

DOI:10.19651/j.cnki.emt.2210725

基于深度神经网络的电阻层析成像重建方法*

胡远洋

(中国民用航空飞行学院工程技术训练中心 广汉 618300)

摘要: 电阻层析成像技术因其非侵入式测量特点、结果可视化的直观性和测量方法便捷性,被广泛用于医学造影,两相流工业检测和特殊材料检测。但其图像重建的逆过程由于固有的欠定性、病态特点,使得结果有一定偏差。针对该情况,设计了基于 Resnet34 改进的深度学习来求解电阻抗层析成像逆问题。通过设置场域内以像素点为中心,小范围内随机半径与电阻率分布变化强度,正向计算仿真 32 电极情况下各电极处边界电压,以此建立训练与测试数据集。经调参、训练后,该方法能较快收敛,并和高斯-牛顿法、全变差法以及 Tikhonov 正则化算法相比较,得到较好的判定性能。

关键词: 电阻层析成像;逆问题;深度学习;Resnet

中图分类号: V267+.31;TP391.9 **文献标识码:** A **国家标准学科分类代码:** 510.4

Reconstruction method of electrical resistance tomography based on deep neural network

Hu Yuanyang

(Engineering Technique Training Center, Civil Aviation Flight University of China, Guanghan 618300, China)

Abstract: Electrical Impedance Tomography was widely used in medical imaging, two-phase flow industrial inspection and special material inspection due to its non-invasive measurement characteristics, intuitive results visualization and convenient measurement methods. However, the inverse process of image reconstruction is inherently under-determined and ill-conditioned, resulting in some deviations in the results. An improved deep neural network based on Resnet34 is designed to solve the inverse problem of electrical impedance tomography for it. The training and test data sets were established, by setting the pixel point as the center in the field, the random radius and resistivity distribution change intensity in a small range, and the boundary voltage at each electrode in the case of 32 electrodes was simulated forwardly. The method was proved to be able to converge quickly, and can obtain better judgment performance compared with Gauss-Newton iteration method, total variation method and Tikhonov regularization algorithm after parameter adjustment and training.

Keywords: electrical impedance tomography; inverse problem; deep learning; Resnet

0 引言

电阻层析成像技术(electrical impedance tomography, EIT)近年来因其非侵入式测量方法与可视化的测量结果,广受关注,被应用于诸多研究、应用领域,比如多相流检测^[1],肺部成像^[2],甚至洗发水流动特性^[3]等。通过在物体外部贴附电极,注入激励电流,并在形成的电极阵列处测量由此产生的电势,结合图像重建算法完成对被测物体内部敏感场域的电导率分布参数矩阵进行计算,通常还将结果以图像形式呈现。

EIT 的过程可分为正问题和逆问题两个过程,目前求解正问题大多基于有限元法(finite element method, FEM)求得边界电压^[4]。逆问题的处理办法则主要有 3 类:第 1 类是通过泰勒展开式求线性近似解,比如广义的反投影算法^[5];第 2 类则利用迭代方式计算,典型的如高斯-牛顿法^[6]、Landweber 迭代算法^[7]等;第 3 类则是非线性非迭代算法^[8-9]等。这些算法通常在不同的情况下针对不同研究对象相较于其他方法有一定的鲁棒性,但在复杂条件下,重建图像精度较差,特别是噪声影响条件下,很容易偏离真实值。

收稿日期:2022-07-19

* 基金项目:四川省科技项目(16ZB0031)资助

卷积神经网络(convolutional neural networks, CNN)是一类包含卷积计算且具有深度结构的前馈神经网络(feedforward neural networks),是深度学习(deep learning)的代表算法之一^[10]。得益于数值计算设备的更新,卷积神经网络得到快速发展,被广泛应用于计算机视觉^[11]、自然语言处理^[12]等领域,该技术也为电阻层析成像的重建提供了崭新的途径。李峰等^[13]设计了一种6层的FCDN图像重建算法,对多相流中导电介质分布有较好的重建精度,但需提高对噪声的鲁棒性;Tan等^[14]提出了一种基于卷积神经网络的电阻层析成像算法;叶明等^[15]提出了一种基于U2-Net模型的电阻抗成像方法,对不规则物体成像进行了仿真;谢莉莉等^[16]提出一种基于改进粒子群算法的反向传播(back propagation, BP)的神经网络电阻层析成像算法,利用PSO修正BP网络权值可以得到较好的结果;全卫国等^[17]基于残差神经网络提出了一种两相流的电阻层析成像及流型识别分类,针对流行特点特别是中心流和环形流有特别优秀的结果。这些方法大多针对特定的研究对象做了特别的优化、改进,尽力兼顾计算量与精度。

He等^[18]提出的Resnet网络相比前人在不降低计算精度的前提下有效降低了深度卷积神经网络的计算量。据此本文利用卷积神经网络强大的特征提取能力,将其与电阻层析成像技术相结合,针对关键点位置缺陷监测的特殊材料检测要求,提出了一种改进的ResNet模型。以电极阵列取得的边界电势测量值作为特征输入,将被测物内截面上像素点作为输出,求解边缘测量值与截面电导率分布情况的非线性映射,测试其泛化性能。与传统的EIT重建算法相比,该方法的重建结果具有更好的评价参数体现。

1 EIT 技术原理

EIT求解时使用电极注入激励,在其他阵列电极处测得边界电压,通过正问题求解得到边界电压值,再由麦克斯韦方程组建模,求解逆问题。因可能的模型复杂性,通常借由有限元法求得边界电压计算近似解,32电极某材料单点缺陷导致电导率分布异常的仿真模型如图1所示。




图1 某材料32电极单点电阻率跳变仿真模型

考虑某材料电磁特性以及薄壁情况,将实物三位问题简化为二维平面问题研究。在考虑测量电极与被测物体之

间接触阻抗的情况下,得到EIT数学模型如式(1)所示。

$$\begin{cases} \Omega: \nabla \cdot (\sigma \nabla \varphi) = 0 \\ \Gamma_2: \sigma \frac{\partial \varphi}{\partial \nu} = 0 \\ \sigma \frac{\partial \varphi}{\partial \nu} = -J \\ \Gamma_3: \varphi + z_l \sigma \frac{\partial \varphi}{\partial \nu} = \varphi_l \end{cases} \quad (1)$$

式中: φ 为场域的电位分布; z_l 是第 l 个测量电极的接触阻抗; φ_l 是第 l 个电极上测得的电位; σ 为被测物体内电导率分布; J 为边界电极注入电流的电流密度; ν 为场域的单位法向量。EIT正问题为已知电导率分布求边界电压,而其逆问题为根据边界电压估计电导率分布,即电导率分布情况重建。

2 基于Resnet的EIT图像重建方法

2.1 residual 结构应对深度网络带来的问题

利用深度卷积神经网络求解EIT逆问题,实质上是基于场域内部电导率分布情况建立激励信号与边界电压值的非线性映射关系,如式(2)所示。

$$Y = f(X, E, w, b) \quad (2)$$

式中: $X = \{x_1, x_2, \dots, x_n\}$ 表示边界电极序列, n 是电极总数, $E = \{e_1, e_2, \dots, e_n\}$ 表示对应激励信号情况, w, b 分别表示各神经元层级连接时的权重weight和偏置bias。

卷积神经网络在计算机视觉领域取得诸多突破,卷积层的复用提高了对研究对象特征隐含信息的提取,但随着卷积层和池化层的堆叠,深度神经网络会因层数的加深放大或者缩小梯度误差,致使梯度消失、梯度爆炸现象越来越明显,其次退化问题(degradation problem)会使深层网络结果还不如浅层的网络。梯度的问题可以通过对数据进行标准化处理、权重初始化方式进行削弱。为此,何恺明等提出利用残差连接的方式(即residual结构),保留原始输入信息,还提出了Batch Normalization的标准化方法,加快了深度网络的训练过程,解决了深层网络训练过程中梯度问题和退化问题,Santurkar S等人也进一步解释了BN方法的优化效果^[19]。

在电阻层析成像过程中,由于边界电压形成的特征数据维度远小于电导率分布维度,浅层卷积网络难以挖掘边界电压的深层隐含信息,无法有效完成电导率分布图像的重建运算;但过深的网络又会导致更多的运算量、更慢的计算速度,失去电阻层析成像技术原有的优点,兼具输出的精度与运算速度,本文参考深度残差神经网络ResNet34的结构,结合电阻层析成像在特殊材料缺陷检测的需求对模型进行了结构与参数的调整。

2.2 仿真数据集

概率学习需要大量的样本数据进行监督学习,但单纯通过实验并人工标记结果来获得大量的样本明显不现实。

故此利用有限元法编写了 Octave 和开源数据包^[20]脚本对正问题过程仿真,求解了大量的数据作为训练与交叉测试数据集。设置二维圆形敏感场域直径 12 cm,电极数量 32,成像像素点 256 个。在每处像素点附近随机范围内半径,随机范围内电阻率跳变强度形成缺陷区域,每一类仿真生成 1 000 个样本,合计共 256 000 个样本。其中训练集、验证集与测试集的数量比例约为 9 : 1 : 0.1。生成的仿真样例如图 2 所示。




图 2 缺陷仿真生成样例

2.3 基于 Resnet34 的改进 EIT 图像重建过程

为针对材料对象中电阻率分布跳变情况,同时提升 EIT 重建图像分辨率,提出了基于 ResNet34 修改的架构,如图 3 所示,其中涉及多层卷积结构框架组成如表 1 所示。

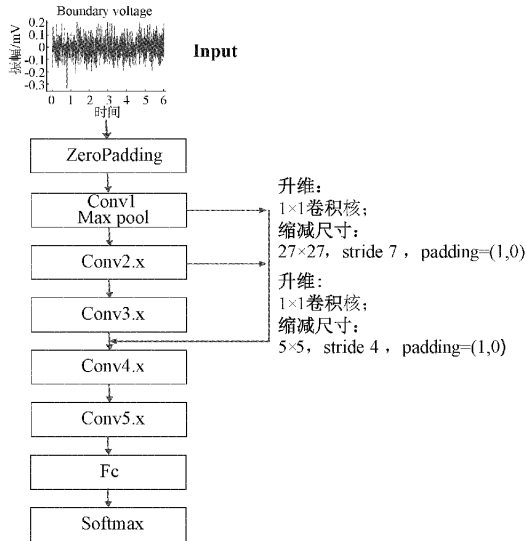


图 3 针对缺陷检测的 Resnet 修改模型

图表中所述 Conv. x 为文献[18]所描述划分的含有残差模块 residual 的多层卷积结构,其优点是使特征矩阵经过多层小卷积核的卷积层达到和经过一层大卷积核的卷积层同样的感受野,在保留同样多的特征信息的同时还能大量减少计算量。

本文提出的算法即在此基础之上,使用同样的手段以期保留更多的特征信息。首先将边界电压信号作为输入,为保证信息量,将通过相对刺激方式得到的边界电压直接测量结果 16×29 个数据列作向量 T ,将 T 的倒序转置与 T

表 1 多层卷积结构框架说明

卷积结构名称	输出	结构
Conv1	$32 \times 152 \times 152$	$11 \times 11, 32, \text{stride}=3$
Conv2. x	$64 \times 76 \times 76$	$\begin{bmatrix} 3 \times 3 & 64 \\ 3 \times 3 & 64 \end{bmatrix} \times 3$
Conv3. x	$128 \times 38 \times 38$	$\begin{bmatrix} 3 \times 3 & 128 \\ 3 \times 3 & 128 \end{bmatrix} \times 4$
Conv4. x	$256 \times 19 \times 19$	$\begin{bmatrix} 3 \times 3 & 256 \\ 3 \times 3 & 256 \end{bmatrix} \times 6$
Conv5. x	$512 \times 9 \times 9$	$\begin{bmatrix} 3 \times 3 & 512 \\ 3 \times 3 & 512 \end{bmatrix} \times 3$

相乘重塑为 464×464 尺寸的矩阵 F 后传入,其排布非常类似于数字图像矩阵。本文仿真实验依赖开源深度学习框架 Pytorch^[21],这里为了方便之后在 PyTorch 中将数据转化为张量,参考 PyTorch 对张量的格式要求 $X(\text{batch}, \text{channel}, \text{height}, \text{width})$ 将数字矩阵 $(464, 464, 1)$ 写为 $(1 \times 464 \times 464)$ 。将输入矩阵首先经过 padding 补零生成方阵方便计算;然后经过卷积核大小 11×11 ,步幅为 3 的卷积层处理得到特征张量 $(64 \times 152 \times 152)$ 。然后再轮流经过第 2、3、4 个残差结构,最终得到 $512 \times 9 \times 9$ 的特征张量,最后经展平处理,且以权重式(3)相加,并经过第 5 个卷积块处理,最后经全连接层和 softmax 输出每一个像素点的概率分布,将其以图像矩阵位置重排位后,乘以 255 作为图像灰度值,最终将经此方法得到的灰度图像作为对象重建的电导率分布图。

$$\begin{aligned} in(\text{Conv4. } x) &= 0.1 \times out(\text{Conv1. } x) + 0.3 \times \\ out(\text{Conv2. } x) &+ 0.6 \times out(\text{Conv3. } x) \end{aligned} \quad (3)$$

这个过程的流程基于经典 Resnet34 结构修改,在卷积系列块与块之间有全连接结构,针对特定要求,现在其基础上增加了跳跃块之间的全连接结构,连接到指定卷积层后、Relu 激活函数之前进行权重相加,将更多的输入信息传递到最后,以保证边界电压蕴含的信息少丢失,同时挖掘更多电极信号之间的隐含关系,各卷积结构间的权重参数为类似学习率的超参数,目前选值仅为多次试验取优结果;当然,在卷积投影时,需要通过一个核为 1×1 的卷积层,在特征矩阵的通道上做改变,同时在每一个捷径连接通道设置不同大小的卷积核和步幅,使其高度、宽度、通道都能够匹配,满足矩阵相加的要求。

3 仿真实验结果与分析

3.1 图像重建结果评价指标

为量化图像重建结果对关键点的电导率分布重建质量,选取了评价参数相对位置误差(position error, PE)用以评估重建图像中关键点偏离真实坐标的情况;形状误差(shape deformation, SD)用以评估计算重建图像中关键点面积占比;分辨率(resolution, RES)用以评估关键点在重

建图像中形成的圆形区域面积占比;环状伪影(ringing, RNG)则用来表征由于图像重建导致的围绕关键点附近环形区域的电导率异常,各评价参数详细定义如文献[22]所述。

3.2 图像重建

首先使用数据集对该模型进行训练,该改进 Resnet34 模型经 230 399 个样本训练后在 25 344 的验证集中最佳得到 89.1%的正确率。为了测试研究基于该改进电阻率分布情况重建方法性能,将全新的边界电压仿真结果通过其得到的权重模型,用以重建电导率分布情况,并将之与传统图像重建算法高斯-牛顿法(Gauss-Newton iteration method, GN)、全变差法(total variation distance, TV)以及 Tikhonov 正则化算法得到的电导率分布图像做比较。将具有代表性的几种模型分类情况以 4 种图像重建方法处理,所得到的成像结果如图 4 所示,其评价参数对比情况如图 5 所示,通过比较,图像重建结果大致可以分为 3 类情况,这 3 类情况代表模型的重建图像结果评价参数如表 2 所示(因考虑评价参数时会受电导率分布变化率影响,因此在做评价参数对比时统一将各模型背景电导率设为 1,缺陷点电阻率设为 5)。

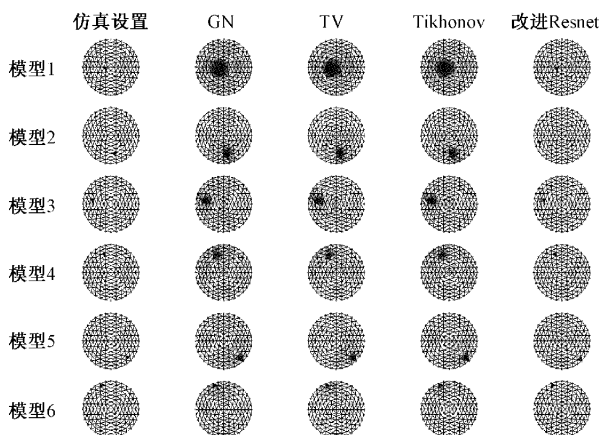


图 4 4 种电导率分布重建算法结果图对比


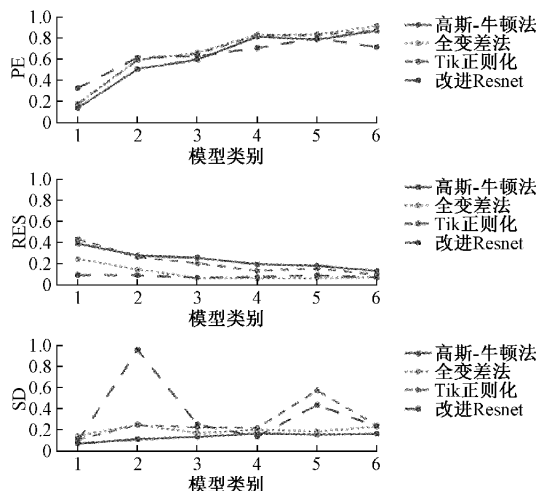


图 5 4 种电导率分布重建算法结果评价参数对比

表 2 4 种典型模型的重建图像结果评价参数

模型	重建方法	PE	RES	SD	RNG
2	GN	-0.505 5	0.272 3	0.109 2	0.303 9
	TV	-0.591 4	0.140 5	0.245 9	0.442 5
	TIK	-0.591 4	0.258 9	0.246 4	0.397 0
3	Adv-Resnet	-0.814 5	0.086 3	0.956 5	0
	GN	-0.593 5	0.252 6	0.132 0	0.398 3
	TV	-0.661 0	0.062 3	0.166 7	0.866 7
5	TIK	-0.652 2	0.198 8	0.221 3	0.594 7
	Adv-Resnet	-0.827 5	0.062 3	0.250 0	0
	GN	-0.784 7	0.177 2	0.154 6	0.468 9
6	TV	-0.834 7	0.059 7	0.181 8	0.391 8
	TIK	-0.826 6	0.150 6	0.257 1	0.526 1
	Adv-Resnet	-0.896 0	0.086 3	0.434 8	0

从仿真实验结果不难看出:

1)情况 1 如模型 2 为特别选取,这种情况在进行测试的 256 个样本中出现了 16 次,在这些情况下,改进的 Resnet 算法对缺陷点位置判断错误,查看重建图像质量评价参数亦可得到类似信息,改进算法对模型二重建图像的 SD 值异常的高,在深度学习中,这种情况不可避免,在深度神经网络的电阻层析成像应用中,目前可通过质量评价参数判断其结果是否正常,如表 2 中可以观察到 PE 和 SD 参数的值明显跳变,处不正常位置,此时可使用多次测试重建方法修正;

2)情况 2 如模型 1、模型 3、模型 4 和模型 6 中,改进的 Resnet 算法体现了其优异的性能,相比传统算法其 PE、RES、SD 评价参数都不遑多让,虽在该类模型上出现了小面积伪影,但重建图像结果仍然优于传统图像重建算法;

3)情况 3 如模型 5 代表了改进 Resnet 算法最为普遍的情况,即预测点位置与实际缺陷点位置十分接近,其评价参数 SD 显示了较为异常的状态,但综合考虑结构相似度 SSIM 和成像相对误差 RE,则可发现改进 Resnet 算法对真实情况的还原程度远远高于传统重建成像方法。

综上,通过深度神经网络算法得到的结果,从关键点准确度以及伪影大小的层面看,均优于传统的图像重建算法,能更准确地反映被测物内部关键点的轮廓形状,边界也较为清晰,更重要的是没有环状伪影,对缺陷点的检查更为适用。

4 结 论

针对特殊材料监测的电阻层析成像技术中,逆问题的非线性映射求解问题,提出了一种基于深度神经网络的改进 Resnet 方法,该方法在经典 Resnet34 网络多层卷积结构的基础上增加了捷径连接的途径,适配了合理的权重参数。

设计制作了大量仿真数据用于训练、测试与验证,并将之与传统的高斯-牛顿法、全变差法和 Tikhonov 正则化算法相比较,该模型验证集正确率最高达 89.1%,测试集数据正确率也达 70%,因为该方法结果没有传统算法的伪影影响,而且在绝大多数情况下即便分类错误也能十分接近缺陷点位置,故其在大多数情况下对真实情况的还原程度远远高于传统重建成像方法。但该方法局限在于仅针对单一缺陷点情况进行了分析,且需要耗费大量时间搜集数据集训练、调试,故其适用性还需要进一步的改进与提高。

参考文献

- [1] 陶芳芳,宁尚雷,靳海波. 电阻层析成像技术在气液(固)多相流动体系中的应用进展[J]. 过程工程学报, 2020, 20(4): 371-381.
- [2] 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, DOI:10.13382/j.jemi. B2104769.
- [3] REN Z, KOWALSKI A, RODGERS T L. Measuring inline velocity profile of shampoo by electrical resistance tomography(ERT)[J]. Flow Measurement and Instrumentation, 2017, 58: 31-37.
- [4] 成国民. 电阻抗成像重构算法研究[D]. 南京:南京邮电大学, 2019: 10-15.
- [5] WANG H, XU G, ZHANG S, et al. An implementation of generalized back projection algorithm for the 2-D anisotropic EIT problem[J]. IEEE Transactions on Magnetics, 2015, 51(3): 1-4.
- [6] AHMAD S, STRAUSS T, KUPIS S, et al. Comparison of statistical inversion with iteratively regularized Gauss Newton method for image reconstruction in electrical impedance tomography[J]. Applied Mathematics and Computation, 2019, 358: 436-448.
- [7] LI F, DONG F, TAN C. Landweber iterative image reconstruction method incorporated deep learning for electrical resistance tomography [J]. IEEE Transactions on Instrumentation and Measurement, 2020, 70: 1-11.
- [8] GARDE H, KNUDSEN K. 3D reconstruction for partial data electrical impedance tomography using a sparsity prior [J]. ArXiv Preprint, 2014, ArXiv:1412.6288.
- [9] KNUDSEN K, RASMUSSEN A K. Direct regularized reconstruction for the three-dimensional Calder\' on problem[J]. ArXiv Preprint, 2021, ArXiv:2106.08391.
- [10] 王亚东,田永林,李国强,等. 基于卷积神经网络的三维目标检测研究综述[J]. 模式识别与人工智能, 2021, 34(12): 1103-1119, DOI: 10.16451/j. cnki. issn1003-6059. 202112004.
- [11] 卢宏涛,张秦川. 深度卷积神经网络在计算机视觉中的应用研究综述[J]. 数据采集与处理, 2016, 31(1): 1-17, DOI:10.16337/j.1004-9037.2016.01.001.
- [12] 奚雪峰,周国栋. 面向自然语言处理的深度学习研究[J]. 自动化学报, 2016, 42(10): 1445-1465, DOI: 10.16383/j. aas. 2016. c150682.
- [13] 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.
- [14] TAN C, LV S, DONG F, et al. Image reconstruction based on convolutional neural network for electrical resistance tomography [J]. IEEE Sensors Journal, 2018, 19(1): 196-204.
- [15] 叶明,李晓丞,刘凯,等. 一种基于 U~2-Net 模型的电阻抗成像方法[J]. 仪器仪表学报, 2021, 42(2): 235-243, DOI:10.19650/j. cnki. cjsi. J2007065.
- [16] 谢莉莉,汪鹏,陈丽. PSO 算法优化 BP 神经网络的 EIT 图像重建算法[J]. 制造业自动化, 2011, 33(2): 45-46, 53.
- [17] 全卫国,曾世超,张立峰,等. 基于深度残差神经网络的电阻层析成像及流型辨识方法[J/OL]. 系统仿真学报: 1-9 [2022-09-20]. <http://kns.cnki.net/kcms/detail/11.3092.V.20210630.1320.018.html>.
- [18] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition[C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2016: 770-778.
- [19] SANTURKAR S, TSIPRAS D, ILYAS A, et al. How does batch normalization help optimization? [J]. Advances in neural information processing systems, 2018, DOI:10.48550/arXiv.1805.11604.
- [20] DJAJAPUTRE D. Electrical impedance tomography: Methods, history and applications [J]. Medical Physics, 2005, 32(8), DOI:10.1118/1.1995712.
- [21] PASZKE A, GROSS S, MASSA F, et al. Pytorch: An imperative style, high-performance deep learning library[J]. Advances in Neural Information Processing Systems, 2019, DOI:10.48550/arXiv.1912.01703.
- [22] 胡远洋. 改进 PSO 电阻抗重建图像质量评估方法研究[J]. 国外电子测量技术, 2021, 40(9): 76-80, DOI: 10.19652/j. cnki. femt. 2102910.

作者简介

胡远洋, 硕士, 实验师, 主要研究方向为电学层析成像、机器学习。

E-mail: yyh@cafuc.edu.cn