

DOI: 10.19650/j.cnki.cjsi.202311360

基于多尺度自适应特征聚合网络的 ECT 图像重建*

马敏, 梁雅蓉

(中国民航大学电子信息与自动化学院 天津 300300)

摘要:针对深层卷积神经网络在电容层析成像图像重建过程中存在电容特征提取尺度单一、中间层特征利用率不高等问题,提出了一种多尺度自适应特征聚合网络模型。首先,利用堆叠的增强型选择核卷积模块设计了一种特征增强模块(FEM),并通过串联多个FEM自适应地提取电容向量多个尺度的特征信息,极大地减少了使用普通卷积所带来的伪影现象;其次,引入了一种特征聚合机制,采用长短残差连接加强了远近特征信息的相关性,解决了网络中间层特征利用不充分的问题。实验结果表明,与传统算法及卷积神经网络算法相比,所提方法在主观视觉效果和客观评价指标上都具有更好的性能,图像相关系数最高达到0.962 9,图像相对误差降低至0.053 0。

关键词: 电容层析成像;特征增强;增强型选择核卷积;聚合机制;残差连接

中图分类号: TH878 TP391.41 **文献标识码:** A **国家标准学科分类代码:** 410.55

ECT image reconstruction based on multi-scale adaptive feature aggregation network

Ma Min, Liang Yarong

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

Abstract: To address the problems of single capacitance feature extraction scale and low utilization of intermediate layer features in the image reconstruction process of electrical capacitance tomography based on deep convolution neural network, a multi-scale adaptive feature aggregation network model is proposed for electrical capacitance tomography image reconstruction. Firstly, a feature enhancement module (FEM) is designed by using stacked enhanced selection kernel convolutional module, which adaptively extracts feature information from multiple scales of the capacitance vector by concatenating multiple FEM. The artifacts caused by using ordinary convolution is reduced. Secondly, a feature aggregation mechanism is introduced, which uses long and short residual connections to enhance the correlation of far and near feature information. The problem of insufficient utilization of middle layer features in the network is solved. Compared with traditional algorithms and CNN algorithm, the experimental results show that the proposed method has better performance in subjective visual effects and objective evaluation indicators, with the highest image correlation coefficient reaching 0.962 9 and the relative error of the image reduced to 0.053 0.

Keywords: electrical capacitance tomography; feature enhancement; enhanced selection kernel convolution; aggregation mechanism; residual connection

0 引言

在过程层析成像(process tomography, PT)领域,把一个混合物系统中同一成份和特性的物质称为相,根据状态的不同,相被分为气体相、固体相和液体相^[1]。层析

成像系统就是通过测量特征物理量,利用一定的物理规律和相关成像算法,将一个混合相系统的某个流经截面进行实时成像。电容层析成像技术(electrical capacitance tomography, ECT)作为PT技术的一个重要分支,主要用于对两相流和多相流进行测量和成像,该技术以其成本低、非侵入性和便捷的操作方式成为无损检测领域的研

收稿日期:2023-04-26 Received Date: 2023-04-26

* 基金项目:国家自然科学基金(61871379)、天津市教委科研计划(2020KJ012)项目资助

究热点^[2]。由于 ECT 技术所检测的区域属于“软场”,信号质量优劣直接受介质分布的影响,二者之间包含复杂的非线性关系^[3],同时 ECT 的逆问题属于典型的病态问题、欠定性问题,因此图像重建算法在 ECT 中显得尤为重要^[4]。

传统算法主要将非线性问题线性化处理或者采用局部优化的非线性处理办法,两种方式都会使图像失真程度较大^[5]。Marashdeh 等^[6]就致力于将神经网络与 ECT 图像重建相结合,并取得了一定的研究进展。吴新杰等^[7]将 Landweber 算法的图像重建结果作为初始状态,训练二维卷积神经网络(2D-CNN)并进行图像重建。孙先亮等^[8]提出一种一维卷积神经网络(1D-CNN)的 ECT 重建方法,利用一维卷积提取数据特征,并在流化床实验中得到了有效性验证,进一步说明神经网络与 ECT 技术结合的可行性。但是神经网络层数过浅时,隐层结点数过少,往往出现网络表达能力不足的情况;反之,若层数过深,则隐层结点数过多,不仅会增加网络的复杂性,在学习过程中也更易陷入局部极小点,进而造成模型退化,而且会使网络学习速度变慢。因此隐层结点数选择的问题一直受到高度重视。而 He 等^[9]在 2015 年提出的深度残差学习架构不仅解决了深层网络的退化问题,同时提升了准确率,简化了深层网络的训练。陆永帅等^[10]利用深度网络提取霍光谱曲线特征,再使用残差学习等方法降低网络训练难度,得到了霍监测模型。全卫国等^[11]将深度残差神经网络用于电阻层析成像,结合深度残差网络思想提出 h-Net 实现了成像及流型辨识的需求。不同于残差网络(ResNet)中的跳跃连接方式,DenseNet^[12]的一大特色是通过特征在通道上的连接来实现特征重用,使网络的参数和计算成本更少。程德强等^[13]在残差模块间采用密集特征融合结构将特征信息充分融合,克服了特征信息利用率低的问题。

虽然以上算法有较好的性能,但目前大多数仍存在如下问题:1)盲目增加网络深度导致参数量过大,增加了训练难度;2)多使用单一尺度的卷积核构建网络,限制了局部感受野作用的范围,导致特征提取不充分^[14];3)无法自适应捕获多尺度信息。基于以上问题,本文提出了一种多尺度自适应特征聚合网络(multi-scale adaptive feature aggregation network, MAFAN)模型。首先,核心模块采用增强型选择核卷积模块(enhanced selective kernel convolution module, ESKM),使网络能够动态调整感受野大小,增强表征能力;其次受跳跃连接^[15-16]的启发,设计了一种聚合机制(aggregation mechanism, AM),采用长短残差相结合的方式充分利用中间层的特征,最后在网络末端将提取到的特征信息充分融合。

1 ECT 系统基本原理

电容层析成像系统主要包括电容传感器系统、数据采集系统、计算机成像系统 3 个部分,如图 1 所示。其中,电容传感器系统主要负责测得场域内不同介质分布状态的边界信息;数据采集系统将采集到的电容值转化为电信号;计算机成像系统通过重构算法利用采集到的电容值反演被测场域内介质的分布状况^[17]。




图 1 ECT 系统

Fig. 1 ECT system

ECT 中主要研究两个数学问题,即正问题与反问题。正问题可归结为已知边界条件、介电常数分布的条件下,求解极板之间的电容值;反问题是指基于正问题中测量的电容数据反演介质在场中的分布,即 ECT 图像重建问题^[18]。

将电容值与介电常数分布的非线性关系离散归一化,得到近似线性的逆问题模型为:

$$C = SG \quad (1)$$

式中: C 为电容值, $C \in R^{n \times 1}$; S 为灵敏度矩阵, $S \in R^{n \times m}$; G 为介电常数, $G \in R^{m \times 1}$; n 为电极的对数; m 为剖分的网格数目。电容层析成像的最终目的是求解得到介电常数 G 。

2 网络模型

多尺度自适应特征聚合网络模型由 3 部分组成,即浅层特征提取模块、深层特征提取模块和重建模块。将 66×1 的电容向量输入到浅层特征提取模块,该模块由一个卷积层与池化层组成。深层特征提取模块由多个特征增强模块(feature enhancement module, FEM)及 AM 组成, FEM 用于提取多个尺度的电容信息, AM 用以聚合多层次特征输出。重建模块由下采样层与两个普通卷积层组成,以对提取到的特征进行信息重组并重建出质量较高的图像。网络的整体结构如图 2 所示。

2.1 浅层特征提取模块

所提模型的特征提取过程分为浅层特征提取和深层特征提取两个阶段,如图 3 所示。首先,采用 1×3 卷积模




图2 MAFAN 网络结构

Fig. 2 Structure of MAFAN network

块提取图像浅层特征。输入电容向量 F_s ，进行 64 个通道的 1×3 卷积，即：

$$F_{s1} = \text{Conv1} \times 3, 64(F_s) \quad (2)$$

式中： F_s 代表 66×1 的电容向量； F_{s1} 代表经过卷积操作后的电容特征图； $\text{Conv}(\cdot)$ 代表卷积操作。卷积后接最大池化操作，其目的在于保留原特征的同时减少网络中的参数，表示为：

$$F_{s2} = \text{maxpooling}_{1 \times 3}(F_{s1}) \quad (3)$$

式中： F_{s2} 代表经过最大池化操作后的电容特征图； $\text{maxpooling}(\cdot)$ 代表最大池化操作。输入的电容量经浅层网络处理后得到的输出为 22×64 。

2.2 深层特征提取模块

在特征信息输入深层网络之前先将浅层输出的 1 维特征进行维度扩张，得到的特征图尺寸为 $22 \times 1 \times 64$ 。深层特征提取模块由 k 个 FEM 组成，如图 3 所示。将每一个 FEM 的输出特征聚合在深层网络末端，此外，通过一个长残差连接将浅层网络的输出特征直接输入到网络的重建部分，因为浅层网络提取的信息包含很多的原始信息，可以辅助重建出被忽略的细节部分。每个 FEM 包含两个 ESKM，其内部的短残差连接在一定程度上减少了特征信息的丢失，从而保证提取更高质量的深层特征。




图3 深层特征提取模块结构

Fig. 3 Structure of deep feature extraction module

1) 增强型选择核卷积模块

Li 等^[19] 设计的选择性核 (selective kernel convolution, SK) 卷积，可以从通道维度自适应地选择不同尺度上有用的全局特征信息，如图 4 所示。在其基础上，ESKM 引入了局部注意块，从而可以在全局和局部角度同时校准不同感受野下的特征，解决了无法自适应提取电容多尺度特征信息的问题^[20]。




图4 SK 模块结构

Fig. 4 Structure of SK module

ESKM 结构如图 5 所示。该模块由 3 个部分组成，即不同核大小的多尺度卷积模块、全局注意模块和局部注意模块。首先，将中间特征映射 F 进行两个并行卷积操作，即 3×3 的卷积和 3×3 的扩张卷积，扩张卷积的扩张率为 2。由两个卷积运算捕获的特征图为：

$$F_1 = W_{3 \times 3} \times F \quad (4)$$

$$F_2 = W_{3 \times 3, 2} \times F \quad (5)$$

式中： F 表示给定的中间特征图； $W_{3 \times 3}$ 和 $W_{3 \times 3, 2}$ 分别表示 3×3 卷积矩阵和 3×3 扩张卷积矩阵； F_1 、 F_2 分别为 3×3 卷积和 3×3 扩张卷积捕获的特征图。随后， F_1 和 F_2 沿通道维度整合，并输入到全局注意模块和局部注意模




图5 ESKM 结构

Fig. 5 Structure of ESKM

块。合并后的特征图 F_M 可表示为:

$$F_M = F_1 \oplus F_2 \quad (6)$$

式中: $\oplus$ 表示元素相加。最后, 将全局注意模块与局部注意模块获得的特征图与输入特征图 F 融合, 得到一组新的特征图 F_{CS} 为:

$$F_{CS} = F \oplus (LAM(F_M) \oplus GAM(F_M)) \quad (7)$$

式中: $LAM(\cdot)$ 和 $GAM(\cdot)$ 分别表示局部注意模块和全局注意模块。

2) 全局注意模块

所引入的 ESKM 中使用的全局注意与 SK 模块中的通道注意相同, 如图 5 所示。其主要目的是通过网络计算出各个通道的权重, 筛选出更多有用的特征。首先通过全局平均池化 (global average pooling, GAP) 操作来获得通道方面的信息, 得到的特征可以表示为:

$$S_C = GAP(F_M) = \frac{1}{H \times W} \sum_{i=1}^H \sum_{j=1}^W F_M(i, j) \quad (8)$$

然后将 S_C 输入到全连接层, 再经批归一化层和 ReLU 层, 生成一组新的特征 Y_C , 可表示为:

$$Y_C = \delta_r(B(W_{fc} \cdot S_C)) \quad (9)$$

式中: W_{fc} 表示全连接 (FC) 层的矩阵, 矩阵维数的大小为 t ; $B(\cdot)$ 表示批处理归一化操作; $\delta_r(\cdot)$ 表示 ReLU 激活操作; Y_C 再进行一个全连接操作得到新的特征图。

$$Y = W_{fc} \cdot Y_C \quad (10)$$

最后, Y 通过 sigmoid 激活函数, 得到全局注意图:

$$\beta = \sigma_s(Y) \quad (11)$$

将 $\beta \in [0, 1]$ 作为 F_1 的全局注意图, 将 $1 - \beta \in [0, 1]$ 作为 F_2 的全局注意图。 F_1 和 F_2 通过全局激活图校准后得到的特征图为:

$$F_{C1} = \beta \cdot F_1 \quad (12)$$

$$F_{C2} = (1 - \beta) \cdot F_2 \quad (13)$$

式中: F_{C1} 、 F_{C2} 为全局注意模块的最终输出。在全局特征校准过程中, 将全局激活图重塑为与校准特征图相同的维度。

3) 局部注意模块

Woo 等^[21]指出, 提取有用的特征同时在通道和空间的角度进行校准操作更有益。引入的 ESKM 在原 SK 模块中加入局部注意机制, 对局部特征进行校准。其中, 特征图 F_M 经过 ReLU 激活、 1×1 卷积运算和 Sigmoid 激活, 得到局部注意图:

$$\alpha = \sigma_s(W \cdot \delta_r(F_M)) \quad (14)$$

式中: $\delta_r(\cdot)$ 和 $\sigma_s(\cdot)$ 分别代表 ReLU 激活操作和 sigmoid 激活操作; W 表示 1×1 卷积的矩阵。将 α 作为 F_1 的局部注意图, 将 $1 - \alpha$ 作为 F_2 的局部注意图。 F_1 和 F_2 通过局部激活图校准后得到的特征图为:

$$F_{S1} = \alpha \cdot F_1 \quad (15)$$

$$F_{S2} = (1 - \alpha) \cdot F_2 \quad (16)$$

式中: F_{S1} 、 F_{S2} 为局部注意模块的最终输出。在局部特征校准过程中, 将局部激活图重塑为与校准特征图相同的维度。最后将校准后的特征图与输入的特征图融合并输入到下一阶段, 此操作可表示为:

$$F_{CS} = F \oplus F_{C1} \oplus F_{C2} \oplus F_{S1} \oplus F_{S2} \quad (17)$$

式中: F_{CS} 为经过 ESKM 的特征图。

4) 聚合机制

深层特征提取模块的末端设置了特征聚合机制, 从图 3 可以看出, 首先在 FEM 内部引入了一种弱密集连接^[22], 将 FEM 中堆叠的 ESKM 的输出特征聚合在一起, 再通过 1×1 卷积核得到 FEM 的输出特征图。该过程可以表示为:

$$F_{d'}^k = A_{Concat}(F_{CS}^{k1}, F_{CS}^{k2}) \quad (18)$$

$$F_d^k = Conv_{1 \times 1, 64}(F_{d'}^k) \quad (19)$$

式中: k 代表 FEM 的个数; F_{CS}^{k1} 代表经过第 k 个 FEM 中第 1 个 ESKM 后的特征图; F_{CS}^{k2} 代表经过第 k 个 FEM 中第 2 个 ESKM 后的特征图; $F_{d'}^k$ 代表两个 ESKM 的融合输出特征图; F_d^k 代表 $F_{d'}^k$ 经过 1×1 卷积核后的特征图, 目的在于通过跨通道特征整合不仅可以获得丰富的特征信息, 还可以减少参数; $A_{Concat}(\cdot)$ 代表特征融合操作; $Conv(\cdot)$ 代表卷积操作。最后将每一个 FEM 的输出特征及浅层网络输出特征聚合在深层网络末端, 聚合过程可表示为:

$$F_R = B_{Concat}(F_{S2}, F_d^1, \dots, F_d^{k-1}, F_d^k) \quad (20)$$

式中: $F_d^1, \dots, F_d^{k-1}, F_d^k$ 分别代表第 k 个 FEM 输出的特征图; F_{S2} 代表浅层网络输出的特征图; F_R 代表深层网络最终输出的特征融合图; $B_{Concat}(\cdot)$ 代表特征融合。融合后的输出为 $22 \times 1 \times 64$ 的 2 维特征, 将其进行维度压缩恢复为 22×64 的 1 维特征后再输入到重建模块。

2.3 重建模块

图像重建模块由上采样层和重建层组成, 如图 1 所示。上采样操作将提取到的特征进行放大, 重建层包含两个普通卷积层。先将深层网络输出的特征图进行上采样操作, 所得到的特征图为 F_{R1} , 可表示为:

$$F_{R1} = Upsampling_{1 \times 3}(F_{S1}) \quad (21)$$

式中: F_{R1} 代表经过上采样操作后的特征图; Upsampling $(\cdot)$ 代表上采样操作。再进行两次卷积操作, 分别得到特征图 F_{R2} 、 F_{R3} 为:

$$F_{R2} = Conv_{1 \times 3, 128}(F_{R1}) \quad (22)$$

$$F_{R3} = Conv_{1 \times 3, 64}(F_{R2}) \quad (23)$$

式中: F_{R2} 、 F_{R3} 分别代表经过卷积操作后的特征图; $Conv(\cdot)$ 代表卷积操作。 F_{R3} 再经全局平均池化层、全连接层处理后完成重建过程。

3 实验结果及分析

3.1 实验细节

使用基于 NVIDIA GeForce RTX3050 的 Tensorflow GPU 环境加速训练,选择优化器为 Adam。选用均方误差(MSE)作为本文模型的损失函数:

$$loss = \frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2 \quad (24)$$

式中: y_i 与 $\hat{y}_i$ 分别代表样本输入的实际值与通过训练网络得出的预测值。由于一些神经网络的激活函数的值域有其区间的要求,因此对输入数据归一化就显得尤为重要,本文也选择归一化操作进行数据预处理。此外,为确定 FEM 的数量,在其他参数固定的情况下通过比较不同 FEM 数量下网络的损失值变化以及模型大小,最终选择 FEM 数量为 3。

对于具有监督学习的神经网络,数据集的质量对其性能起着重要的作用^[23]。ECT 系统很难获得足够样本来满足训练要求,因此本文利用 Comsol 建模联用 MATLAB 编写程序对 ECT 正问题进行求解得到仿真数据集。采用 Comsol 软件建立 12 电极管道截面模型,标定模型材料相对介电常数:空气场为 1;塑料管壁为 5.8;铜质电极及屏蔽罩为 2.2;被测物为 4.2;剖分网格数为 3 228。选取单泡流、双泡流、三泡流、四泡流、平行四边形、十字流、扇形流与环流 8 种流型进行研究。为使流型样本具有随机性和代表性,流型位置和大小均为随机设置,获得 8 种流型共计 14 500 个样本,其中 13 300 个作训练样本,其余 1 200 个作测试样本。

3.2 评价指标

为定量分析本文模型对于 ECT 图像重建的成像效果,选取图像相关系数(correlation coefficient, CORR)、图像相对误差(image relative error, IME)作为网络成像质量评价指标。CORR 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,成像效果越好,其计算公式如下:

$$CORR = \frac{\sum_{i=1}^m (\hat{G}_i - \bar{\hat{G}})(G_i - \bar{G})}{\sqrt{\sum_{i=1}^m (\hat{G}_i - \bar{\hat{G}})^2 \sum_{i=1}^m (G_i - \bar{G})^2}} \quad (25)$$

IME 为重建介质分布与真实介质分布的相对误差,相对误差越小,重建图像的质量越好,其计算公式下:

$$IME = \frac{\|\hat{G} - G\|}{\|G\|} \quad (26)$$

式中: G 表示仿真设定的介电常数分布; $\hat{G}$ 表示图像重建介电常数分布, $\bar{G}$ 、 $\bar{\hat{G}}$ 分别为 G 、 $\hat{G}$ 的平均值; m 为有限元法剖分数目。

3.3 仿真实验

对模型进行训练后,随机在测试集中选取以下流型进行图像重建。除 MAFAN 方法还设计了另外几个用于 ECT 图像重建的网络,以比较 ESKM 结构的优势和 AM 的有效性。所采用的 CNN 是将所提网络中的 ESKM 替换为普通卷积且不含 AM;多尺度自适应网络(multi-scale adaptive network, MAN)仅不含 AM,对比 CNN 以验证 ESKM 的作用;深层卷积聚合网络(deep convolutional aggregation network, DCAN)仅替换 ESKM 为普通卷积,对比 CNN 以验证 AM 的作用。此外,基于 SKNet 的聚合网络(aggregation network based on SKNet, SKAN)是将原始 MAFAN 中的 ESKM 替换为 SK 模块,以验证混合注意的作用。同时还比较了两种传统算法即 Tikhonov 正则化算法、Landweber 算法的重建结果。不同算法的成像结果如图 6 所示。

由图 6 可知,无论是简单流型还是复杂流型,神经网络算法的成像结果明显优于传统算法。具体来说, CNN 成像效果相比于传统算法有明显的提高,不仅可以识别流型类别且重建流型的大小和形状与标准流型均比较接近,但部分重建流型存在失真和残缺现象;MAN 与 DCAN 算法成像结果较 CNN 有所改善,但是边缘伪影仍较多且扇形存在重建不完整的情况;SKAN 算法对以上流型基本都能准确成像且伪影明显减少,但对流型边缘部分细节捕捉不足;而 MAFAN 算法比 SKAN 算法更关注细节,对流型的“边、角、弧”都能很好地重建,且伪影更少,更接近实际分布。不同算法的 CORR 与 IME 如表 1、2 所示,可以看出 MAFAN 算法的两个评价指标皆为最优。其中,对简单流型重建的 CORR 均在 0.92 以上,最高达 0.962 9,相应的 IME 降低至 0.053 0;在复杂流型重建中,尤其是平行四边形,其 CORR 提高至 0.931 3。以上数据进一步表明了 MAFAN 算法的有效性。

3.4 加噪实验

将信噪比为 20、30、40 dB 的高斯白噪声添加到测试集的电容数据中以测试网络的抗噪性能。两个网络的加噪成像结果及 CORR 分别如图 7、8 所示。其中流型 1~4 分别为双泡流、三泡流、十字流和环流。分析结果可知,与 SKAN 算法相比,MAFAN 算法的重建图像与 CORR 在不同的噪声水平下具有更好的表现。在 MAFAN 算法的结果中,当信噪比为 40 dB 时,各流型的 CORR 都较高,均在 0.8 以上。随着噪声的增加,成像效果变差。




图 6 仿真实验成像结果

Fig. 6 Imaging results of simulation experiment

表 1 仿真实验图像相关系数

Table 1 CORR of simulation experiment

流型	Tikhonov	Landweber	CNN	MAN	DCAN	SKAN	MAFAN
1	0.788 1	0.732 6	0.816 2	0.840 1	0.895 4	0.933 3	0.962 9
2	0.705 1	0.685 2	0.798 8	0.871 2	0.843 9	0.907 1	0.947 5
3	0.441 4	0.443 1	0.788 1	0.846 2	0.859 2	0.886 3	0.928 4
4	0.465 8	0.529 4	0.779 5	0.841 8	0.873 2	0.896 1	0.935 2
5	0.572 3	0.606 5	0.814 0	0.870 7	0.869 9	0.903 4	0.931 3
6	0.366 6	0.556 1	0.779 6	0.820 6	0.848 9	0.856 5	0.899 6
7	0.686 1	0.714 6	0.794 9	0.835 6	0.861 4	0.891 5	0.919 2

表 2 仿真实验图像相对误差

Table 2 IME of simulation experiment

流型	Tikhonov	Landweber	CNN	MAN	DCAN	SKAN	MAFAN
1	0.409 1	0.525 6	0.360 2	0.312 8	0.144 6	0.080 2	0.053 0
2	0.487 4	0.521 8	0.404 0	0.271 3	0.257 2	0.126 7	0.083 1
3	0.751 2	0.766 7	0.383 9	0.256 1	0.179 1	0.149 0	0.119 1
4	0.754 5	0.586 3	0.453 8	0.257 9	0.161 5	0.141 5	0.093 7
5	0.533 1	0.459 9	0.390 4	0.175 0	0.175 2	0.123 7	0.100 5
6	0.781 3	0.655 7	0.421 6	0.324 3	0.288 4	0.202 6	0.139 8
7	0.539 3	0.354 5	0.374 5	0.294 9	0.186 6	0.157 8	0.124 7




图 7 MAFAN 算法在不同噪声下的成像结果及 $CORR$
Fig. 7 Imaging results and $CORR$ of MAFAN algorithm under different noises




图 8 SKAN 算法在不同噪声下的成像结果及 $CORR$
Fig. 8 Imaging results and $CORR$ of SKAN algorithm under different noises

当信噪比为 20 dB 时,重建图像伪影增多,但与 SKAN 算法相比,MAFAN 算法对复杂的几何形状具有更好的边缘保留能力。实验证明 MAFAN 算法在不同噪声环境下具备良好的抗噪声能力。

3.5 静态实验

为验证算法在 ECT 中的实际应用效果,采用天津大学研制的 12 电极 ECT 数据采集系统进行静态实验,ECT 系统如图 9 所示。将亚克力棒作为被检测对象,空场和满场分别标定为空气和塑料颗粒,设置了 5 种分布模型,第 1、2 种模型分别选取 1 根直径为 30 与 20 mm 的亚克力棒作为单泡流;第 3 种模型选取 2 根直径为 20 mm 的亚克力棒作为双泡流;第 4 种模型选取 3 根直径为 30 mm 的亚克力棒作为三泡流;第 5 种模型选取厚度为 15 mm 的环流。将采集到的电容值通过以下算法进行重建,重建结果与各算法平均成像时间如图 10、表 3 所示。




图 9 ECT 系统
Fig. 9 ECT system




图 10 静态实验成像结果
Fig. 10 Imaging results of static experiments

表 3 各算法平均成像时间			
Table 3 Average imaging time of each algorithm			
算法	Tikhonov	Landweber	MAFAN
平均成像时间/s	0.593 6	0.293 1	0.523 2

分析结果可知,Tikhonov 算法和 Landweber 算法所成图像的伪影较大,粘连现象明显;MAFAN 算法成像效果明显改善,在不同流型中均呈现出较为优质的图像。在成像时间方面,Landweber 算法平均成像时间最短,MAFAN 算法与 Tikhonov 算法平均成像时间接近,均在 0.6 s 以下。虽然 MAFAN 算法可满足实时成像,但重建时间还可进一步优化。实验结果证明,多尺度自适应特征聚合网络 ECT 图像重建算法具备一定实用性。

4 结 论

本文提出了一种多尺度自适应特征聚合网络模型来拟合电容和介电常数的非线性映射关系,通过堆叠特征增强模块、设计特征聚合机制克服了特征提取尺度单一、特征信息利用率低等问题。核心部分采用了一种增强型选择核卷积模块用以引导网络自适应地选择有用的电容特征,减少重建伪影;同时在网络末端引入聚合机制,充分利用了各模块的特征信息,提高重建精度。并通过仿真实验、加噪实验以及静态实验进行验证,实验表明所提方法在客观指标上明显优于其他方法;在主观视觉上,也表现出较好的重建效果,重建图像伪影较少,重建精度较高,且具备一定的抗噪性与实时性,是一种有效的 ECT 图像重建方法。

参考文献

[1] 周云龙,高云鹏,衣得武. ECT 系统高速数据采集电路的实现[J]. 化工自动化及仪表, 2010, 37(11): 63-65.

ZHOU Y L, GAO Y P, YI D W. Implementation of high-speed data acquisition circuit for ECT system [J]. Chemical Automation and Instrumentation, 2010, 37(11): 63-65.

[2] LIU S, WANG H G, JIANG F, et al. A new image reconstruction method fortomographic investigation of fluidized beds [J]. AIChE Journal, 2002, 48(8): 1631-1638.

[3] REINECKE N, MEWES D. Recent developments and industrial research application of capacitance tomography[J]. Measurement Science and Technology, 1996, 7(3): 325-327.

[4] 刘石,雷兢,李志宏. 基于改进正则法的 ECT 图像重建算法[J]. 仪器仪表学报, 2007(11): 1977-1981.

LIU SH, LEI J, LI ZH H. ECT image reconstruction algorithm based on improved regularization method[J]. Chinese Journal of Scientific Instrument, 2007(11): 1977-1981.

[5] 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.

MA M, SUN Y, FAN G Y. ECT image reconstruction algorithm based on deep belief network[J]. Journal of Metrology, 2021, 42(4): 476-482.

[6] MARASHDEH Q, WARSITO W, FAN L S, et al. Nonlinear forward problem solution for electric al capacitance tomography using feed-forward neural network[J]. IEEE Sensors Journal, 2006, 6(2): 441-449.

[7] 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 X J, LI H Y, LIANG N N. Application of convolutional neural networks in ECT image reconstruction[J]. Journal of Liaoning University, 2018, 45(1): 29-33.

[8] 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 X L, LI J, HAN ZH ZH, et al. Data driven convolutional neural network capacitance tomography image reconstruction [J]. Journal of Chemical Engineering, 2020, 71(5): 2004-2016.

[9] HE K M, ZHANG X Y, REN S Q, et al. Deep residual learning for image recognition[C]. IEEE Conference on Computer Vision and Pattern Recognition, IEEE, 2016.

[10] 陆永帅,李元祥,刘波,等. 基于深度残差网络的高光谱遥感数据霾监测[J]. 光学学报, 2017, 37(11): 314-324.

LU Y SH, LI Y X, LIU B, et al. Haze monitoring of hyperspectral remote sensing data based on deep residual network [J]. Journal of Optics, 2017, 37(11): 314-324.

[11] 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]. 系统仿真学报, 2022, 34(9): 2028-2036.

TONG W G, ZENG SH CH, ZHANG L F, et al. Electrical resistance tomography and flow pattern identification method based on deep residual neural network [J]. Journal of System Simulation, 2022, 34(9): 2028-2036.

[12] HUANG G, LIU Z, MAATEN L, et al. Densely connected convolutional networks[C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2017.

[13] 程德强,赵佳敏,寇旗旗,等. 多尺度密集特征融合的图像超分辨率重建[J]. 光学 精密工程, 2022, 30(20): 2489-2500.

CHENG D Q, ZHAO J M, KOU Q Q, et al. Image

- super-resolution reconstruction using multi-scale dense feature fusion[J]. Optical Precision Engineering, 2022, 30(20): 2489-2500.
- [14] 许娇, 袁三男. 增强型多尺度残差网络的图像超分辨率重建算法[J]. 激光与光电子学进展, 2023, 60(4): 296-304.
- XU J, YUAN S N. Image super-resolution reconstruction algorithm for enhanced multi-scale residual networks[J]. Progress in Laser and Optoelectronics, 2023, 60(4): 296-304.
- [15] 周露珊, 赵磊, 李恒, 等. 基于轻量级密集残差网络的水下图像增强[J]. 电子测量与仪器学报, 2023, 37(1): 70-77.
- ZHOU L SH, ZHAO L, LI H, et al. Underwater image enhancement based on lightweight dense residual networks[J]. Journal of Electronic Measurement and Instrumentation, 2023, 37(1): 70-77.
- [16] 申利华, 李波. 基于特征金字塔网络和密集网络的肺部 CT 图像超分辨率重建[J]. 计算机应用, 2023, 43(5): 1612-1619.
- SHEN L H, LI B. Super-resolution reconstruction of lung CT images based on feature pyramid networks and dense networks[J]. Computer Applications, 2023, 43(5): 1612-1619.
- [17] 马敏, 张彩霞, 陆成超, 等. 基于小波变换的 ECT 图像处理[J]. 中南大学学报, 2016, 47(6): 1947-1952.
- MA M, ZHANG C X, LU CH CH, et al. ECT image processing based on wavelet transform[J]. Journal of Central South University, 2016, 47(6): 1947-1952.
- [18] 王化祥. 电学层析成像技术[J]. 自动化仪表, 2017, 38(5): 1-6.
- WANG H X. Electrical tomography imaging technology[J]. Automation Instrumentation, 2017, 38(5): 1-6.
- [19] LI X, WANG W H, HU X L, et al. Selective kernel networks[C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2019: 510-519.
- [20] CHEN G P, DAI Y, ZHANG J, et al. AAU-net: An adaptive attention U-net for breast lesions segmentation in ultrasound images[J]. IEEE Transactions on Medical Imaging, 2022, DOI:10.1109/TMI.2022.3226268.
- [21] WOO S, PARK J, LEE J Y, et al. CBAM: Convolutional block attention module[C]. Proceedings of the European Conference on Computer Vision (ECCV), 2018.
- [22] TONG T, LI G, LIU X J, et al. Image super-resolution using dense skip connections[C]. Proceedings of the IEEE International Conference on Computer Vision, 2017: 4809-4817.
- [23] GNAYDN H M, DOAN S Z. A neural network approach for early cost estimation of structural systems of buildings[J]. International Journal of Project Management, 2004, 22(7): 595-602.

作者简介



马敏, 1993 年于郑州大学获得学士学位, 2003 年于天津大学获得硕士学位, 2007 年于天津大学获得博士学位, 现为中国民航大学教授, 主要研究方向为无损检测及新型传感器技术。

E-mail: mm5739@163.com

Ma Min received her B. Sc. degree from Zhengzhou University in 1993, received her M. Sc. degree from Tianjin University in 2003, and received her Ph. D. degree from Tianjin University in 2007. She is currently a professor at Civil Aviation University of China. Her main research interests include nondestructive testing and technology of new sensor.



梁雅蓉 (通信作者), 2021 年于中北大学获得学士学位, 现为中国民航大学硕士研究生, 主要研究方向为电学层析成像技术。

E-mail: liangyarong0107@163.com

Liang Yarong (Corresponding author) received her B. Sc. degree from North University of China in 2021. She is currently a M. Sc. candidate at Civil Aviation University of China. Her main research interest is electrical tomography technology.