensing method and electrical impedance data from conductive fabric with aid of deep learning [J]. *Scientific Reports*, 2019, 9(6): 1-11.
- [19] HADDAD H, HAFSA M, BADER O, et al. Post-processing for thorax imaging based on electrical impedance tomography using deep learning [C]. 19th International Multi-Conference on Systems, Signals & Devices, 2022: 1092-1097.
- [20] 王鹏. 基于深度学习的 EIT 成像算法的研究 [D]. 重

- 庆:重庆邮电大学, 2021.
- WANG P. Research on EIT imaging algorithm based on deep learning [D]. Chongqing: Chongqing University of Posts and Telecommunications, 2021.
- [21] 叶健安, 田翔, 王普, 等. 基于多分支一维卷积神经网络电阻断层成像数据后处理方法研究 [J]. 空军军医大学学报, 2022, 43(7): 842-851.
- YE J AN, TIAN X, WANG P, et al. Post-processing model of EIT data based on multi-branch one-dimensional convolutional neural network [J]. Journal of Air Force Medical University, 2022, 43(7): 842-851.
- [22] 丁亚, 王伟刚, 涂真珍, 等. 一种 O-Net 卷积神经网络优化的电阻抗成像技术 [J]. 生物医学工程研究, 2022, 41(2): 129-136.
- DING Y, WANG W G, TU ZH ZH, et al. An electrical impedance tomography technique optimized by O-Net convolutional neural network [J]. Journal Biomedical Engineering Research, 2022, 41(2): 129-136.
- [23] 李若愚, 戎舟, 方滔. 基于 WGAN-gp 的电阻抗成像后处理算法研究 [J]. 国外电子测量技术, 2021, 41(3): 124-129.
- LI R Y, RONG ZH, FANG T. Post-processing algorithm for electrical impedance tomography based on WGAN-gp [J]. Journal Foreign Electronic Measurement Technology, 2021, 41(3): 124-129.
- [24] 郭鹏, 邵剑飞. 融合金字塔卷积的 U-Net 肝脏与肝肿瘤分割网络 [J]. 现代电子技术, 2023, 46(5): 85-88.
- GUO P, SHAO J F. U-Net liver and liver tumor segmentation network based on pyramid convolution [J]. Modern Electronics Technique, 2023, 46(5): 85-88.
- [25] 赵少峰, 李静. 基于二维卷积神经网络的电阻抗成像算法 [J]. 仪表技术与传感器, 2022, 13(7): 85-89.
- ZHAO SH F, LI J. Electrical impedance tomography algorithm based on two-dimensiona convolution neural network [J]. Instrument Technique and Sensor, 2022, 13(7): 85-89.
- [26] RONNEBERGER O, FISCHER P, BROX T. U-net: Convolutional networks for biomedical image segmentation [C]. International Conference on Medical Image Computing and Computer-Assisted Intervention, 2015: 234-241.

作者简介

袁晶晶, 硕士研究生, 主要研究方向为电阻抗成像算法。

E-mail: yjjddcf@163.com

戎舟, 副教授、硕士生导师, 主要研究方向为虚拟仪器及网络化测控技术、阻抗成像技术等。

E-mail: rongz@njupt.edu.cn