

DOI:10.19651/j.cnki.emt.2209772

# 自适应加权的多特征融合 ECT 图像重建算法<sup>\*</sup>

马 敏 高晓波

(中国民航大学电子信息与自动化学院 天津 300300)

**摘要:**为了解决电容层析成像(ECT)图像重建中电容值与介电常数这一非线性病态问题,提出一种自适应加权的多特征融合(AWMF)ECT 图像重建算法,利用网络模型拟合电容张量和介电常数的非线性映射关系。首先,在网络模型中采用密集卷积网络(DenseNet),不仅缓解梯度消失现象,还融合不同通道的特征信息;添加挤压激励网络(SENet)自适应调整特征通道的权重,用以提取不同通道的关键特征,提高重建图像的精度。其次,构建树形聚合结构(TASN)网络模块,扩大感受野并提取丰富的多尺度特征信息,消除普通卷积所带来的伪影现象。在 COMSOL5.3 软件上建模仿真后,通过 MATLAB2014a 对图像进行重建。实验结果表明,重建图像误差系数降低至 0.025 6,相关系数提高至 0.971 7,与传统算法和 CNN 算法相比,具有更高的图像重建质量。

**关键词:**电容层析成像技术;图像处理;密集网络;注意力机制

中图分类号: TP391.4 文献标识码: A 国家标准学科分类代码: 510.4030

## Adaptive weighted multi-feature fusion ECT image reconstruction algorithm

Ma Min Gao Xiaobo

(College of Electronic Information and Automation, Civil Aviation University of China, Tianjin 300300, China)

**Abstract:** In order to solve the nonlinear ill-conditioned problem of capacitance and permittivity in electrical capacitance tomography (ECT) image reconstruction, An adaptive weighted multi-feature fusion (AWMF) ECT image reconstruction algorithm is proposed to realize the nonlinear mapping between capacitance value and dielectric constant is fitted by network model. Firstly, dense convolutional network (Densenet) is used in the network model, which not only alleviates the phenomenon of gradient disappearance, but also integrates the characteristic information of different channels. The weights of the feature channels are adjusted adaptively by squeeze excitation network (SENet) to extract the key features of the different channels to improve the accuracy of the image reconstruction. Secondly, the tree aggregation structure network (TASN) Network module is constructed to expand the receptive field and extract rich multi-scale characteristic information to eliminate artifacts brought by ordinary convolution. After modeling and simulation on COMSOL5.3, the image was reconstructed by MATLAB2014a. Experimental results show that the reconstructed image error coefficient is reduced to 0.025 6, and the correlation coefficient is up to 0.974 7. Compared with the traditional algorithm and CNN algorithm, the reconstructed image has higher quality.

**Keywords:** capacitance tomography; image processing; dense network; attentional mechanism

## 0 引言

电容层析成像技术作为一种工业层析成像技术,具有非侵入性,低成本,结构简单,安装便捷,响应速度快等优势,被广泛的应用于工业化管道内流体的实时状态和形状的过程监测。相比于传统的仪器仪表检测,电学层析成像技术具有更高的检测精度和速度,因此受到了国内外学者的广泛研究。图像重建在 ECT 中起着重要作用,而重建图

像质量决定了其是否可以在工业生产中广泛应用。由于 ECT 本身存在欠定性,病态性和非线性等问题,并且在测量过程中的噪声会对灰度值求解造成较大的干扰,影响重建结果,因此图像重建算法就显得尤其重要<sup>[1-3]</sup>。

电容层析成像图像重建算法分为迭代类和非迭代类,前者例如线性反投影算法(LBP),Tikhonov,SVD<sup>[4-5]</sup>等,而迭代类算法例如 Landweber,共轭梯度算法和牛顿迭代算法。这两类算法本质上将介质分布和电容向量之间的非线

收稿日期:2022-04-27

\* 基金项目:国家自然科学基金面上项目(61871379)资助

性关系简化为线性关系。但是多相流本身是复杂多变的,致使通过简化的线性模型算法进行的图像重建存在较大困难,会造成图像失真。有学者提出将机器学习引入到 ECT 图像重建的过程中来,通过网络模型建立电容向量和介质分布的非线性映射关系,来解决 ECT 系统的软场问题,提高重建图像的质量<sup>[6]</sup>。Liu 等<sup>[7]</sup>利用极限学习机建立灰度值和电容值的映射模型,吴新杰等<sup>[8]</sup>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,对网络进行训练并进行了图像重建。孙先亮等<sup>[9]</sup>基于数据驱动建立的卷积神经网络提高了模型的泛化能力和实用性。但是传统的神经网络如果层数过浅,则隐含层较小,网络提取的特征不充分且表达能力不足,导致重建图像的精度不高;如果层数过深,则会造成模型的退化。而周涛等<sup>[10]</sup>将密集神经网络应用于肺部肿瘤的识别,从理论上证明了密集卷积网络可以解决传统神经网络特征提取不充分,特征维度较高的问题。本文提出一种自适应加权的多特征融合网络模型,首先,在路径 1 中采用密集卷积网络(DenseNet),不仅减轻了梯度消失现象,使网络更容易训练,而且通过跳层连接将高层特征和低层特征进行融合,更好地恢复了细节信息;添加挤压激励网络(SENet)标注不同特征通道之间的权重,用以提取不同通道的关键特征,提高重建图像的精度。其次,在路径 2 构建树形聚合结构网络模块(TASN),扩大了感受野并提取丰富的多尺度信息,可以消除普通卷积所带来的伪影现象。最后,对两个路径的特征张量进行特征融合,从而表达电容张量与介电常数之间的非线性映射关系。将训练好的模型应用于 ECT 的图像重建中,通过对重建结果的定量分析表明,该方法可以较好实现 ECT 系统的图像重建。

## 1 ECT 基本原理

本文采用的 ECT 系统由三部分组成:12 电极电容传感器阵列,数据采集系统和计算机成像系统。被测管道内流动介质的分布和种类的变化会引起敏感场介电常数的变化,12 电极通过上位机的控制给定电压激励后测量不同极板之间的独立电容值,测量出的独立电容值传输至数据采集系统进行放大,滤波,解调,AD 转换后将处理好的数据传输给计算机成像系统,成像系统将电容数据通过软件和算法进行图像重建并呈现在计算机上。ECT 系统如图 1 所示。

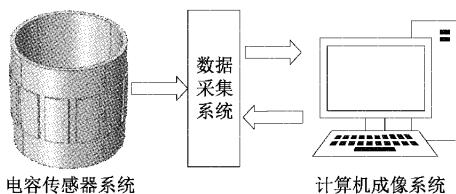


图 1 ECT 系统图

ECT 系统敏感场模型如式(1)所示。

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

式中:  $\epsilon(x,y)$  表示管道内介电常数分布函数,  $E(x,y)$  表示电场强度分布函数, 对式(1)进行离散化及线性化后, 可得式(2):

$$\lambda_{M \times 1} = S_{M \times N} G_{N \times 1} \quad (2)$$

式中:  $\lambda$  表示归一化之后的电容值,  $S$  表示灵敏度矩阵,  $G$  表示灰度值矩阵,  $M$  为 ECT 的独立测量值,  $N$  为剖分的网格数。

ECT 技术中主要研究两个数学问题: 正问题和反问题, 正问题主要研究如何在已知边界条件, 介电常数和介质分布的条件下, 求解极板之间的电容值; 反问题是基于正问题中测量的电容数据反演被测场内的介质分布, 即 ECT 图像重建问题<sup>[11-12]</sup>。

## 2 网络模型与算法

### 2.1 密集卷积网络模块

传统的卷积神经网络(convolutional neural network, CNN)由输入层, 卷积层(convolution layer), 池化层(pooling layer), 全连接层和输出层五部分组成。特征张量经输入层进入卷积层进行特征提取, 池化层将输出的特征张量进行压缩, 最后由全连接层对多维特征张量展平得到一维特征张量<sup>[13]</sup>。但是随着深度学习工作的不断推进, CNN 产生了浅层参数无法更新, 网络学习过程停滞的问题, 冗余的网络层使模型产生了退化现象。

与 CNN 的跳层连接的网络形式不同, 密集卷积网络(DenseNet)是一种具有密集连接特点的卷积神经网络<sup>[14]</sup>, 前层输出特征送到靠后的输入层不需要卷积操作, 直接作为下一层的输入。利用网络结构中浅层复杂度低和深层复杂度高的特征, 实现特征的重复利用, 弥补了传统卷积神经网络因为层数过多造成的梯度消失问题, 具有良好的抗过拟合性能, 提高了特征提取的效率。

密集卷积网络的设计核心是密集块(DenseBlock), 其中每一个 DenseBlock 模块包含批归一化(batch normalization, BN), 激活函数 RELU, 卷积(Conv)。BN 层可将训练数据集打乱, 加快训练速度, 提高模型准确度, RELU 作为神经元的激活函数, 可有效缓解梯度消失现象。密集卷积网络由于每一层网络都与之前的网络直接连接, 获得输入的特征信息, 因此对于一个 L 层的 DenseBlock, 则有  $L \times (L + 1) \div 2$  个连接, L 层的输出如式(3)所示。

$$x_L = H_L(x_0, x_1, x_2 \dots x_{L-1}) \quad (3)$$

式中:  $x_0, x_1, x_2 \dots x_{L-1}$  为第 0, 1, 2, ..., L-1 层的输出,  $(x_0, x_1, x_2 \dots x_{L-1})$  表示将第 L 层之前的所有特征张量进行拼接。 $H(\cdot)$  定义的是 BN, RELU 和卷积操作。每一层网络都包含了所有前层输出的信息, 增强了特征的流通, 因此只需要较少的参数量来训练网络。

密集卷积网络模块如图 2 所示, 由 4 个交替连接的密集块和过渡层(Transition)组成, 由于特征向量通过

DenseBlock 后输出维度增加,因此在每一个 DenseBlock 后加入网络结构为 BN+RELU+Conv+Pooling 的过渡层,过渡层可以减小特征的维度和尺寸,使特征信息在网络中快速传递,简化了计算量,同时将各个通道的特征信息进行融合。密集卷积网络模块中,特征向量通过一个 BN 层,RELU 层提取高维特征,同时使用  $1 \times 1$  的卷积层改变通道数,然后通过密集连接的方式,输出特征向量送入 Transition 层和 Pooling 层,重复四次后输出特征张量到全连接层。

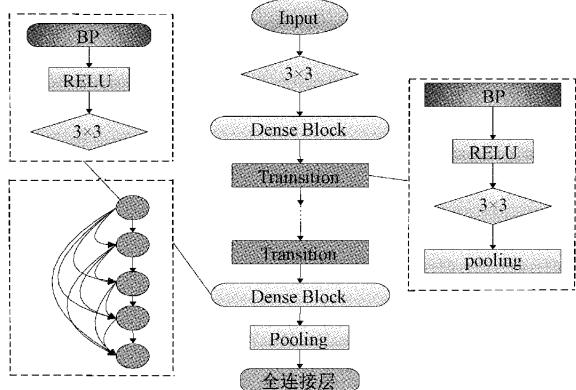


图 2 DenseNet 网络结构

## 2.2 挤压激励网络(SENet)

挤压激励网络(SENet)模块通过学习密集卷积网络中不同通道之间的权重,建立通道之间的相互依赖关系,捕捉相关性获得密集卷积网络提取不同通道特征的重要程度,以此来加强特征信息在图像重建过程中的指导作用<sup>[15]</sup>。

挤压激励网络主要由挤压(sequeeze),激励(excitation)和特征重标定(scale)组成。挤压操作通过空间维度对二维的特征通道进行压缩,形成一个具有全局感受野权重因子。具体操作是将原始输入  $W \times H \times C$  进行全局平均池化,得到一个  $1 \times 1 \times C$  大小的特征图( $C$  为通道数目, $W, H$  为输入的长和宽)。

$$Z_e = F_{sq}(u_e) = \frac{1}{H \times W} \sum_{i=1}^H \sum_{j=1}^W u_e(i, j) \quad (4)$$

式(4)中  $u_e(i, j)$  为输入数据中第  $i$  行第  $j$  列的元素。

激励操作将输出的  $1 \times 1 \times C$  特征向量经过两个全连接层(fully connected, FC)获得归一化的权重因子,然后用 sigmoid 选通机制通过权重因子来为每个特征通道生成权重。

$$s = F_{ex}(Z, W) = \sigma(g(Z, W)) = \sigma(W_2 \theta(W_1 Z)) \quad (5)$$

式中:  $\sigma(\cdot)$  和  $\theta(\cdot)$  分别表示 sigmoid 和 RELU,  $W_1$  和  $W_2$  分别为两个全连接层的参数。特征重标定操作将激励机制得到的结果作为权重,然后通过乘法运算让权重加权到原先特征上,完成在通道维度上对原始特征的重标定。

## 2.3 树形聚合结构网络模块

在图像重建任务中,融合不同尺度的特征信息是提高

图像重建质量的一个重要手段<sup>[16]</sup>。一般来说,小尺度特征分辨率更高,包含更多细节信息,但噪声较多;较大尺度特征具有更强的特征信息,但分辨率较低。基于上述矛盾,本节提出树形聚合网络结构,该网络可以在不增加参数数量和计算量的情况下引入丰富的多尺度特征信息,获得更大的感受野。本节树形聚合网络结构如图 3 中所示,输入张量经过  $1 \times 1$  卷积操作后按照通道分成 4 个特征子张量  $x_i$ ,  $x_i = \{1, 2, 3, 4\}$ , 第一个特征子张量直接输出,后 3 个都对应一个  $3 \times 3$  卷积操作,卷积操作用  $k$  表示,则  $y_i$  可以如式(6):

$$y_i = \begin{cases} x_i, & i = 1 \\ kx_i, & i = 2 \\ k(x_i + y_{i-1}), & 2 < i < 5 \end{cases} \quad (6)$$

将每个特征子张量和上个特征子张量对应的卷积输出作为该张量对应的卷积输入,然后将 4 个通道的输出进行融合。由于组合效应,网络模型中包含了大小和数量都不同的卷积核,得到多种尺度特征。此种先将通道拆分提取特征再合并的操作可以更好地利用了多特征信息,更高效的学习特征,提高图像重建的质量

## 2.4 模型构建

自适应加权的多特征融合 ECT 图像重建算法模型如图 3 所示。在路径 1 采用密集卷积网络结构,在有限的网络深度下,充分融合不同通道的特征信息,在密集卷积网络后引入挤压激励网络机制,调整特征通道的权重,用以提取不同通道的特征信息。路径 2 采用聚合树形卷积网络,通过不同大小的感受野在一定量的计算负载下提取多尺度特征信息,有效克服普通卷积带来的伪影现象,最后形成双通道多特征融合的算法模型。

## 3 实验与分析

### 3.1 评价指标

本次实验利用图像相关系数(CORR)与图像误差系数(IME)对重建图像质量进行定量分析,图像相关系数表示模型预测的介质分布与真实介质分布之间的线性相关程度,相关系数越大,则重建图像的质量越好,其数学表达式为式(7):

$$CORR = \frac{\sum_{i=1}^N (\hat{g}_i - \bar{\hat{g}})(g_i - \bar{g})}{\sqrt{\sum_{i=1}^N (\hat{g}_i - \bar{\hat{g}})^2 \sum_{i=1}^N (g_i - \bar{g})^2}} \quad (7)$$

图像相对误差为重建介质分布与真实介质分布的相对误差,误差系数越小,成像效果越好,其数学表达式如式(8):

$$IME = \frac{\|\hat{g} - \bar{\hat{g}}\|}{\|g\|} \quad (8)$$

式中:  $g$  表示仿真中设定的介电常数分布;  $\hat{g}$  表示图像重建

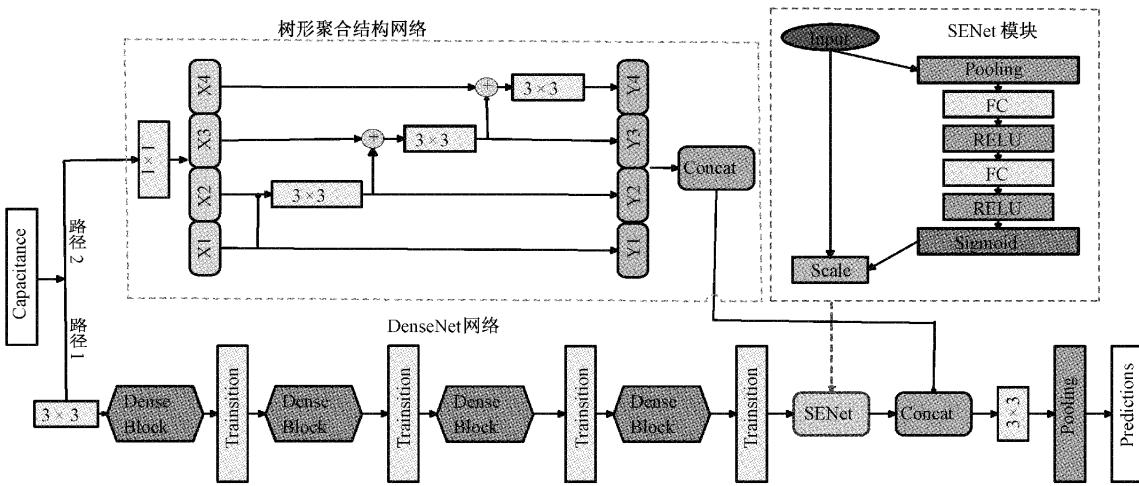


图 3 网络结构

介电常数分布,  $\bar{g}$  和  $\hat{g}$  分别为  $g$  和  $\hat{g}$  的平均值,  $N$  为有限元法剖分的数目。

### 3.2 仿真实验

本文采用的实验平台配置为 AMD R7-5800H CPU@3.2 G, GPU 为 RTX3050, Windows10 的 64 位操作系统, 运行内存容量为 16GB, 网络训练采用 Tensorflow2.1 架构。利用 COMSOL5.3 软件构建 12 阵列电极 ECT 传感器模型, 并对其进行剖分, 设定固体颗粒的参数, 通过有限元法求解的电容值和灵敏度矩阵。仿真设置电极张角为  $25.5^\circ$ , 管道内径、外径及外屏蔽层直径分别为 46、50 及 55 mm。其中管道的材料设置为塑料, 介电常数为 5.8, 空场设定为空气, 介电常数设置为 1, 被测流形用亚力克棒替代, 介电常数为 4.2。

本文选取了 6 种典型流形进行图像重建研究, 其中流形 1 至流形 4 考察算法对于简单泡状流形的重建效果, 流形 5 和流形 6 考察对于复杂流形的重建效果。为使流形样本具有随机性和代表性, 流形的位置和大小均为随机设置。每一种流形建立 2000 个样本, 共建立 12000 个样本, 计算获得每个样本的独立电容值组和介电常数分布。从每种流型样本中选取前 1990 个作为训练样本, 共计 11940 个训练样本, 其余 60 个作为测试样本。将训练样本的电容值作为网络的输入, 介质分布作为网络的输出对网络模型进行训练, 网络训练完成之后, 随机选取测试样本中的 6 种流形, 将只经过 CNN, 只经过 (DenseNet, DN), 带有 SENet 的单通道密集卷积网络模型 (dense convolution single channel network based on SENet, DS), 自适应加权的多特征融合网络模型 (adaptive weighted multi-feature fusion network, AWMF) 的结果进行预测, 并与传统算法 LBP 和牛顿迭代算法 (NM) 进行对比, 重建结果如图 4 所示。

分析实验结果可以得出, 对于设置的 6 种流形模型, 传统算法的成像精度普遍偏低, 无论是简单模型还是复杂

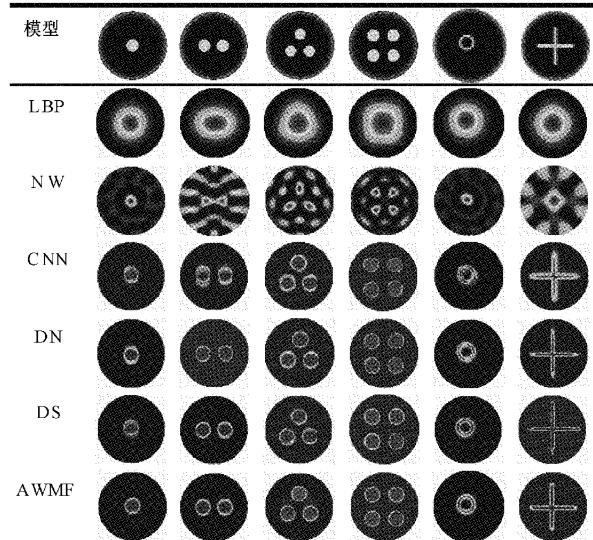


图 4 仿真实验结果

模型都有明显的伪影, 较难分辨实际分布。CNN 算法相比于传统算法有着明显的提高, 重建流形的大小和形状均与原模型非常接近, 但是对于复杂流形的重建有明显失真和残缺。DS 算法无论是流形的大小, 位置和形状, 该算法都能准确成像, 但是在边缘上会出现伪影, 对于细节的捕捉不到位。AWMF 算法所成图像无粘连, 无伪影, 接近实际分布, 无论是简单流形还是复杂流形的重建效果都优于改进前的效果, 接近实际分布。

6 种重建算法的相关系数和相对误差系数如表 1、2 所示, 可以看出 AWMF 算法的两个评价指标在各个流形的相对误差系数和图像相关系数均取得最优, 尤其在核心流这一简单流形的图像重建中, 图像相关系数提高至 0.9717, 相对误差降系数低至 0.0256。证明 AWMF 算法无论对于简单流形还是复杂流形都具有较好的反演能力。

### 3.3 抗噪性实验

ECT 系统通常应用于复杂工业环境下, 在实际工作中

表 1 图像相关系数计算值

Model	核心	双泡流	三泡	四泡	环流	十字流
LBP	0.621 9	0.571 4	0.465 7	0.354 7	0.465 6	0.488 0
NM	0.608 7	0.217 7	0.421 8	0.266 0	0.072 4	0.157 0
CNN	0.798 3	0.771 6	0.745 8	0.714 4	0.508 1	0.582 6
DN	0.825 1	0.789 4	0.811 2	0.806 4	0.764 9	0.724 1
DS	0.910 7	0.882 6	0.879 4	0.868 2	0.910 6	0.822 4
AWMF	0.971 7	0.952 0	0.968 6	0.924 4	0.932 7	0.891 9

表 2 图像误差计算值

Model	核心	双泡流	三泡	四泡	环流	十字流
LBP	0.321 3	0.448 6	0.501 3	0.554 7	0.515 6	0.508 0
NM	0.316 2	0.784 6	0.513 0	0.716 3	0.854 7	0.892 1
CNN	0.135 8	0.147 7	0.186 0	0.275 1	0.504 2	0.474 3
DN	0.122 7	0.207 8	0.154 6	0.179 0	0.274 6	0.235 4
DS	0.082 3	0.110 4	0.119 5	0.128 4	0.084 1	0.154 6
AWMF	0.025 6	0.045 2	0.034 9	0.074 2	0.054 7	0.100 5

数据采集和传输过程中易受到外界环境和自身设备的噪声干扰,导致重建精度下降,因此需进一步验证该网络的抗噪性能。抗噪性实验中,在 3 种流形的电容数据中添加 5%,10%,15%,20% 的噪声,通过加入噪声来模拟真实工作环境以探究多特征融合卷积网络算法的抗噪性能。添加不同噪声之后的成像效果如图 5 所示,重建图像的相关系数和相对误差系数如图 6、7 所示。

5% 的微弱噪声对于重建结果影响不大,图像重建整体质量与无噪声结果相似,相关系数较高。随着噪声的增加,重建图像出现了不同程度的伪影和失真现象,其中对添加噪声的十字流的重建效果影响最为明显。在 15% 的噪声干扰下十字流的图像相关系数可以达到 0.609 8,在 20% 的噪声的干扰下虽然相关系数虽然下降到 0.421 4,但仍然可以辨别十字流的位置和轮廓,表明自适应加权的多特征融合 ECT 图像重建算法具有良好的抗干扰性能。

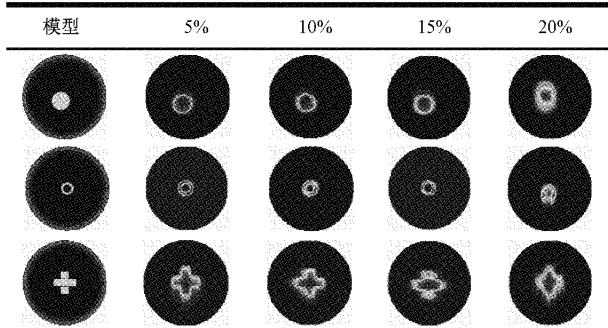


图 5 不同噪声环境下图像重建结果

### 3.4 静态实验

为了验证算法的有效性,采用天津大学的电容层析成像测量系统进行静态实验,ECT 系统如图 8 所示。传感器

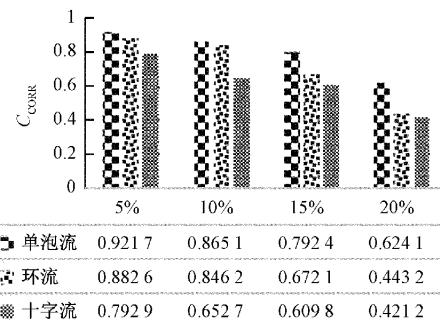


图 6 图像相关系数计算值的比较

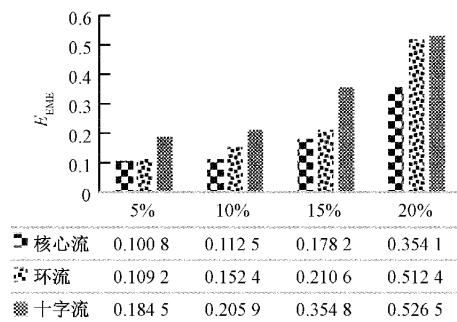


图 7 图像误差计算值的比较

为内径 10.5 cm 的圆形塑料管道,空场和满场分别标定为空气和塑料颗粒,设置了 3 种分布模型,第 1 组选取直径为 3 cm 的亚克力棒,第 2 组选取一根直径为 3 cm 和一根直径为 2 cm 的亚克力棒作为两泡流,第 3 组为层流,液面位于圆心位置。通过算法模型将采集到的电容值进行图像重建,重建结果如图 9 所示,并与 LBP 和牛顿迭代算法进行对比。

由实际成像结果分析可知,直接类算法和迭代类算法

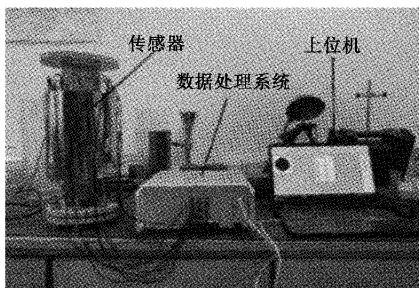


图 8 ECT 系统

在进行图像重建的时候,各种流形都会产生大量的伪影,且图像的粘连情况严重,自适应加权的多特征融合 ECT 图像重建算法的静态实验成像效果明显好于传统类算法,对于图像的细节特征捕捉较好,具有一定的实用价值。

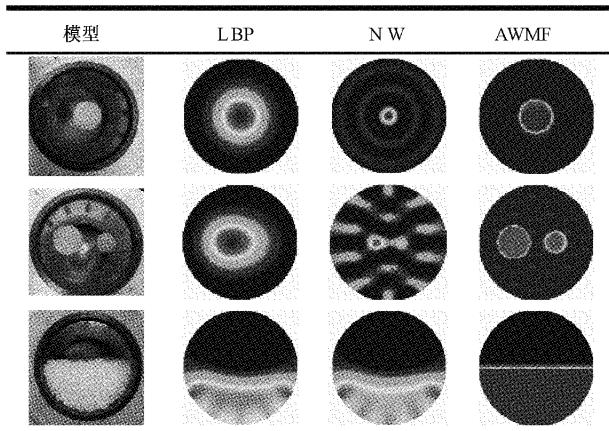


图 9 静态实验成像

#### 4 结 论

本文提出了一种基于密集卷积网络模块和聚合树形结构网络模块的双路径网络模型拟合电容张量和介电常数的非线性映射关系。将密集卷积网络和挤压激励网络结合,用于捕捉自适应调整后的高低层特征,提高图像重建精度;同时添加树形聚合网络模块提取多尺度特征信息,消除伪影现象。并通过仿真实验、抗噪性实验和静态实验验证,实验结果表明该算法对流形的重建精度较高,伪影较少,尤其对于复杂流形的位置,形状都能准确成像,且具备一定的抗噪性能,在 ECT 图像重建中具有良好的应用前景。

#### 参考文献

- [1] 王化祥. 电学层析成像技术[J]. 自动化仪表, 2017, 38(5): 1-6.
- [2] 赵玉磊, 郭宝龙, 闫允一. 电容层析成像技术的研究进展与分析[J]. 仪器仪表学报, 2012, 33(8): 1909-1920.
- [3] LU L, TONG G W, GUO G, et al. Split Bregman iteration based reconstruction algorithm for electrical capacitance tomography [J]. Transactions of the Institute of Measurement and Control, 2019, 32(7): 2389-2399.
- [4] 张立峰, 张梦涵. 基于自适应模拟退火及 LM 联合反演算法的 ECT 图像重建[J]. 仪器仪表学报, 2021, 42(12): 228-235.
- [5] 马敏, 郭琪, 闫超奇. 等 基于广义正则化的 ECT 图像重建[J], 系统仿真学报, 2017 29(8):1851-1857.
- [6] 马敏, 孙颖, 范广永. 基于深度信念网络的 ECT 图像重建算法[J]. 计量学报, 2021, 42(4): 476-482.
- [7] LIU X, WANG X X, HU H L, et al. An extrelelearning machine combined with Landweber iteration algorithm for the inverse problem of electrical capacitancetomography [J]. Flow Measurement and Instrumentation, 2015, 45(5): 348-356.
- [8] 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.
- [9] 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.
- [10] 周涛, 霍兵强, 陆惠玲, 等. 融合多尺度图像的密集神经网络肺部肿瘤识别算法[J]. 光学精密工程, 2017(29): 1696-1697.
- [11] CUI Z Q, YANG C Y, SUN B Y, et al. Liquid film thickness estimation using electrical capacitance tomography[J]. Measurement Science Review, 2014, 14(1): 8-15.
- [12] ROSA E D L, YU W. Randomized algorithms for nonlinear system identification with deep learning modification [J]. Information Sciences, 2016, 364: 197-212.
- [13] 郭蕴欣, 张越, 马宏. 基于 CNN 的数字信号调制识别研究[J]. 国外电子测量技术, 2019, 42(14): 112-116.
- [14] 杨小东, 纪国宜. 基于融合 CNN 的滚轮轴承剩余寿命预测[J]. 电子测量技术, 2021, 40(3): 62-67.
- [15] 谷峥岩, 魏利胜. 基于深度学习网络的轴承工件自动检测[J]. 电子测量与仪器学报, 2021, 35(9): 80-88.
- [16] LEI J, LIU Q B, Y X, et al. Combin ation regularization reconstruction method for electrical capacitance tomography [J]. International Journal of Intelligent Systems and Applications, 2018, 59(3): 135-146.

#### 作者简介

马敏,工学博士,教授,主要研究方向为无损检测及新型传感器技术。

E-mail: mm5739@163.com

高晓波,硕士研究生,主要研究方向为无损检测技术。

E-mail: 1978097296@qq.com