

DOI: 10.19650/j.cnki.cjsi.J2107976

模型参数对卷积神经网络电容层析成像图像重建的影响*

汤政^{1,2,3}, 雷刚³, 王天祥³, 李健², 许传龙²

(1. 航天低温推进剂国家重点实验室东南大学基地 南京 210096; 2. 东南大学能源与环境学院火电机组振动国家工程研究中心 南京 210096; 3. 航天低温推进剂国家重点实验室 北京 100028)

摘要:卷积神经网络凭借其较强的非线性拟合能力,在电容层析成像图像重建中逐渐得到应用。本文针对卷积神经网络模型超参数调节问题,研究了模型参数对卷积神经网络电容层析成像图像重建的影响。首先,通过数值方法构建了包含80 000组随机流型与40 000组典型流型的“电容矩阵-介质分布”数据集;然后,通过该数据集中的训练集对不同超参数的卷积神经网络模型进行训练和验证,并系统研究了网络初始化、网格密度、卷积核数、全连接层神经元数以及隐藏层结构等超参数对图像重建精度的影响;接着,利用额外生成的12 000组数据作为测试集对各网络模型性能进行评价;最后通过静态实验,对不同网络模型的图像重建效果进行了比较和分析。结果表明:网络隐藏层结构对图像重建精度影响较大,而网络初始化、网格密度、卷积核数以及全连接层神经元数等超参数对重建精度影响较小。

关键词:电容层析成像;图像重建;卷积神经网络;模型超参数

中图分类号: TK313 TH816 **文献标识码:** A **国家标准学科分类代码:** 480.30

Effects of model parameters on image reconstruction of convolutional neural network electrical capacitance tomography

Tang Zheng^{1,2,3}, Lei Gang³, Wang Tianxiang³, Li Jian², Xu Chuanlong²

(1. State Key Laboratory of Technologies in Space Cryogenic Propellants-SEU Research Center, Nanjing 210096, China;
2. National Engineering Research Center of Turbo-Generator Vibration, School of Energy and Environment, Southeast University, Nanjing 210096, China; 3. State Key Laboratory of Technologies in Space Cryogenic Propellants, Beijing 100028, China)

Abstract: Convolutional neural network (CNN) is applied in the image reconstruction of electrical capacitance tomography (ECT) gradually due to its strong nonlinear fitting ability. Aiming at the hyperparameter regulation problem of CNN model, this paper investigates the effects of the model parameters on the image reconstruction results of ECT. Firstly, a dataset of “capacitance matrix-particle concentration distribution” with 80 000 random flow patterns and 40 000 typical flow patterns is established with numerical method, then the CNN models with various hyperparameters are trained and validation through the training set in the dataset. The effects of the network hyperparameters, including the network initialization, grid density, number of the convolution kernels, number of the neurons in the fully connected layer and the structure of the hidden layers, on the image reconstruction accuracy are systematically studied. Further, a test dataset composed of 12 000 extra generated flow patterns is utilized to evaluate the performance of the CNN models. Static experiments were performed to compare and analyze the image reconstruction quality with various CNN models. Results demonstrate that the structure of network hidden layers has a relatively great effect on the image reconstruction accuracy, while the network initialization, grid density, number of the convolution kernels, number of the neurons in the fully connected layers have less effect on image reconstruction accuracy.

Keywords: electrical capacitance tomography; image reconstruction; convolutional neural network; model hyperparameter

收稿日期: 2021-05-21 Received Date: 2021-05-21

* 基金项目: 国家自然科学基金(52006036)、江苏省自然科学基金(BK20190366)、航天低温推进剂技术国家重点实验室开放课题(SKLTSCP1908)、中央高校基本科研业务费专项资金(3203002101C3)资助

0 引 言

电容层析成像技术 (electrical capacitance tomography, ECT) 具有非侵入性、结构简单、成本低、适用范围广等优点,在流化床、气力输送等工业系统中广泛用于实时测量颗粒介质分布^[1-2]。ECT 的基本原理是通过测量各电极对间电容,并根据电容与介质分布之间的关系计算出相应的介质分布。ECT 正问题是通过已知的介质分布以及边界条件求出电极对间电容值,确定电容与介质分布之间的映射关系;而 ECT 反问题则是根据该映射关系与测量电容反演介质分布,也称图像重建^[3]。ECT 技术发展至今,图像重建算法不断改进:线性模型算法(如线性反投影^[4]、Landweber 迭代算法^[5]等)基于线性简化后的灵敏场矩阵,通过不同的线性方法求解灵敏场矩阵的伪逆,完成图像重建,但该类算法图像重建精度往往较低;智能寻优算法(如模拟退火算法^[6]、遗传算法^[7]等)同样基于线性灵敏场模型,通过全局搜索策略完成反问题的非线性求解,提高了图像重建精度,但该类算法收敛性较差,在 ECT 图像重建中应用受限;人工神经网络算法^[8]以及在其基础上发展出的深度神经网络算法,可直接拟合电容向量与介质分布之间复杂的非线性映射,避免了灵敏场的线性简化问题,可明显提高图像重建精度,逐渐被用于 ECT 图像重建。

基于深度学习的 ECT 图像重建算法通过大样本量数据集的训练,可取得明显优于线性模型算法的重建效果。Zheng 等^[9-10]基于数值方法建立了包含分层流、环形流、单核流、双核流 4 种典型流型的数据集,并提出一种有监督的自编码网络,可实现电容向量到介质分布的直接重建,且具有较好的重建效果与泛化能力。孙颖^[11]采用深度置信网络进行 ECT 图像重建,该网络模型可对典型流型实现较高精度的重建。卷积神经网络(convolutional neural network, CNN)广泛应用于图像识别、图像超分辨率重建等领域^[12-14],亦已成功用于电容层析成像图像重建^[15-16]。为了使卷积神经网络算法能够实现动态流动过程的介质分布重建,孙先亮等^[17]提出了一种复杂流型的数值生成方法,并用于卷积神经网络的学习和训练,最终获得的网络模型可较好地重建循环湍动流化床中复杂的介质分布。然而,卷积神经网络的训练过程以及图像重建效果受模型超参数(如网络初始化、卷积核尺寸及数量、全连接层神经元数、隐藏层结构等)的影响严重^[18],训练过程中易出现过拟合和欠拟合问题,过于复杂的网络还会降低图像重建速度和质量。同时,在使用卷积神经网络进行图像重建时,由于对象的变化,模型超参数对于结果的影响亦发生改变,但目前在电容层析成像领域中的相关研究较少,导致模型参数对重建

精度的影响尚不明确^[19]。因此,为了获得结构最简、性能最优的 ECT 图像重建卷积神经网络模型,需要系统研究网络模型超参数调节对电容层析成像图像重建的影响。

本文以数值方法建立“电容矩阵-介质分布”数据集为基础,系统研究了网格密度、网络初始化、卷积核数、全连接层神经元数以及隐藏层结构等超参数对卷积神经网络电容层析成像图像重建的影响,并采用 12 000 组测试集数据对不同卷积神经网络模型进行了定量指标评价,最后通过静态实验对不同网络模型的图像重建结果进行了比较和分析。

1 卷积神经网络图像重建模型

1.1 数据集的建立

图 1 为 8 电极 ECT 电容传感器结构图。本文采用数值方法生成“电容矩阵-介质分布”数据集。首先对管道截面进行网格剖分^[20]。内部区域划分为 S 个网格单元,视每个网格单元内部固相颗粒浓度均匀一致,则可用 $1 \times S$ 维列向量描述流动区域的相对介电常数分布。以网格划分为基础,通过 Zheng 等^[10]提出的数值方法生成典型流型以及孙先亮等^[17]提出的随机噪声滤波法生成随机流型。对于生成的所有流型,采用有限元分析法^[20]计算任意两个电极之间的电容值,并进行归一化处理:

$$C_{ij}^* = \frac{C_{ij} - C_{ij}^L}{C_{ij}^H - C_{ij}^L} \quad (1)$$

式中: C_{ij}^* 为 i 电极与 j 电极间归一化电容; C_{ij} 为该流型下 i 电极与 j 电极间原始电容; C_{ij}^L 和 C_{ij}^H 分别为空管和满管时 i 电极与 j 电极间原始电容。将各电极对间归一化电容重新排列可得到归一化电容矩阵 C_m :

$$C_m = \begin{bmatrix} C_{11}^* & C_{12}^* & \cdots & C_{1N}^* \\ C_{21}^* & \ddots & & C_{2N}^* \\ \vdots & & \ddots & \vdots \\ C_{N1}^* & C_{N1}^* & \cdots & C_{NN}^* \end{bmatrix} \quad (2)$$

式中: N 为电极数量,对角线归一化电容值均设为 0。各流型展平后获得的 $1 \times S$ 维介质分布与其对应的归一化电容矩阵可构成一个数据样本。本文中,“介质分布-电容矩阵”数据集共包含 120 000 组样本。其中,典型流型样本共 40 000 组,具有气固相分界面明确的特点,主要包含分层流、环形流、单核流以及多核流等常见气固两相流型,部分样本如图 2 所示。随机流型样本共 80 000 组,包含具有复杂介质分布的流型,气固相分界面模糊且平滑,可表征复杂气固两相流的流动细节,图 3 为部分随机流型样本,按平均浓度由小到大排列。




图1 8电极ECT传感器结构

Fig. 1 Structure of the ECT sensor with 8 electrodes




图2 部分典型流型样本

Fig. 2 The samples of partial typical flow patterns




图3 部分随机流型样本

Fig. 3 The samples of partial random flow patterns

1.2 卷积神经网络模型

卷积神经网络结构如图4所示,由输入层、上采样层、卷积层、全连接层以及输出层组成。输入层为归一化电容矩阵 C_m 。卷积层设置 m 个 $n \times n$ 维卷积核,卷积核步长为1。全连接层位于卷积层后,对卷积后的高度抽象化特征进行整合,最终输出 $1 \times S$ 维介质分布列向量。在该卷积网络中,由于输入层电容矩阵维度较小,故采用上采样层实现数据的维度扩充,以增强网络可提取的信息量,从而提高图像重建精度。卷积层与全连接层后均添加了Dropout层^[21],可在训练时随机删除部分神经元及其连接,从而增强网络的泛化能力,有效避免过拟合,但训练集损失将有所提高。验证期间Dropout层关闭,所有网络神经元均被使用,验证集损失将小于训练集损失。此外,本文选用ReLU函数作为激活函数^[22],Adam自适应算法作为优化策略^[23]。因研究的ECT图像重建问题属于典型的回归问题,因此选用均方误差(mean square error, MSE)函数作为模型的损失函数^[24]。

将120 000组“电容矩阵-介质分布”样本按9:1的比例分为训练集与验证集,使用训练集对卷积神经网络进




图4 用于ECT图像重建的卷积神经网络

Fig. 4 The convolutional neural network used for ECT image reconstruction

行训练,使用未参与训练的验证集对网络性能进行检验。此外,本文还额外建立了一个由4 000组典型流型与8 000组随机流型组成的测试集,用于测试和评价各网络模型的图像重建性能。由于用于训练和验证的数据集与该测试集分开生成,可保证两个数据集之间存在差异性,有利于网络模型泛化能力的验证。为了比较各网络模型的图像重建精度,选取相对图像误差、相关系数和相含量误差3个指标进行评价^[18]。对于图像重建精度的评价,应综合考虑这3个指标,相对图像误差越小,相关系数越大,相含量误差越小,则图像重建质量越高。

2 卷积神经网络模型超参数优化

关于学习率、激活函数、优化策略、损失函数以及Dropout层等超参数选择的研究较多,可直接根据相关研究成果进行选取^[21-24],文中所选值见表1。本文主要对网络初始化、卷积核数、全连接层神经元数以及隐藏层结构等超参数进行了研究,并分析了上采样层以及网格划分密度对图像重建精度的影响。

表1 部分超参数的选择

Table 1 Selection of partial hyperparameters

参数	学习率	激活函数	优化策略	损失函数	训练次数	Dropout
数值	0.001	ReLU	Adam	MSE	200	0.2

2.1 上采样层

上采样层主要用于扩充输入层数据的维度。图5对比了有上采样层和无上采样层两种网络训练过程的损失函数曲线,图5(a)为训练集损失下降曲线,图5(b)为验证集损失下降曲线。除上采样层外,两种网络采用相同的隐藏层结构,即1层卷积层、1层全连接层,卷积层设置8个 4×4 维卷积核,全连接层设置1 024个神经元。网络权重初始化方法均采用随机均匀初始化,输出层维度均为 1×172 。添加上采样层后,训练集损失降低了11%,验证集损失则降低了16%。训练完成后,使用




图 5 有无上采样层时模型训练和验证过程中的损失曲线

Fig. 5 Loss curves in the model training and validation process with and without up-sampling layer

测试集对其重建性能进行定量指标分析,表 2 列出了两种网络 12 000 张重建图像的平均相对图像误差、平均相关系数和平均相含量误差。可以看出,有上采样层的网络 3 项指标均优于无上采样层的网络,因此,采用上采样层可有效提高模型的性能。

表 2 有无上采样层模型的图像重建结果评价指标统计

Table 2 Evaluation index statistics of the image reconstruction results of the models with and without up-sampling layer

评价指标	相对图像误差/%	相关系数	相含量误差/%
无上采样层	8.14	0.883 4	-0.73
有上采样层	7.42	0.893 1	-0.16

2.2 网格划分密度

管道内部测量区域划分为若干三角网格单元^[20],该网格同时用于正向计算与图像重建,其数量和大小影响电容计算精度,同时也决定了卷积神经网络模型的输出层维度,是重要的超参数之一。图 6 为测量区域分别划分为 364, 838, 1 172, 2 040, 3 334 个网格的示意图,采用三角形网格,每个网格的面积基本相同。对

于不同的网格划分,使用除输出层维度外完全相同的网络进行训练。




图 6 不同密度网格划分

Fig. 6 Mesh generation with different grid density

各网格划分下的流型生成时间、训练时间以及验证集损失如表 3 所示。可以看出,网格数量越多,流型生成时间与网络训练时间越长。同时,当网格数增加时,验证集损失也会随之增加,最后在 0.005 左右波动。图 7 为一组典型流型的成像效果对比。可以看出,网格划分越密,图像重建分辨率越高,原图与重建图像的边缘更光滑,能更好地体现管内的流动状态。总体而言,当网格数达到 800 后,迭代 200 次得到的验证集损失较稳定。同时,由于流型生成与模型训练均为一次性工作,其对工程实际应用影响较小。因此,应结合具体要求,尽量选择较高的网格划分密度。

表 3 不同网格密度参数对比

Table 3 Comparisons of the parameters for different grid density

网格数量	364	838	1 172	2 040	3 334
流型生成时间(s/3 个)	2.598	3.405	4.421	6.537	11.209
训练时间(μs/sample)	128	131	135	140	188
验证集损失	0.004 402	0.005 045	0.004 946	0.004 858	0.005 266

2.3 网络初始化

对于网络初始化方法,本文主要考虑了卷积层权重初始化方法,对初始权重为常量、随机均匀初始化、Xavier 初始化器^[25]与 He 初始化器^[26]4 种权重初始化方法的效果进行了比较。图 8 为采用不同卷积层权重初始化方法的训练曲线。表 4 为 4 种网络 12 000 张重建图像的平均相对图像误差、平均相关系数和平均相含量误差。可以看出,初始权重为常量 1 时,其收敛速度较慢,最终的验证集损失较高(0.006 0);从定量指标结果来看,使用该权重初始化方法训练出的网络重建精度较低。随机均匀初始化、Xavier 均匀初始化与 He 均匀初始化的训练曲线收敛较快,验证集损失分别为 0.004 89、0.004 95、0.004 97,




图7 不同网格密度下模型的图像重建结果

Fig. 7 Image reconstruction results of the models with different grid density





(a) 权重初值为常量1
(a) Initial weights equal to constant one(d) He均匀初始化
(d) He uniform initialization(b) 随机均匀初始化
(b) Random uniform initialization(c) Xavier均匀初始化
(c) Xavier uniform initialization

图8 采用不同权重初始化方法时模型训练和验证过程中的损失曲线

Fig. 8 Loss curves in the model training and validation process using various weight initialization methods

表4 采用不同权重初始化方法时模型的图像重建结果评价指标统计

Table 4 Evaluation index statistics of the image reconstruction results of the models using various weight initialization methods

评价指标	相对图像误差/%	相关系数	相含量误差/%
权重初值为1	8.68	0.859 5	0.52
随机均匀初始化	7.77	0.899 4	0.22
Xavier 均匀初始化	7.42	0.893 1	-0.16
He 均匀初始化	8.00	0.870 3	0.04

3项定量指标结果相近,重建精度较高。值得注意的是,虽然采用不同的权重初始化方法会影响最终的神经网络精度,但对于文中的4种方法,网络的训练均能实现收敛,这从侧面反映了本文所使用数据集的合理性和有效性。

2.4 卷积核数与全连接层神经元数

卷积核的尺寸与数量均会影响卷积神经网络模型性能。但对于 ECT 图像重建问题,输入层维度较小,卷积核尺寸变化范围有限,对重建效果的影响程度较小,故本文仅对卷积核数量进行研究。全连接层连接卷积层与输出层,全连接神经元数决定了全连接层的学习能力,故将全连接神经元数与卷积核数一同纳入研究目标。

图 9 为不同卷积核数和全连接层神经元数网络的重建精度评价指标对比,各网络均采用相同初始化方法与隐藏层结构,网络数量均为 1 172。图 9(a) 为模型训练过程的验证集损失,图 9(b)~(d) 分别为测试集图像重建的平均相对图像误差、平均相关系数和平均相含量误差。整体而言,卷积神经网络模型的重建精度随着卷积核数以及全连接层神经元数的增加而提高。当卷积核数小于等于 12 时,重建精度随卷积核的增加提升较大;当卷积核数大于 12 时,各项重建精度指标变化趋于平缓。当全连接层神经元数由 512 增加到 1 024 时,验证集损失与平均相对图像误差均可降低 6~12%,重建精度提升较明显。此外,当全连接层神经元数较少时,卷积核数对重建精度的影响程度更大,这表明卷积核数与全连接层神经元数之间存在联系,相互影响。总体来看,卷积核数选取在 8~12 之间,全连接层神经元数在 1 024~2 048 之间选取较为合适。





图 9 不同卷积核数与全连接层神经元数网络模型重建结果评价指标

Fig. 9 Evaluation indices of image reconstruction results of the models with different numbers of the convolution kernels and the neurons in the fully connected layer

2.5 隐藏层结构

表 5 为不同数量卷积层与全连接层的网络在训练后的验证集损失。模型结构 1、2 和 3 均设置 1 个卷积层,全连接层数分别为 1、2 和 3;模型结构 1、4 和 5 均设置一个全连接层,卷积层数分别为 1、2 和 3;模型结构 6 设置了两组“上采样-卷积层”与 1 个全连接层。图 10 为 6 种模型结构所对应的卷积神经网络的训练曲线。从图 10(a)~(c) 可以看出,全连接层数增多后,训练集损失明显增大;验证集损失在迭代 100 次后回升,出现了不同程度的过拟合。而如图 10(a)、(d) 和 (e) 所示,网络全连接层数相同时,卷积层数增多后,训练集损失明显增大,且验证集损失曲线出现剧烈震荡,训练效果较差。因此,全连接层和卷积层均以设置 1 层为优。图 10(f) 所示的模型结构 6 采用了两次上采样,其训练集损失提升较小,但验证集损失明显高于训练集损失,且剧烈震荡。因此,上采样层应只在输入层后设置 1 层。

为了验证网络隐藏层结构对于图像重建精度的影响,使用额外生成的 12000 组测试集数据进行模型性能测试与评价。表 6 统计了 3 项评价指标的最大值、最小值、中位数以及方差。可以看出,模型结构 1 对应卷积神经网络整体预测效果最好,其相对图像误差中位




图10 采用不同隐藏层结构时模型训练与验证过程中的损失曲线

Fig. 10 Loss curves in the model training and validation process using different hidden layer structures

表5 采用不同隐藏层结构时模型的验证集损失

Table 5 Validation set losses of the models with different hidden layer structures

序号	网络结构	验证集损失
结构1	1层上采样、1层卷积、1层全连接	0.004 946
结构2	1层上采样、1层卷积、2层全连接	0.006 295
结构3	1层上采样、1层卷积、3层全连接	0.008 562
结构4	1层上采样、2层卷积、1层全连接	0.006 603
结构5	1层上采样、3层卷积、1层全连接	0.008 096
结构6	2层上采样、2层卷积、1层全连接	0.009 754

数(1.15%)、相关系数中位数(0.946 8)以及相含量误差中位数(0.48%)均优于其他模型。图11展示了3项评价指标的频数分布。对于12 000组测试集数据,模型结构2、3对应网络重建图像的相关系数较低,表明全连接层较多的网络在重建时,图像发生了较大的变形;模型4、5、6对应网络的平均相含量误差较高,表明卷积层较多的网络在重建时,出现了一定的信息丢失。以相对图像误差低于10%、相关系数高于0.9、相含量误差低于1%为标准,模型结构1对应网络模型所重建图像达到标准的数量分别为10 523、9 042、938 8,均高于其他结构,进一步体现结构1对应的卷积神经网络整体预测性能较好。

表6 采用不同隐藏层结构时模型的图像重建结果评价指标统计

Table 6 Evaluation index statistics of the image reconstruction results of the models with different hidden layer structures

评价指标	统计	结构1	结构2	结构3	结构4	结构5	结构6
相对图像误差	最大值/%	167.58	129.32	565.95	426.90	1 819.52	1 203.68
	中位数/%	1.15	1.58	2.23	2.01	2.40	2.41
	最小值/%	0.00	0.00	0.00	0.00	0.00	0.00
	方差	0.037 6	0.045 2	0.051 6	0.048 8	0.135 9	0.063 5
相关系数	最大值	1.000 0	1.000 0	1.000 0	1.000 0	1.000 0	1.000 0
	中位数	0.946 8	0.933 0	0.904 4	0.929 5	0.920 3	0.928 8
	最小值	0.000 0	0.000 0	0.000 0	0.000 0	0.000 0	0.000 0
	方差	0.027 0	0.030 7	0.039 9	0.056 3	0.055 7	0.036 1
相含量误差	最大值/%	8.80	10.06	10.93	7.36	9.03	15.40
	中位数/%	0.48	0.56	0.74	1.73	1.52	2.52
	最小值/%	0.00	0.00	0.00	0.00	0.00	0.00
	方差	0.000 0	0.000 1	0.000 1	0.000 2	0.000 4	0.002 1




图 11 3 项评价指标的误差-频数分布柱状图

Fig. 11 Bar charts of the error-frequency distribution for the three evaluation indices

3 实验研究

为了进一步验证模拟评价结果的准确性,对典型流型进行了静态测量实验,分析和比较了表 5 中的 6 种卷积神经网络模型的图像重建效果。实验系统如图 12 所示,主要由有机玻璃管道、ECT 传感器、数据采集与控制系统以及成像计算机构成。其中,有机玻璃管道内径为 50 mm,外径为 60 mm;ECT 传感器为 8 电极,采用单电极激励-单电极检测模式。该 ECT 测量系统采集到电容数据后,根据训练好的卷积神经网络模型,可直接得到重建图像。图 13 为 6 种典型流型的静态模拟方法,实验中将不同尺寸、形状的有机玻璃棒置于管道内的不同位置,用于模拟出 6 种典型流型的介质分布。模拟图则依据网格划分,通过等比例复原实验图得到,便于结果比较与定量分析。



图 12 ECT 在线测量系统

Fig. 12 ECT online measuring system

实验系统每秒采集 100 组电容数据,每种流型各选取一段时间内的 500 组电容数据进行图像重建。表 7 为各网络模型 500 组重建图像的平均相对图像误差、平均相关系数和平均相含量误差。图 14 对比了各网络模型




图 13 典型流型静态模拟

Fig. 13 Static simulation of typical flow patterns

表 7 静态实验典型流型图像重建结果评价指标统计

Table 7 Evaluation index statistics of image reconstruction results of the typical flow patterns in static experiment

流型	评价指标	结构 1	结构 2	结构 3	结构 4	结构 5	结构 6
单核 1	相对图像误差/%	7.27	4.57	9.94	4.04	4.43	8.18
	相关系数	0.943 3	0.964 3	0.926 8	0.968 4	0.966 2	0.939 5
	相含量误差/%	-0.21	0.03	3.81	-0.57	1.64	3.32
单核 2	相对图像误差/%	23.60	30.67	44.79	29.86	22.76	22.83
	相关系数	0.864 5	0.828 9	0.776 3	0.831 5	0.866 2	0.863 0
	相含量误差/%	1.56	2.26	5.55	2.48	1.21	0.40
环形 1	相对图像误差/%	39.58	42.97	41.50	35.09	35.94	39.68
	相关系数	0.753 7	0.761 4	0.761 0	0.778 4	0.763 8	0.734 9
	相含量误差/%	2.11	4.42	3.51	1.82	1.09	-0.64
环形 2	相对图像误差/%	32.50	43.86	50.08	39.33	31.92	34.97
	相关系数	0.769 1	0.717 8	0.698 3	0.727 5	0.765 4	0.749 0
	相含量误差/%	4.60	8.40	12.09	6.07	4.25	4.24
双核	相对图像误差/%	24.20	27.04	25.77	22.41	25.03	24.67
	相关系数	0.816 2	0.799 5	0.810 0	0.829 9	0.809 5	0.812 9
	相含量误差/%	0.43	3.52	4.02	0.93	0.32	1.21
三核	相对图像误差/%	19.90	23.70	21.54	19.94	18.32	18.74
	相关系数	0.808 4	0.771 8	0.794 9	0.806 4	0.820 8	0.818 1
	相含量误差/%	1.61	1.18	3.86	1.95	1.85	2.43




图 14 静态实验流型成像结果对比

Fig. 14 Comparisons of image reconstruction results of the typical patterns in static experiment

对每种流型的重建图像。可以看出:模型结构1整体上重建精度较高,图像重建效果较稳定;模型结构2、3重建精度较低,重建图像与原图形状差距较大,尤其对于气固相界面的辨识性能较差,且具有整体预测浓度偏高的问题,这表明全连接层的增加不利于提高图像重建精度;模型结构4、5、6与模型结构1的重建精度相近,对于环形流以及多核流这类流型,3种模型重建图像的重建效果更好,界面辨识更明确,这表明卷积层的增加有利于部分具有复杂气固相界面流型重建精度的提高,但这3种模型的平均相含量误差较大,且整体预测浓度偏低,一定程度上也反映了卷积层数据降维所带来的信息丢失。综合四种流型的重建结果,设置1层卷积层与1层全连接层的网络模型在结构最简的同时,还可获得较高的图像重建精度,整体性能最优。

4 结 论

本文针对卷积神经网络电容层析成像图像重建的超参数调节问题,主要研究了网络初始化、网络密度、卷积核数、全连接层神经元数以及隐藏层结构对电容层析成像图像重建的影响,并通过实验比较了不同结构卷积神经网络模型的图像重建效果。结果表明:隐藏层结构对ECT图像重建精度影响较大,当设置1层卷积与1层全连接时,图像重建效果最好;网络初始化、网络密度、卷积核数以及全连接层神经元数等超参数对图像重建精度的影响较小,采用合适的初始化方式(随机均匀初始化、Xavier初始化或He初始化)、网络密度(1 000~3 500)、卷积核数(8~12)以及全连接层神经元数(1 024~2 048)可使网络模型获得较好的训练效果。

参考文献

- [1] 祝光泉,杨海马,李筠,等. 电容层析成像图像重建算法对比[J]. 电子科技, 2019, 31(1): 1-6.
ZHU G Q, YANG H M, LI Y, et al. Comparison of image reconstruction algorithms of electrical capacitance tomography [J]. Electronic Science and Technology, 2019, 31(1): 1-6.
- [2] 杨道业,周宾,许传龙,等. 电容层析成像在高压浓相煤粉气力输送中的应用[J]. 仪器仪表学报, 2007, 28(11): 1987-1993.
YANG D Y, ZHOU B, XU CH L, et al. Application of electrical capacitance tomography in dense-phase pneumatic conveying of pulverized coal under high pressure [J]. Chinese Journal of Scientific Instrument, 2007, 28(11): 1987-1993.
- [3] 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): 1909-1919.
ZHAO Y L, GUO B L, YAN Y Y. Latest development and analysis of electrical capacitance tomography technology [J]. Chinese Journal of Scientific Instrument, 2012, 33(8): 1909-1919.
- [4] GAMIO J C, ORTIZ-ALEMAN C, MARTIN R. Electrical capacitance tomography two-phase oil-gas pipe flow imaging by the linear back-projection algorithm [J]. Geofísica Internacional, 2005, 44(3): 265-273.
- [5] YANG W Q, SPINK D M, YORK T A, et al. An image-reconstruction algorithm based on Landweber's iteration method for electrical-capacitance tomography [J]. Measurement Science and Technology, 1999, 10(11): 1065.
- [6] ORTIZALEMAN C, MARTIN R, GAMIO J C. Reconstruction of permittivity images from capacitance tomography data by using very fast simulated annealing [J]. Measurement Science and Technology, 2010, 15(7): 1382-1390.
- [7] 陈德运,郑贵滨,于晓洋,等. 基于遗传算法电容层析成像图像重建算法的研究[J]. 电机与控制学报, 2003, 7(3): 207-211.
CHEN D Y, ZHENG G B, YU X Y, et al. Image reconstruction algorithm based on genetic algorithms for two-phase flow electrical capacitance tomography system [J]. Electric Machines and Control, 2003, 7(3): 207-211.
- [8] MARASHDEH Q, WARSITO W, FAN L S, et al. Nonlinear forward problem solution for electrical capacitance tomography using feed-forward neural network [J]. IEEE Sensors Journal, 2006, 6(2): 441-449.
- [9] ZHENG J, PENG L. An autoencoder-based image reconstruction for electrical capacitance tomography [J]. IEEE Sensors Journal, 2018, 18(13): 5464-5474.
- [10] ZHENG J, LI J, LI Y, et al. A benchmark dataset and deep learning-based image reconstruction for electrical capacitance tomography [J]. Sensors, 2018, 18(11): 3701.
- [11] 孙颖. 基于深度信念网络的ECT图像重建算法研究[D]. 天津: 中国民航大学, 2020.
SUN Y. Research on ECT image reconstruction algorithm based on deep belief network [D]. Tianjin: Civil

- Aviation University of China, 2020.
- [12] 蓝金辉, 王迪, 申小盼. 卷积神经网络在视觉图像检测的研究进展[J]. 仪器仪表学报, 2020, 41(4): 167-182.
- LAN J H, WANG D, SHEN X P. Research progress on visual image detection based on convolutional neural network[J]. Chinese Journal of Scientific Instrument, 2020, 41(4): 167-182.
- [13] 谢晓蔚, 史健芳. 弱监督卷积神经网络的多目标图像检测研究[J]. 电子测量与仪器学报, 2019, 33(6): 31-37.
- XIE X W, SHI J F. Research of convolutional neural networks with weakly-supervised learning on multi-object image detection[J]. Journal of Electronic Measurement and Instrumentation, 2019, 33(6): 31-37.
- [14] 李伟, 张旭东. 基于卷积神经网络的深度图像超分辨率重建方法[J]. 电子测量与仪器学报, 2017, 31(12): 1918-1928.
- LI W, ZHANG X D. Depth image super-resolution reconstruction based on convolution neural network[J]. Journal of Electronic Measurement and Instrumentation, 2017, 31(12): 1918-1928.
- [15] ZHENG J, MA H, PENG L. A CNN-based image reconstruction for electrical capacitance tomography[C]. 2019 IEEE International Conference on Imaging Systems and Techniques (IST), 2019: 1-6.
- [16] YANG X, ZHAO C, CHEN B, et al. Big data driven U-Net based electrical capacitance image reconstruction algorithm[C]. 2019 IEEE International Conference on Imaging Systems and Techniques (IST), 2019: 1-6.
- [17] 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 image reconstruction of electrical capacitance tomography based on convolutional neural network [J]. CIESC Journal, 2020, 71(5): 2004-2016.
- [18] 展华伟, 唐艳, 付婧. 卷积神经网络的参数优化和函数选择[J]. 太原师范学院学报(自然科学版), 2020, 19(1): 77-80.
- ZHAN H W, TANG Y, FU J. Parameter optimization and function selection of convolutional neural networks[J]. Journal of Taiyuan Normal University (Natural Science Edition), 2020, 19(1): 77-80.
- [19] CIARAN C, ATTILA K, RAFFAELLA F, et al. Evaluation of hyperparameter optimization in machine and deep learning methods for decoding imagined speech EEG[J]. Sensors, 2020, 20(16): 1-22.
- [20] 金建铭. 电磁场有限元方法[M]. 西安: 西安电子科技大学出版社, 1998.
- JIN J M. Finite element method of electromagnetic field[M]. Xi'an: Xidian University Press, 1998.
- [21] SRIVASTAVA N, HINTON G, KRIZHEVSKY A, et al. Dropout: A simple way to prevent neural networks from overfitting [J]. The Journal of Machine Learning Research, 2014, 15(1): 1929-1958.
- [22] 田娟, 李英祥, 李彤岩. 激活函数在卷积神经网络中的对比研究[J]. 计算机系统应用, 2018, 27(7): 43-49.
- TIAN J, LI Y X, LI T Y. Contrastive study of activation function in convolutional neural network [J] Computer Systems & Applications, 2018, 27(7): 43-49.
- [23] 贾桐. 深度学习常用优化算法研究[J]. 信息技术与网络安全, 2019, 38(7): 42-46.
- JIA T. A study of common optimization algorithms for deep learning[J]. Information Technology and Network Security, 2019, 38(7): 42-46.
- [24] LI F, YANG Y. A loss function analysis for classification methods in text categorization [C]. Proceedings of the 20th International Conference on Machine Learning (ICML-03), 2003: 472-479.
- [25] GLOROT X, BENGIO Y. Understanding the difficulty of training deep feedforward neural networks [C]. Proceedings of the 13th International Conference on Artificial Intelligence and Statistics (AISTATS), 2010(9): 249-256.
- [26] HE K, ZHANG X, REN S, et al. Delving deep into rectifiers: Surpassing human-level performance on ImageNet classification [C]. IEEE International Conference on Computer Vision (ICCV), 2015: 1026-1034.


作者简介



汤政, 2020 年于东南大学获得学士学位, 现于东南大学能源与环境学院攻读硕士学位, 主要研究方向为多相流测试与电容层析成像。

E-mail: tangzheng1@163.com


Tang Zheng received his B.Sc. degree in 2020 from Southeast University. He is currently pursuing his M.Sc. degree with School of Energy and Environment, Southeast University. His main research interest includes multiphase flow measurement and electrical capacitance tomography.



李健(通信作者),2010 年、2016 年于东南大学分别获得学士、博士学位,现为东南大学讲师,主要研究方向为多相流测试技术与测试仪表。

E-mail: eelijian@seu.edu.cn

Li Jian (Corresponding author) received his B.Sc. and Ph.D. degrees both from Southeast University in 2010 and 2016, respectively. He is currently a lecturer with School of Energy and Environment, Southeast University. His research interest includes multiphase flow measurement and measurement instrumentation.



许传龙,2001 年于东北电力大学获得学士学位,2003 年、2006 年于东南大学分别获得硕士、博士学位,现为东南大学能源与环境学院教授,主要研究方向为多相流测试和燃烧诊断。

E-mail: chuanlongxu@seu.edu.cn

Xu Chuanlong received his B.Sc. degree in 2001 from Northeast Electric Power University, received his M.Sc. and Ph.D. degrees both from Southeast University in 2003 and 2006, respectively. He is currently a professor with School of Energy and Environment, Southeast University. His research interest includes multiphase flow measurement and combustion diagnostics.