

4-19-2022

## Image Reconstruction of Electrical Capacitance Tomography Based on Convolutional Neural Network and Finite Element Simulation

Lifeng Zhang

*Department of Automation, North China Electric Power University, Baoding 071003, China;*  
lifeng.zhang@ncepu.edu.cn

Huiren Wang

*Department of Automation, North China Electric Power University, Baoding 071003, China;*

Follow this and additional works at: <https://dc-china-simulation.researchcommons.org/journal>



Part of the Artificial Intelligence and Robotics Commons, Computer Engineering Commons, Numerical Analysis and Scientific Computing Commons, Operations Research, Systems Engineering and Industrial Engineering Commons, and the Systems Science Commons

---

This Paper is brought to you for free and open access by Journal of System Simulation. It has been accepted for inclusion in Journal of System Simulation by an authorized editor of Journal of System Simulation.

---

# Image Reconstruction of Electrical Capacitance Tomography Based on Convolutional Neural Network and Finite Element Simulation

## Abstract

**Abstract:** To address the issues related to the mixed hybrid telemetry, track and command(TT&C) resource, including multiple attributes, large differences in preferences and scheduling conflicts when resources are limited in joint scheduling, on the basis of the description method in the single system TT&C network scheduling research, the characteristics of the hybrid TT&C task requirements are analyzed and *the standardized description of the hybrid TT&C resource scheduling task requirements is provided. With the goal of maximizing the return value of TT&C scheduling, a hybrid resource joint scheduling model is established. A solution strategy based on an improved genetic algorithm is proposed by introducing the idea of infinitesimal method and applying an extended multiplexing method for the available arc segments.* The simulation results show that the proposed model and the corresponding conflict resolution algorithm can effectively improve the mission satisfaction rate and scheduling revenue.

## Keywords

telemetry, track and command(TT&C), joint scheduling of hybrid TT&C resources, infinitesimal method, scheduling revenue, mission satisfaction rate

## Recommended Citation

Lifeng Zhang, Hui ren Wang. Image Reconstruction of Electrical Capacitance Tomography Based on Convolutional Neural Network and Finite Element Simulation[J]. Journal of System Simulation, 2022, 34(4): 712-718.

# 基于卷积神经网络及有限元仿真的电容层析成像图像重建

张立峰, 王会忍

(华北电力大学 自动化系, 河北 保定 071003)

**摘要:** 为求解电容层析成像 (electrical capacitance tomography, ECT) 图像重建非线性病态逆问题, 提出基于一维卷积神经网络 (*one-dimensional convolutional neural network, 1D CNN*) 的电容层析成像图像重建算法。通过 *1D CNN* 建立了 ECT 系统独立测量值与重建图像灰度值之间的非线性映射关系。采用有限元仿真软件获得 6 种典型流型的随机分布样本, 完成了 *1D CNN* 网络的训练及测试, 进行了静态实验, 并与常用的线性反投影、Landweber 迭代算法进行比较。仿真及静态实验结果均表明: 基于 *1D CNN* 算法的 ECT 重建图像质量得到明显提高, 具有较好的泛化能力及实时性。

**关键词:** 两相流; 电容层析成像; 一维卷积神经网络; 图像重建; 有限元仿真

中图分类号: TP391; TN911.73

文献标志码: A

文章编号: 1004-731X(2022)04-0712-07

DOI: 10.16182/j.issn1004731x.joss.20-0849

## Image Reconstruction of Electrical Capacitance Tomography Based on Convolutional Neural Network and Finite Element Simulation

Zhang Lifeng, Wang Huiren

(Department of Automation, North China Electric Power University, Baoding 071003, China)

**Abstract:** In order to resolve the nonlinear and ill-posed inverse problem of the image reconstruction of electrical capacitance tomography (ECT), *an image reconstruction algorithm based on one-dimensional convolutional neural network (1D CNN) is presented.* The nonlinear mapping relationship between the independent measurement value of ECT system and the gray value of reconstructed image is established by 1D CNN. Six typical flow regimes with random distribution are obtained by the finite element simulation software and a 1D CNN is successfully trained. Simulation and static experiments are carried out and the reconstructed images using linear back projection, Landweber iterative algorithm and 1D CNN are compared. *Experimental results show that the 1D CNN algorithm has good generalization ability and the quality of reconstructed images by 1D CNN is obviously improved compared with the other two algorithms.*

**Keywords:** two-phase flow; electrical capacitance tomography; one-dimensional convolutional neural network; image reconstruction; finite element simulation

## 引言

电容层析成像 (electrical capacitance tomography, ECT) 技术为一种用于两相或多相流参数测量的可视化测量技术<sup>[1]</sup>。ECT 图像重建的质

量决定了其是否能在工业中成功应用。电容层析成像图像重建算法按是否需要迭代可分为非迭代及迭代型, 前者代表算法有 LBP (linear back projection), 后者代表算法为 Landweber 迭代算法<sup>[2]</sup>。目前, ECT 图像重建算法精度仍不能达到实际应用的

收稿日期: 2020-11-04

修回日期: 2021-01-22

基金项目: 国家自然科学基金(61973115)

第一作者: 张立峰(1979-), 男, 博士, 副教授, 研究方向为电学层析成像技术。E-mail: lifeng.zhang@ncepu.edu.cn

要求。

机器学习理论的发展带来了ECT图像重建算法研究的新途径。利用机器学习算法可较好地实现电容值与介质分布的非线性映射关系,从而提高ECT图像重建精度,常用算法有BP神经网络及支持向量机<sup>[3-4]</sup>。随着深度学习理论不断发展,其学习与预测能力亦不断增强,为ECT图像重建提供了新的方法。吴新杰等将二维卷积神经网络应用在ECT系统图像重建中,以Landweber算法的图像重建结果作为初始状态,对网络进行训练实现了图像重建<sup>[5]</sup>;张耘采用DBN(deep belief network)神经网络对ECT系统进行图像重建,取得了较好的效果<sup>[6]</sup>;根据二维卷积神经网络适宜图像处理的特点,孙先亮等将ECT系统电容值预处理为二维矩阵作为二维卷积神经网络的输入,建立了数据集并对网络模型进行训练,实现了ECT的图像重建<sup>[7]</sup>。

由于ECT系统的独立电容测量值数量较少,图像重建为病态问题,上述研究表明深度学习可较好地解决非线性映射问题,同时具有较好的适应性。卷积神经网络(convolutional neural network, CNN)是深度学习中应用较为广泛的算法。CNN网络通常应用于提取二维图像的特征,而在ECT系统中采集的电容数据为一维数值,为更好地提取数据特征,本文采用一维卷积神经网络(one-dimensional convolutional neural network, 1D CNN)构建了基于1D CNN的ECT图像重建算法。

## 1 ECT工作原理

ECT系统通常由传感器、数据采集系统和图像重建计算机三部分构成<sup>[8]</sup>,其结构原理如图1所示。

其工作流程为:通过对电极阵列按照一定激励顺序施加激励电压,测量激励电极与不同的检测电极之间的电容值,数据采集系统将测量信号转变为数字量并发送给计算机,计算机根据接收的信号结合图像重建算法得到管内介质介电常数的分布图像<sup>[9]</sup>。




图1 电容层析成像系统原理

Fig. 1 Principle of electrical capacitance tomography system

ECT系统敏感场模型可表示为<sup>[10]</sup>

$$\nabla[\varepsilon(x,y)E(x,y)]=0 \quad (1)$$

式中:  $\varepsilon(x,y)$ 为管内介电常数分布函数;  $E(x,y)$ 为电场强度分布函数。

对式(1)进行离散化及线性化后,可得

$$\lambda_{M \times 1} = \mathbf{S}_{M \times N} \mathbf{G}_{N \times 1} \quad (2)$$

式中:  $\lambda$ 为归一化后的电容测量值向量;  $\mathbf{S}$ 为灵敏度矩阵;  $\mathbf{G}$ 为图像灰度值矩阵;  $M$ 为ECT系统的独立测量值;  $N$ 为管内剖分网格数。

ECT包含正问题及逆问题:正问题指已知介电常数分布和施加的边界条件,计算场域内电势分布,进而求取电极对间的电容值;逆问题指通过边界测量电容值,获得重建图像灰度值<sup>[11]</sup>。由于独立测量数远小于图像像素数,所以ECT逆问题本质上是一个非线性病态问题,求解难度大<sup>[12]</sup>。

## 2 基于1D CNN的ECT图像重建方法

### 2.1 1D CNN在ECT图像重建中的应用

卷积神经网络包括输入层、卷积层、池化层、全连接层,以及输出层。通过各卷积层快速提取特征,不断降低特征维度,提取不同含义的特征,再通过全连接层实现对特征的分类或回归<sup>[13]</sup>。根据ECT系统图像重建的特点,采用的一维卷积神

经网络无需使用层数太多的网络结构, 本文设计的网络结构如图2所示。




图2 网络结构  
Fig. 2 Network structure

本文使用12电极ECT传感器, 共可测量得到66个电容独立测量值, 将其归一化后作为网络输入, 重建图像各像素的灰度值作为网络输出。网络含有2个卷积层及池化层, 其中卷积层1和2分别使用了32和64个卷积核, 每个卷积核的尺寸均为 $1 \times 3$ , 池化层1和2均为最大池化层, 使用 $1 \times 2$ 的窗口且步长设置为1, 其目的是将特征向量下采样2倍, 全连接层和输出层均为全连接。

此外, 卷积层1和2以及全连接层均采用ReLU激活函数, 将输入中大于0的数据保留下来, 对于小于0的数据置为0:

$$f(x) = \max(0, x) \quad (3)$$

输出层采用常用的非线性激活函数 Sigmoid:

$$f(x) = 1/(1 + e^x) \quad (4)$$

式中:  $x$  的取值范围 $[-\infty, +\infty]$ , 其对应的  $y$  的取值范围为 $[0, 1]$ 。该激活函数可使预测的数据分布在 $[0, 1]$ 内, 通过训练更易得到图像的灰度值。

损失函数根据预测值与真实值的距离来指导模型的收敛方向, 损失函数的合理选取直接影响到网络学习的质量<sup>[14]</sup>。为配合 Sigmoid 激活函数, 本文采用二值交叉熵损失函数:

$$L(\hat{y}_i, y_i) = -[y_i \ln \hat{y}_i + (1 - y_i) \ln(1 - \hat{y}_i)] \quad (5)$$

式中:  $\hat{y}$  为样本的期望输出;  $y$  为样本的实际输出。

## 2.2 建立训练样本

样本数据的获得即为在设置流型分布下, 通过计算式(1)求解ECT正问题。然而, 由于流型分布的随机性, 介电常数分布无解析表达式, 导致式(1)无法计算解析解, 通常采用有限元法进行数值求解。

本文以油/气两相流为研究对象, 采用有限元法对ECT正问题进行仿真计算。仿真参数: 12电极ECT传感器, 管道内径、外径和外屏蔽层直径分别为125, 150, 170 mm。采用课题组开发的基于MATLAB的有限元仿真软件包进行ECT传感器建模及正问题求解, 其求解过程如图3所示。

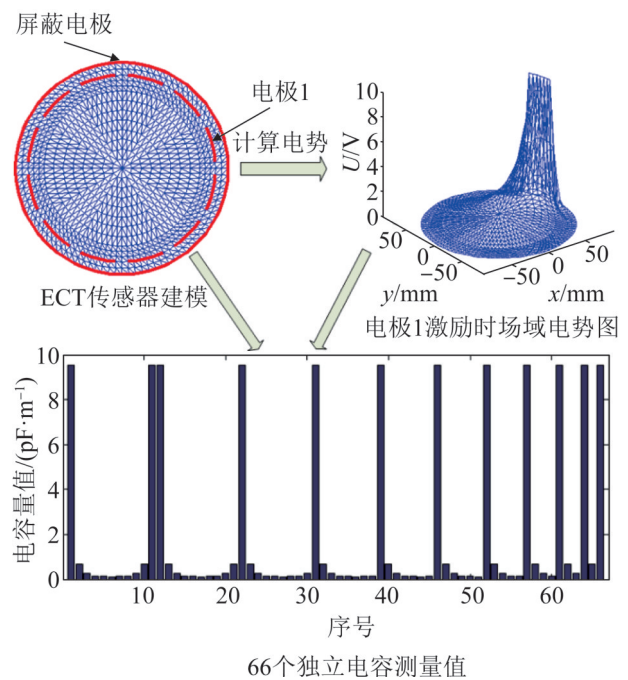


图3 有限元仿真流程图  
Fig. 3 Flow chat of finite element simulation

图3中管内成像区域剖分为1728个三角形网格单元, 以电极1作为激励电极为例, 给出了基于有限元法计算的场域内电势三维分布图。

本文选取了6种典型流型进行图像重建研究, 包括泡状流、环状流和层流, 如图4所示。



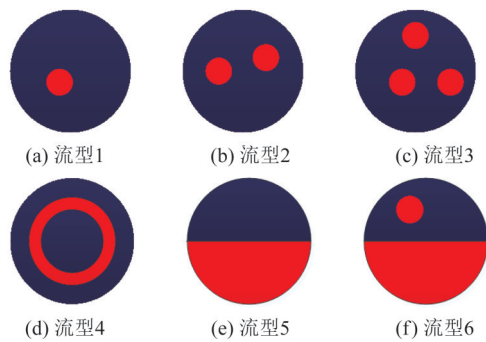


图4 6种典型流型

Fig. 4 Six typical flow regimes

为使流型样本具有随机性及代表性, 对于泡状流型1, 2, 3, 泡的中心位置及大小均为随机设置, 流型4模拟环状流, 通过改变环的厚度获得不同的样本, 流型5模拟层流, 通过改变层流的厚度和分布角度获得不同的样本, 流型6将泡状流型和层流结合, 每个样本中含有不同位置和厚度的流型。对每种流型各随机生成5 000个样本, 获得6种流型共计30 000个样本。选定好流型样本后, 按照图3所示流程进行有限元仿真计算, 获得每种流型样本对应的66个独立电容测量。然后, 从每种流型样本中随机选取4 990个作为训练样本, 共计29 940个训练样本, 其余60个样本作为测试集。

### 2.3 网络训练

使用PC配置为Inter(R)Core(TM)i5-4210UCPU@1.7GHz 4G RAM, Windows8的64位操作系统, 采用Anaconda对一维卷积神经网络进行训练。训练过程中损失函数(loss)随轮次(epoch)的变化如图5所示。




图5 损失函数

Fig. 5 Loss function

## 3 实验结果及分析

### 3.1 评价指标

为定量分析重建图像质量, 选取图像相对误差及相关系数作为评价指标<sup>[15-16]</sup>。

图像相对误差为重建介质分布与原始介质分布的相对误差:

$$RE = \frac{\sum_{i=1}^N (\hat{g}_i - g_i)^2}{\sum_{i=1}^N g_i^2} \quad (6)$$

式中:  $\hat{g}_i$ 和 $g_i$ 分别为重建介质分布和原始介质分布图像中第 $i$ 个网格内的灰度值;  $N$ 为管道截面剖分网格总数。当图像相对误差越小, 重建的灰度值与原始的灰度值差距越小, 即重建图像的质量越好。

相关系数用来衡量重建介质分布与原始介质分布之间的线性相关程度:

$$CC = \frac{\text{cov}(\hat{g}, g)}{\sqrt{\text{var}(\hat{g})\text{var}(g)}} \quad (7)$$

式中:  $\text{cov}()$ 为协方差;  $\text{var}()$ 为均方差;  $\hat{g}$ 表示重建的灰度值;  $g$ 为原始的灰度值。当相关系数越大, 重建的灰度值与原始的灰度值越接近, 重建图像的质量就越好。

### 3.2 重建图像

一维卷积神经网络训练完毕后, 随机选取测试集中的6种流型, 分别采用LBP, Landweber迭代和1D CNN 3种算法进行图像重建, 重建结果如图6所示, 计算的定量评价指标如表1所示。

由图6可知, LBP算法对6种流型均出现物体边缘模糊、图像失真的现象, 不能准确反映管道内物体分布的信息; Landweber迭代算法成像质量比LBP算法有所改善, 但对流型1和流型5成像边缘模糊, 存在较大的误差。对流型2, 3和6重建结果存在较多伪影, 相邻物体存在粘连现象。对流型4的重建结果严重失真; 再对比使用1D CNN算法的重建结果, 不仅边缘清晰且伪影少, 形状保真度高, 对于流型2和3中多个物体的成像没有粘连。

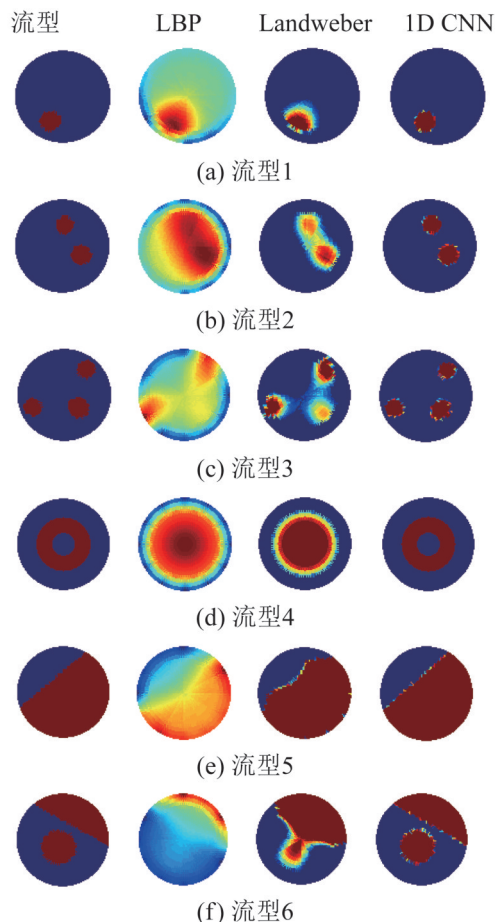


图6 重建图像

Fig. 6 Reconstruction images

表1 评价指标

Table 1 Evaluation index

流型	指标	LBP	Landweber	1D CNN
1	RE	0.925 6	0.553 3	0.179 8
	CC	0.587 7	0.830 0	0.983 1
2	RE	0.913 0	0.677 7	0.263 2
	CC	0.422 0	0.753 6	0.963 4
3	RE	0.909 8	0.672 2	0.344 8
	CC	0.429 1	0.758 1	0.930 0
4	RE	0.739 7	0.545 6	0.000 1
	CC	0.571 1	0.771 2	0.999 9
5	RE	0.545 2	0.231 6	0.064 6
	CC	0.859 8	0.900 3	0.992 5
6	RE	1.063 9	0.549 3	0.125 0
	CC	0.679 4	0.717 8	0.986 8

从表1可见, LBP算法成像结果的RE偏高, CC偏低; Landweber迭代算法次之; 1D CNN算法RE及CC指标均为最优。与图6定性观察结果一致。

### 3.3 重建时间

本文使用Windows平台对LBP, Landweber和1D CNN 3种算法的重建时间进行比较, 结果如表2所示。表2中Landweber迭代算法为迭代100次的耗时。

表2 重建时间

Table 2 Reconstruction time		s
算法	重建时间	
LBP	0.005	
Landweber	0.686	
1D CNN	0.438	

由表2可知, LBP算法的重建时间最短, 1D CNN与Landweber算法重建时间在同一数量级, 但是1D CNN算法重建时间更短。虽然1D CNN算法可满足实时成像, 但重建时间还可进一步优化。

### 3.4 泛化能力测试

为验证1D CNN算法的泛化能力, 选取了4种未参与训练的流型作为测试样本, 其重建结果如图7所示, 计算的定量评价指标如表3所示。

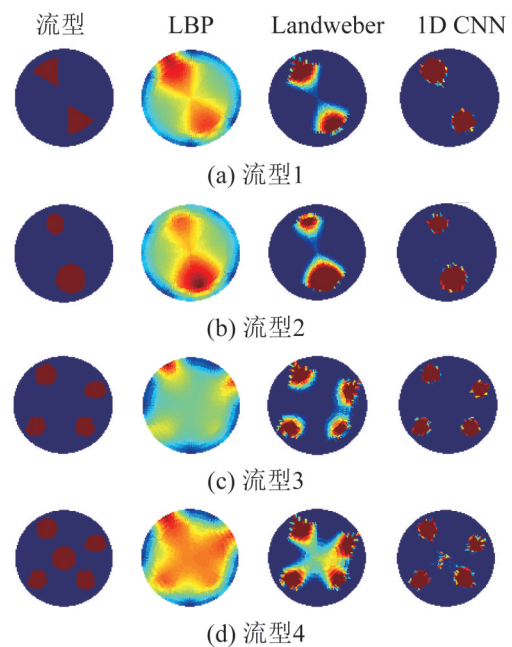


图7 测试重建结果

Fig. 7 Test reconstruction results

表3 评价指标  
Table 3 Evaluation index

流型	指标	LBP	Landweber	1D CNN
1	RE	0.887 9	0.587 6	0.539 6
	CC	0.517 9	0.796 0	0.840 5
2	RE	0.863 7	0.472 5	0.402 4
	CC	0.607 4	0.868 5	0.904 0
3	RE	0.939 1	0.555 3	0.446 3
	CC	0.433 9	0.823 6	0.877 2
4	RE	0.848 3	0.718 0	0.652 3
	CC	0.433 4	0.655 6	0.703 6

由图7可知, LBP算法重建精度差, 流型3和流型4的重建结果失真严重; Landweber迭代算法成像效果较好, 但对于4种流型均存在伪影及粘连的现象, 且流型4重建图像失真; 1D CNN算法无论在重建精度及形状保真度方面都明显优于前2种算法, 可准确反映管道内物体的位置信息。

从表3的评价指标可以看出, LBP算法成像结果的RE偏高, CC偏低; Landweber迭代算法次之; 相比较而言1D CNN算法RE最低CC最高。

图7及表3的结果表明1D CNN算法具有较好的泛化能力。

### 3.5 静态实验

采用华北电力大学先进测量实验室的ECT系统进行了静态实验, 传感器管道内径为60 mm, 使用直接为10 mm的有机玻璃棒模拟泡状流, 使用塑料颗粒和有机玻璃管模拟环状流, 静态实验测试流型的图像重建结果如图8所示。

由图8可知, LBP算法对5种流型重建效果差; Landweber迭代算法对流型1, 3, 5的重建效果较好, 但精度不高, 对流型2和4的重建结果失真严重; 1D CNN算法对测试流型的重建图像精度最高, 形状保真度最好。

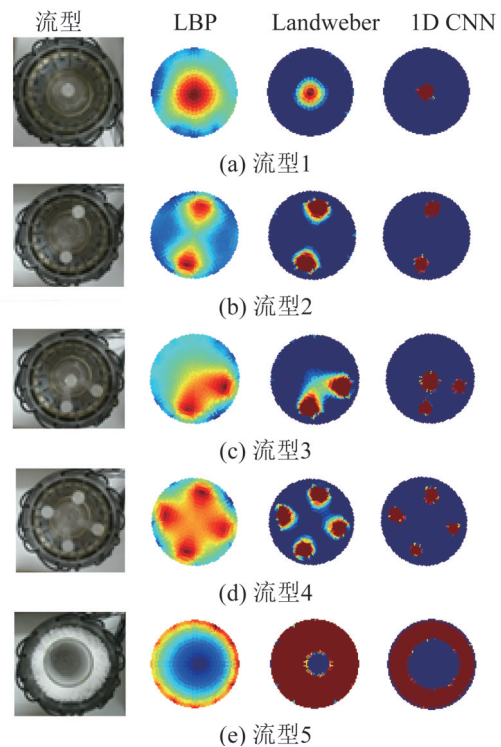


图8 静态实验重建结果

Fig. 8 Reconstruction results of static test

## 4 结论

本文针对ECT图像重建存在的非线性及病态问题, 基于深度学习神经网络较强的学习与预测能力与ECT采集数据的特点, 研究了基于1DCNN网络的ECT图像重建算法, 并进行了仿真及静态实验, 实验结果表明: 基于1D CNN的ECT图像重建算法与LBP算法及Landweber迭代算法相比, 其图像重建质量高, 重建图像中物体分布无粘连、伪影少、能较好地分割多物体; 同时, 1D CNN算法运行时间较短, 能满足在线成像要求。基于1D CNN的ECT图像重建算法为ECT图像重建提供了新的思路。由于多相流流型丰富, 而本文研究的流型偏少, 未来可继续扩充训练样本库, 亦可针对不同的流型, 单独构建相应的1D CNN网络, 进一步提高重建图像质量, 更好地促进ECT的工程应用。



## 参考文献:

- [1] Lei J, Liu S. Dynamic Inversion Approach for Electrical Capacitance Tomography [J]. IEEE Transaction on Instrumentation and Measurement(S0018-9456), 2013, 62(11): 3035-3049.
- [2] 王丕涛, 王化祥, 孙彝渊. 基于内阵列电极的ECT/ERT双模态成像[J]. 天津大学学报(自然科学与工程技术版), 2015, 48(4): 311-316.  
Wang Pitaoy, Wang Huaxiang, Sun Benyuan. ECT/ERT Dual-Modality Tomography Based on Inner Electrode Array[J]. Journal of Tianjin University(Science and Technology), 2015, 48(4): 311-316.
- [3] 王小鑫, 王博, 陈阳正, 等. 基于电容层析成像技术重构图像的两相流流型识别[J]. 计量学报, 2020, 41(8): 942-946.  
Wang Xiaoxin, Wang Bo, Chen Yangzheng, et al. Two-phase Flow Pattern Recognition Based on Electrical Capacitance Tomography Reconstructed Images [J]. Acta Metrologica Sinica, 2020, 41(8): 942-946.
- [4] 张立峰, 朱炎峰. 极限学习机在电容层析成像中的应用[J]. 电测与仪表, 2020, 57(9): 146-150.  
Zhang Lifeng, Zhu Yanfeng. Application of Extreme Learning Machine in Electrical Capacitance Tomography [J]. Electrical Measurement & Instrumentation, 2020, 57(9): 146-150.
- [5] 吴新杰, 李红玉, 梁南南. 卷积神经网络在ECT图像重建上的应用[J]. 辽宁大学学报, 2018, 45(1): 29-33.  
Wu Xinjie, Li Hongyu, Liang Nannan. Application of Convolutional Neural Network in ECT Image Reconstruction [J]. Journal of Liaoning University, 2018, 45(1): 29-33.
- [6] 张耘. 电容层析成像系统成像算法研究[D]. 哈尔滨: 哈尔滨理工大学, 2015.  
Zhang Yun. Research on Imaging Algorithm of Electrical Capacitance Tomography System[D]. Harbin: Harbin University of Technology, 2015.
- [7] 孙先亮, 李健, 韩哲哲, 等. 基于数据驱动的卷积神经网络电容层析成像图像重建[J]. 化工学报, 2020, 71(5): 2004-2016.  
Sun Xianliang, Li Jian, Han Zhezhe, et al. Image Reconstruction of Electrical Capacitance Tomography Based on Data Driven Convolution Neural Network [J]. Journal of Chemical Engineering, 2020, 71(5): 2004-2016.
- [8] Meribout M, Saied I M. Real-Time Two-Dimensional Imaging of Solid Contaminants in Gas Pipelines Using an Electrical Capacitance Tomography System[J]. IEEE Transactions on Industrial Electronics(S0278-0046), 2017, 64(5): 3989-3996.
- [9] 陈宇, 夏宗基, 周雨佳. 基于修正稀疏拟牛顿的电容层析成像重建算法[J]. 系统仿真学报, 2019, 31(5): 820-821.  
Chen Yu, Xia Zongji, Zhou Yujia. Modified Sparse Quasi-newton Algorithm for Electrical Capacitance Tomography System[J]. Journal of System Simulation, 2019, 31(5): 820-821.
- [10] 张立峰, 李佳, 田沛. Kalman滤波在电容层析成像图像重建中的应用[J]. 计量学报, 2017, 38(3): 316-318.  
Zhang Lifeng, Li Jia, Tian Pei. Application of Kalman Filter for Image Reconstruction of Electrical Capacitance Tomography [J]. Acta Metrologica Sinica, 2017, 38(3): 316-318.
- [11] 刘诗源. 电容层析成像系统关键技术研究与设计[D]. 南昌: 华东交通大学, 2017.  
Liu Shiyuan. Research and Design of Key Technology for Capacitance Tomography System[D]. Nanchang: East China Jiaotong University, 2017.
- [12] 马敏, 郭琪, 闫超齐. 基于广义正则化的ECT图像重建[J]. 系统仿真学报, 2017, 29(8): 1851-1853.  
Ma Min, Guo Qi, Yan Chaoqi. ECT Image Reconstruction Algorithm Based on Generalized Regularization[J]. Journal of System Simulation, 2017, 29(8): 1851-1853.
- [13] Li F, Tan C, Dong F, et al. V-Net Deep Imaging Method for Electrical Resistance Tomography [J]. IEEE Sensors Journal(S1530-437X), 2020, 20(12): 6460-6468.
- [14] 于波, 方业全, 刘闽, 等. 基于深度卷积神经网络的图像重建算法[J]. 计算机系统应用, 2018, 27(9): 170-175.  
Yu Bo, Fang Yequan, Liu Min, et al. Image Reconstruction Algorithm Based on Deep Convolution Neural Network [J]. Computer Systems & Applications, 2018, 27(9): 170-175.
- [15] 颜华, 许鑫, 孙延辉. 带阈值滤波的迭代法三维ECT图像重建[J]. 沈阳工业大学学报, 2014, 36(6): 671-675.  
Yan Hua, Xu Xin, Sun Yanhui. 3D ECT Image Reconstruction by Iterative Method with Threshold Filtering[J]. Journal of Shenyang University of Technology, 2014, 36(6): 671-675.
- [16] Tan C, Dong F, Masahiro T. Image Reconstruction Based on Convolutional Neural Network for Electrical Resistance Tomography [J]. IEEE Sensors Journal(S1530-437X), 2019, 19(1): 196-203.