

采用多任务学习和电容层析成像的 两相流参数测量方法

杨海潮, 胡红利, 陆程程, 卢家宇, 王茂杰

(西安交通大学电力设备电气绝缘国家重点实验室, 710049, 西安)

摘要: 针对电容层析成像技术(ECT)重建的图像精度低、对流动参数测量误差较大的问题,提出了一种采用多任务学习和电容层析成像的两相流参数测量方法。首先,采用残差模块作为特征提取模块对 Landweber 算法重构的图像进行特征提取,以此消除重建图像的伪影对流动参数测量所带来的干扰;其次,为了进一步提升模型的抗噪声干扰能力,采用硬参数共享的双路输出神经网络结构进行初次相含率测量;之后,采用融合神经网络与极端随机森林等分类模型的方法来实现流型识别;最后,为了进一步提升相含率测量的准确度,采用极端随机森林等回归模型通过融合流型识别和初次相含率测量的结果,获得最终的相含率。实验结果表明:该方法相对于仅采用神经网络的方法,可以提升相含率测量的准确度;在实测数据测试中,该方法进行相含率测量的相对误差在5%以内,流型识别的准确度可以达到98%以上,表现出了较好的抗噪声干扰能力,能够满足对实际工业应用的需求。

关键词: 电容层析成像; 多任务学习; 两相流; 流型识别; 噪声干扰

中图分类号: TP183 **文献标志码:** A

DOI: 10.7652/xjtuxb202303019 **文章编号:** 0253-987X(2023)03-0202-10

Two-Phase Flow Parameter Measurement Using Multi-Task Learning and Electrical Capacitance Tomography

YANG Haichao, HU Hongli, LU Chengcheng, LU Jiayu, WANG Maojie

(State Key Laboratory of Electrical Insulation and Power Equipment, Xi'an Jiaotong University, Xi'an 710049, China)

Abstract: A two-phase flow parameter measurement method, which combines multi-task learning and electrical capacitance tomography, is proposed to solve the problem of the interference in parameter measurement caused by the low accuracy of the images reconstructed by the reconstruction algorithm in terms of electrical capacitance tomography. Firstly, the residual module is used as the feature extraction module to extract the features of the images reconstructed by the Landweber algorithm, so as to eliminate the interference of artifacts of reconstructed images on parameter measurement. Secondly, a dual output multi-task neural network with hard parameter sharing is built to finish the task of initial measurement of the phase fraction in order to further improve the anti-noise ability of the model. Then, a method of fusing neural network and classification models, such as extreme random forests, is proposed to achieve flow identification. Finally, regression models such as extreme random forests are used to obtain the final phase fraction by fusing the results of flow pattern identification and initial results of the phase fraction in order to

收稿日期: 2022-09-28。 作者简介: 杨海潮(1999—),男,硕士生;胡红利(通信作者),男,教授,博士生导师。 基金项目: 国家自然科学基金资助项目(52177009);陕西省科技攻关计划资助项目(2016GY-001)。

网络出版时间: 2022-12-26

网络出版地址: <https://kns.cnki.net/kcms/detail/61.1069.T.20221226.1103.002.html>

further improve the accuracy of phase fraction measurement. The experimental results show that the proposed algorithm can improve the accuracy of phase fraction measurement when compared with the method of only using the neural network. In the actual measurement, the relative error of phase fraction measured by the proposed algorithm is within 5%, and the accuracy of flow identification is beyond 98%, which shows a good anti-noise ability of the model and can meet the demands of practical industrial applications.

Keywords: electrical capacitance tomography; multi-task learning; two-phase flow; flow identification; noise interference

ECT 技术是一种利用电容传感器对被测物理场进行介质分布成像的技术,利用该技术可以实现不同参数的测量^[1-4]。常见的 ECT 技术的应用场景包含对石油、天然气输送管道进行参数测量、介质分布成像等,而石油和天然气管道输送的流体属于典型的油-水或气-水两相流对象,其流动的形式复杂多变,因此对其流动参数的准确测量是需要重点解决的问题。两相流的流动参数主要有流型、流速、相含率以及质量流量,但描述多相流行为特征最重要的参数是流型和相含率,其中相含率的测量较为困难,流型是其他参数测量的基础,因此本文重点解决如何准确实现相含率的测量和流型识别。ECT 技术虽然具有非侵入、不干扰流场的特点,但是采用该技术在流型识别和相含率的测量方面仍然有许多问题,其中就包括设备本身受到的噪声干扰、ECT 灵敏度的非线性问题等,而这会影响到 ECT 图像重构算法的重建精度。常用的图像重构算法包括线性反投影算法(LBP)^[5]、Landweber 迭代算法^[6]等,但是采用传统的重构算法重构的图像因为上述的问题会具有较大的误差,首先,这会干扰流型识别的结果;其次,会干扰到相含率参数的测量,例如,利用重构图像计算相含率需要统计每一种相的像素点的个数,所以重构图像由于具有较大误差的问题而会使得相含率的结果具有较大的偏差。对此问题,现有的解决方法包含改进测量方法^[7]、传感器的结构^[8]、提出新的图像重建算法^[9]等,但是上述方法依旧没有有效的解决该问题。由于利用电容向量或重构图像直接获取相含率和流型难以直接用解析式表达,而深度学习和机器学习具有较强的非线性特点,适合用来解决非线性问题,所以本文从深度学习和机器学习的角度来解决该问题。由于深度学习和机器学习模型的输入向量的维度是固定的,而采用重构图像作为输入,对于不同的 ECT 系统不需要因为电容向量维度的不同而重新设计结构,因此其相比使用电容向量作为输入,模型适用

范围要广。所以本文以 Landweber 重构的图像为例通过一种融合机器学习和深度学习的方法来实现相含率测量和流型识别。

通过在图像分割^[10]、图像超分辨^[11]等多个领域的应用情况来看,深度学习能够较好的完成相应的目标,但是依然存在梯度消失、梯度爆炸、过拟合等问题,而其中一个解决方法是设计较好的网络结构,现如今效果较好的网络结构包含 ResNet^[12]、VGGNet^[13]、DenseNet^[14]等。所以,本文首先对比了 ResNet、VGGNet、DenseNet 相关特征提取模块的效果,以此选择合适的特征提取模块。多任务学习可以使得模型在多个任务上都能够在其对应的指标上有较好的结果^[15-16],此外,模型的抗噪声干扰的能力也会有所增强。然而,多任务学习的一个关键问题在于如何实现不同任务之间特征的共享^[17],根据以往的情况来看,采用多任务学习的网络结构可以归纳为硬参数共享和软参数共享两种网络结构,但具体采用哪种结构需要根据实际的问题对比决定。此外,不同任务的损失函数以及其对应的权重对于最终的结果会有很大的影响。因此,本文根据硬参数共享的网络结构设计了一个双路输出的多任务神经网络,并且对该网络采用多任务学习的方法,以此来进行初次相含率的测量。

虽然深度学习已经在很多领域有较为成功的应用,但是不能忽视机器学习所具有的超参数调节效率高、可解释性强的特点。因此,如何充分的利用并融合传统机器学习和深度学习各自的优势是需要解决的问题。对此,本文提出了一种融合两者的方法,通过实验验证,采用该方法进行流型识别有较高的准确度,并且可以进一步提升相含率测量的准确度。总体而言,本文的贡献有以下 3 个方面:

(1)提出了一种结合多任务神经网络和传统的机器学习算法的模型框架,该框架可以根据 Landweber 图像重构算法重构的图像同时较为准确地实现相含率的测量和流型识别两个任务,并且对于实

测数据,其依旧保持了较好的性能;

(2) 经过实验验证,在相含率测量方面,发现当采用合适的损失函数组合时,多任务神经网络相较于单任务神经网络有较高的准确性,并且采用本文的方法相较于仅采用神经网络可以进一步提升测量的准确性;

(3)分析了当电容传感器在遭受到高斯噪声干扰情况下所提出的方法的有效性,经过实验验证,本文所提出的多任务神经网络相较于单任务神经网络有更好的抗噪声干扰的能力,并且发现,使用噪声数据进行训练虽然可以提升模型的抗噪能力,但是在低信噪比的情况下,其性能依然会有所下降。

1 相关研究

1.1 Landweber 算法

Landweber 迭代重建算法是 ECT 层析成像技术中常用的图像重建算法,其利用传感器阵列所测量得到的相关测量参数,利用迭代的方法来重建出相应场域内的介质分布情况,如式(1)^[18]所示

$$\mathbf{G}_{k+1} = \mathbf{G}_k + A_0 (\mathbf{Z} - \mathbf{S}\mathbf{G}_k) \quad (1)$$

式中: $\mathbf{G}_k$ 为第 k 次迭代后的灰度矢量矩阵; $\mathbf{Z}$ 为电容矢量矩阵; $\mathbf{S}$ 为灵敏度矩阵; A_0 为超参数。

利用 Landweber 算法虽然比 LBP 算法重建的图像有较高的准确度,但是其重建的图像依然存在较多的伪影,其原因主要在于电极测量的电容与场域的介电常数分布之间是非线性关系,这导致灵敏度矩阵本身是病态的^[18],而这会使得测量误差较大。针对这个问题,有部分研究显示 ECT 传感器阵列的个数、重建的像素点的个数等都会对重建误差产生影响^[19]。如果仔细分析,这些因素实际上都在影响场域内的灵敏度的分布情况。而采用包含改进传感器结构^[8]等方法并没有从根本上解决灵敏度非线性所导致的重构误差较大的问题,所以本文从对 Landweber 重建的图像进行处理这个角度来解决重建图像误差较大而引起参数测量和流型识别准确性较低的问题。

1.2 深度学习和机器学习在 ECT 技术中的应用

深度学习和机器学习在 ECT 技术中的应用主要包含图像重建、流型识别、图像处理等方面。对于图像重建问题,有采用卷积神经网络^[20-21]、贝叶斯算法^[22]、向量机^[23]等方法,其基本的原理都大致相似,即利用传感器阵列所测量得到的信号,利用算法获取得到对应的截面介质分布情况。这些方法可以有效地避免传统图像重建算法存在的伪影较多的问题。对于识别问题,主要是利用传感器测量得到的

信号或重建的图像来实现识别,其采用的方法包含神经网络^[24]、EEMD^[25]等。不同文献的结果显示,大多数方法都能够较为准确的实现流型识别,但是噪声对其所产生的影响并没有详细的分析。针对图像处理方面,采用深度学习和机器学习主要是通过对重建算法重构的图像进行处理来提升图像的精度^[26]。但是,上述问题均采用单一算法来实现单一目标,所以本文提出一种融合机器学习和多任务神经网络的方法来实现流型识别和相含率测量。

2 本文提出的方法

2.1 网络结构

针对 Landweber 算法重构图像精度较低的问题, 本文结合多任务神经网络和机器学习来实现相含率测量和流型识别。整体的网络框架如图 1 所示。




图 1 相含率测量和流型识别的整体框架

Fig. 1 Overall framework of phase fraction measurement and flow identification

图1网络框架利用Landweber迭代重建算法输出的图像作为整体网络框架的输入,对应的相含率和流型作为该框架的输出。针对神经网络部分,采用残差模块作为神经网络的特征提取模块,并使用双路输出的方式进行初次的相含率测量。针对机器学习部分,首先,利用神经网络全连接层的特征向量通过极端随机森林等算法进行流型识别,其次,为了进一步提升相含率测量的准确度,通过融合神经网络初次测量的相含率以及机器学习算法输出的流型,利用机器学习算法获取得到最终的相含率测量结果。

2.2 神经网络结构

本文所采用的神经网络结构如图 2 所示,该结构为硬参数共享的网络结构,包含一个特征提取模块和两个测量模块。




图 2 多任务神经网络整体框架

Fig. 2 Overall framework of multi-task neural network

图 2 中特征提取模块采用 6 个残差模块对图像进行相应的处理,随后利用全局平均池化层将处理得到的一组特征图转变为一维向量。残差模块采用多路处理的方法,一路采用 3×3 的二维卷积层、ReLU 激活函数、批量归一化层、 2×2 的平均池化层的结构,另一路采用 1×1 的二维卷积层、ReLU 激活函数来对图像进行处理,最终两路输出的特征图沿着通道维度进行合并,残差模块中所有卷积层的步长设定为 1,池化层的步长设定为 2。测量模块采用多组全连接层对全局平均池化层的输出特征向量进行处理,该模块的全连接层单元的个数分别为 128、64、1,其中单元数为 128 和 64 的全连接层采用 ReLU 激活函数,最后一层用于输出重构图像对应的相含率,由于相含率设定为 0 到 1 的浮点数,所以最后一层采用 Sigmoid 激活函数。

2.3 机器学习算法

为了实现机器学习算法与多任务神经网络之间的相互融合,首先利用机器学习算法并采用网络中全连接层的特征向量来实现流型识别。为了分析采用不同全连接层的特征向量对于结果是否有较为明显的影响,本文分别使用 4 个全连接层的特征向量作为算法的输入来进行分析,其中各特征向量的维度分别为 128、128、64、64。算法分别采用随机森林、极端随机森林。而为了进一步提升相含率测量的准确率,本文融合了神经网络输出的相含率以及流型识别的结果,通过极端随机森林等回归器再一次进行相含率的测量,并以此作为整个网络框架最终输出的相含率。本文所使用的随机森林和极端随机森林分别由 100 个决策树和极端随机树构成,并且不对最大深度和最大叶子节点个数进行设定,最少样本个数设定为 1,最少分裂样本个数设定为 2。整体框架如图 3 所示。




图 3 机器学习算法总体框架

Fig. 3 Overall framework of machine learning algorithm

2.4 损失函数

本文采用多任务学习的方法来训练该网络。而训练时的一个关键问题为两个损失函数各自的权重,本文设置两个损失函数 L_1 、 L_2 的权重均为 1,因此总损失函数可表示为

$$L = L_1 + L_2 \quad (2)$$

式中: L 为总损失函数; L_1 、 L_2 分别代表两种不同的损失函数。 L_1 选择均方误差损失函数(L_{mse}),其表达式如下

$$L_{\text{mse}} = (y - \hat{y})^2 \quad (3)$$

式中: y 为神经网络的预测值; $\hat{y}$ 为其真实值。

L_2 则选择 Huber 损失函数(L_{huber}) 该损失函数结合了 L_{mse} 和 MAE 损失函数(L_{mae}) 的特点,当损失值较小时,损失函数为二次函数,当损失值较大时,损失函数为一次函数,这解决了 L_{mae} 在损失值较小时依然具有较大梯度的问题,使得模型的收敛性有所提升,并且对异常值更具鲁棒性。Huber 损失函数的表达式如下

$$L_{\text{huber}} = \begin{cases} 0.5 (y - \hat{y})^2, & |y - \hat{y}| \leq d \\ 0.5 d^2 + d(|y - \hat{y}| - d), & |y - \hat{y}| \geq d \end{cases} \quad (4)$$

式中, d 为可调节的超参数。

3 实验设置与评价指标

3.1 数据集和训练设置

本文利用 COMSOL Multiphysics 仿真软件获取两相流二维仿真数据,介电常数分别为 3.2 和 1,仿真的管道内径为 23 mm,外径为 25 mm,屏蔽罩半径为 35 mm。采用 12 电极的 ECT 成像系统,设定激励电压为 1 V,该数据集中训练集、验证集、测试集分别有 4 000、4 000、2 500 组数据,其中包含中心流、环状流、层流和偏心流 4 种流型。为避免样本不平衡的问题,设定训练集、验证集、测试集每组流型有 1 000、1000、500 组。每组数据包含利用 Landweber 算法迭代重构的图像、流型及其对应的相含率,图像的尺寸为 128×128 像素,并设置 Landweber 算法迭代 500 次。针对神经网络的训练,本文采用小批量学习的方法来对神经网络进行训练,设定批量个数为 20,模型共训练 500 个周期。反向传播算法选择 Adam 方法,其中 β_1 、 β_2 、 ϵ 分别设定为 0.9、0.999 和 1×10^{-7} ,参数学习率设定为 1×10^{-3} ,并且为了减

少训练过程中存在的振荡问题,在周期为 100、200、300、400 和 500 时将学习率下降为原先的 0.9 倍。Huber 损失函数的超参数 d 选为 1,权重参数采用“glorot uniform”初始化,偏置参数初始值均设定为 0。机器学习算法的训练在神经网络训练完成后进行。

3.2 评价指标

本文所提出的框架需要评价相含率测量和流型识别准确性两个方面,其中相含率测量采用相对误差(e)进行评价,其表达式如下

$$e = \frac{|y - \hat{y}|}{\hat{y}} \quad (5)$$

式中: y 为算法输出的相含率; $\hat{y}$ 为 y 对应的真实相含率。

流型识别准确性则从精确率($F_{\text{precision}}$)、召回率(F_{recall})、F1-score 值(F_1)3 个方面进行评价。其中,精确率和召回率的公式如下

$$\begin{cases} F_{\text{precision}} = \frac{N_{\text{TP}}}{N_{\text{TP}} + N_{\text{FP}}} \\ F_{\text{recall}} = \frac{N_{\text{TP}}}{N_{\text{TP}} + N_{\text{FN}}} \end{cases} \quad (6)$$

式中: N_{TP} 为真阳性样本个数; N_{FP} 为假阳性样本个数; N_{FN} 为假阴性样本个数。

为了将精确率和召回率两者统一起来,本文采用 F_1 指标,其公式如下

$$F_1 = \frac{2F_{\text{precision}}F_{\text{recall}}}{F_{\text{precision}} + F_{\text{recall}}} \quad (7)$$

4 实验结果分析

本文中所有的实验均采用训练 10 次取结果平均值的方法来对测试集的数据进行评价,为了保证公平性,每组实验的超参数设定均相同,测试集数据均相同。相含率相对误差的评价结果包含相对误差的平均值和方差,相关的评价指标如 3.2 节所述。

4.1 特征提取模块对于结果的影响

为了排除数据本身的影响,本文使用不同的特征提取模块的神经网络,并且使用不同的损失函数组合进行分析。特征提取模块分别采用 ResNet、VGGNet 和 DenseNet 的相关模块 Res、VGG 和 Dense,其中 VGG、Dense 模块的结构如图 4 所示。




图 4 VGGNet 和 DenseNet 的特征提取模块结构图

Fig. 4 Structure diagram of feature extraction module of VGGNet and DenseNet

对于 VGG 模块,其采用的卷积层均为 3×3 的卷积核,步长均设定为 1,平均池化层的池化核尺寸均为 2×2 ,步长为 2,每次处理后的特征图通道维度分别为 8、16、32、64、128。而利用 Dense 模块,首先将重构图像经过 3×3 的卷积、ReLU 激活函数、批量归一化和 ReLU 激活函数处理,得到通道维度为 8 的一组特征图,随后连续利用模块 1 和模块 2 处理 5 次,期间特征图的通道维度分别为 8、16、32、64、128,最终经过全局平均池化层的处理通入到全连接层。训练结果如表 1 所示。

表 1 采用不同损失函数组合和特征提取模块结果比较

Table 1 Comparison results using different loss function combinations and feature extraction modules

损失函数	相对误差 / %		
	Res	VGG	Dense
L_{mse}	2.34	3.62	2.97
L_{huber}	2.13	3.31	4.16
$L_{mse} + L_{mse}$	2.28	3.26	3.98
$L_{mse} + L_{huber}$	2.16	2.36	2.54
$L_{huber} + L_{huber}$	2.02	3.33	3.78

通过对比可以看出,当采用 VGG 和 Dense 模块,利用 $L_{mse} + L_{huber}$ 组合的多任务神经网络相较于利用 L_{mse} 或 L_{huber} 的单任务神经网络结果更好,而当

采用 Res 模块时,利用 $L_{huber} + L_{huber}$ 组合的效果更好。但是对于采用不同的损失函数组合,多任务神经网络的结果并不一定比单任务神经网络的结果好,这说明损失函数的组合方式对于相含率测量的性能有较大的影响。但无论采用哪种组合方式,采用 Res 模块都相较于采用 VGG 和 Dense 模块的结果要好,因此后文均采用 Res 模块作为网络的特征提取模块进行分析。

4.2 流型识别结果分析

进行流型识别时,由于输入是神经网络的特征向量,所以为了分析特征向量维度的影响,本文分析了不同全连接层输出的特征向量($T_{m,n}$ 代表利用第 m 条支路中单元数为 n 的全连接层的特征向量)作为算法的输入的情况,神经网络采用 $L_{huber} + L_{huber}$ 组合的损失函数,最终采用随机森林和极端随机森林 2 种机器学习算法进行流型识别,结果如表 2 所示。根据表 2 结果可以看出,2 种算法的准确性均较高,并且特征向量维度为 128 的结果相较于维度为 64 的结果要好,说明特征向量的维度对流型识别的准确性是有一定影响的。这也说明在进行相含率测量的过程中,全连接层的特征向量可能包含了流型的相关信息,即说明神经网络在进行相含率测量任务时可能考虑到了流型的特征。

表 2 采用 2 种机器学习算法进行流型识别的性能对比

Table 2 Performance comparison of different machine learning algorithms for flow identification

特征向量	随机森林			极端随机森林		
	$F_{precision} / \%$	$F_{recall} / \%$	$F_1 / \%$	$F_{precision} / \%$	$F_{recall} / \%$	$F_1 / \%$
$T_{1,128}$	99.98	99.99	99.99	99.99	99.99	99.99
$T_{2,128}$	99.90	99.99	99.95	99.99	99.99	99.99
$T_{1,64}$	99.73	99.94	99.83	99.94	99.94	99.94
$T_{2,64}$	99.59	99.98	99.78	99.98	99.98	99.98

注:加粗数据表示最优值。

总体而言,利用极端随机森林的效果均较好。从结果中也可看出,虽然采用相同的网络结构,但是两条支路进行流型识别的准确性存在一定的差别,其原因在于神经网络采用“glorot uniform”进行参数初始化,所以不同支路上的可训练参数在训练后的结果是不同的,而这一点也正是多任务神经网络能够提升泛化能力、具有较好的抗噪声干扰能力的原因。

4.3 机器学习对相含率测量的影响

为了进一步提升相含率测量的准确度,本文利用神经网络初次测量的相含率和机器学习算法分类得到的流型结果作为机器学习算法的输入,通过该算法再一次进行相含率的测量。为了说明其有效性,分别采用单任务神经网络和多任务神经网络进行对比实验。两者均利用极端随机森林选择单元数为 128 的全连接层的特征向量进行流型识别,其中多任务神经网络采用第一条支路的全连接层 $T_{1,128}$ 。之后,分别采用随机森林和极端随机森林回归器进行最终相含率的测量,对于两种神经网络,回归器的输入分别为两个输出相含率和流型、一个输出相含率和流型,各算法的参数设置与前文保持一致,最终结果如表 3 所示。通过结果可以看出,采用两种回归器再一次进行相含率的测量,可以提升测量的准确性。

表 3 机器学习对相含率测量的影响


Table 3 Results of Phase fraction Measurement by Machine Learning

损失函数	相对误差/%		
	不使用机器学习	随机森林	极端随机森林
L_{mse}	2.34	1.78	1.69
L_{huber}	2.13	1.74	1.67
$L_{mse} + L_{mse}$	2.29	1.97	1.71
$L_{mse} + L_{huber}$	2.16	1.75	1.67
$L_{huber} + L_{huber}$	2.02	1.59	1.54


4.4 噪声对于测量结果的影响

为了分析模型的抗噪能力,本文对测试集的电容向量添加信噪比为 60~110 dB 的高斯噪声,并利用加噪后的电容向量来进行图像重建。其中设定算法迭代的次数为 500 次,每两组数据间信噪比相差 10 dB。流型识别采用的算法为极端随机森林分类器,并采用 $T_{1,128}$ 作为算法的输入,进行初次相含率测量的神经网络采用 Res 模块进行特征提取,而进

行最终相含率的测量则采用极端随机森林回归器,相关参数设置参照前文,其中多任务神经网络的相含率结果取两路输出的相含率的平均值。考虑到将噪声数据作为训练数据可以提高模型的泛化能力,所以本文对比了使用噪声数据进行训练前后模型性能的变化,其中用来进行训练的噪声数据为添加了信噪比为 60~110 dB 高斯噪声的训练集数据,最终结果如图 5 所示(图 5 中 ML 表示利用极端随机森林回归器再一次进行相含率测量的模型,noise 表示该模型利用无噪声和有噪声数据进行训练)。



(a) 流型识别准确率变化曲线



(b) 相含率相对误差曲线

图 5 噪声对结果造成的影响

Fig. 5 Impact of noise on results

图 5 中的基准线为使用全局阈值分割方法^[27]对无噪声测试集数据进行相含率测量的结果,可以看出,当采用传统的阈值分割方法进行相含率测量时,其性能相当于本文中未用噪声数据训练的模型在信噪比为 60~70 dB 下的性能,这说明了传统方法进行相含率测量具有很大的局限性。此外,无论是否使用噪声数据作为训练数据,采用多任务学习的方法都可以提升模型的抗噪声干扰的能力。当模型未使用噪声数据进行训练时,本文所提出的模型在信噪比达到 90 dB 以上时进行流型识别和相含率预测方面会具有较高的准确性。而当模型利用噪声数据进行训练时,在信噪比相对较低时,其相含率测

量和流型识别的准确性都有明显的提升,这说明了利用噪声数据进行训练可以有效地提升模型的抗噪能力。然而,即使利用 60~110 dB 的数据进行了相应的训练,随着信噪比的进一步下降,其相含率测量的准确度还是会有一定的下降,而这一点反映了当信噪比相对较低时,数据的畸变程度较大。因此,即使利用同样信噪比的训练数据进行训练,也很难保证模型在遇到较大噪声干扰的情况下,依然能维持较高的准确度。

4.5 实测数据分析

为了验证本文所提出的模型的实用性,本文利用气固两相流气力输送实验平台进行相应的实验验证^[28],其中采用的固相介质为煤粉,气相介质为空气。该平台主要包含 5 个部分:载气单元、给粉单元、流型发生器、测试单元、收集单元。在实验时,首先利用鼓风机产生载气,然后通过控制风机来调整风速,再通过调节给粉机的圈数来调节质量流量,最终通过采用 12 电极的电容传感器获得 4 种流型共 500 组电容数据及其对应的流型和真实相含率(真实相含率依据流量、管道半径、风速、密度来确定^[28]),每种流型各 125 组数据,由于实验环境的限制,所获得的数据不可避免的存在一定程度的噪声,而这可以用来进行模型抗噪声干扰能力的测试。

本文利用 $L_{\text{huber}} + L_{\text{huber}}$ 损失函数组合+极端随机森林的模型来对上述实测数据进行相应的验证,该模型利用无噪声数据+60~110 dB 噪声数据进行训练,训练的步骤如前文所述,最终结果如表 4 所示。通过结果可以看出,采用本文方法能够较为准确地实现相含率测量和流型识别,能够满足工业应用的需求。

表 4 实测数据结果

Table 4 The results of experiments on real data

流型	相对误差/%	F_1 /%
中心流	3.5	98.76
环状流	4.2	98.65
层流	3.3	98.43
偏心流	3.4	98.80

5 结 论

本文提出了一种联合多任务学习和机器学习的方法,通过利用 ECT 系统来进行相含率的测量和流型识别。为了分析不同特征提取模块性能的特点,本文比较了 Res、VGG 和 Dense 3 种特征提取模块,结果表明,特征提取模块的不同对于神经网络进

行相含率测量的准确度有着明显的影响,其中采用 Res 模块的性能最好。此外,采用不同的损失函数的组合方式来训练神经网络。经过验证,本文发现对于采用不同的特征提取模块、选择合适的损失函数组合可以进一步提升模型的相含率测量的准确度,并且还说明损失函数的组合方式应当根据模型的结构来进行选择,而这两者之间的关联则是之后需要考虑解决的问题。

为了实现机器学习和深度学习的融合,本文提出了一种融合两者的方法,结果表明,采用不同单元数的全连接层的特征向量,机器学习算法均能够较为准确地实现流型识别,这一点说明神经网络在进行相含率测量任务的训练中很有可能考虑到了流型特征。这也从侧面说明本文所提出的方法对于深度学习模型的可解释性研究能够有所帮助。此外,利用机器学习使用神经网络初次测量的相含率以及流型的识别结果再一次进行相含率的测量,可以进一步提升相含率测量的准确度。

通过噪声干扰实验可以看出,本文所提出的模型在信噪比较高时性能较好,并且采用多任务神经网络相较于单任务神经网络有更好的抗噪声干扰的能力。此外,通过实验也说明了采用噪声数据作为训练数据可以有效提升模型的抗噪声干扰的能力,但是当信噪比较低时,其准确度依然会发生一定的下降,因此当遭受到较大噪声干扰时模型准确性下降是一个需要考虑的问题。为了验证本文模型的有效性,利用实测平台的数据进行验证,结果表明,本文方法可以较好地满足工业中对两相流参数测量方面的需求。

参考文献:

[1] WANTA D, MAKOWIECKA O, SMOLIK W T, et al. Numerical evaluation of complex capacitance measurement using pulse excitation in electrical capacitance tomography [J]. Electronics, 2022, 11(12): 1864.

[2] RASEL R K, STRAITON B, MARASHDEH Q, et al. Toward water volume fraction calculation in multiphase flows using electrical capacitance tomography sensors [J]. IEEE Sensors Journal, 2021, 21(6): 7702-7712.

[3] SUN Yurong, ZHANG Yuyan, WEN Yintang. Identification of defects in the inner layers of composite components based on capacitive sensing [J]. Review of Scientific Instruments, 2022, 93(9): 094710.

[4] 张立峰, 苗雨. 基于电容层析成像系统测量信号稀疏

- 性的两相流流型辨识 [J]. 计量学报, 2021, 42(7): 861-865.
- ZHANG Lifeng, MIAO Yu. Identification of two-phase flow pattern based on the sparsity of measured capacitance for electrical capacitance tomography [J]. *Acta Metrologica Sinica*, 2021, 42(7): 861-865.
- [5] WAJMAN R, BANASIAK R, BABOUT L. On the use of a rotatable ECT sensor to investigate dense phase flow; a feasibility study [J]. *Sensors*, 2020, 20(17): 4854.
- [6] ZHU Hai, SUN Jiangtao, LONG Jun, et al. Deep image refinement method by hybrid training with images of varied quality in electrical capacitance tomography [J]. *IEEE Sensors Journal*, 2021, 21(5): 6342-6355.
- [7] RODRIGUEZ-FRIAS M A, YANG Wuqiang. Dual-modality 4-terminal electrical capacitance and resistance tomography for multiphase flow monitoring [J]. *IEEE Sensors Journal*, 2020, 20(6): 3217-3225.
- [8] SHEN Jingjing, MENG Shuanghe, WANG Jing, et al. Study on the shape of staggered electrodes for 3-D electrical capacitance tomography sensors [J]. *IEEE Transactions on Instrumentation and Measurement*, 2021, 70: 1-10.
- [9] HOSSAIN M S, ABIR M T, ALAM M S, et al. An algorithm to image individual phase fractions of multiphase flows using electrical capacitance tomography [J]. *IEEE Sensors Journal*, 2020, 20(24): 14924-14931.
- [10] LIU Kunhua, YE Zihao, GUO Hongyan, et al. FISS GAN: a generative adversarial network for foggy image semantic segmentation [J]. *IEEE/CAA Journal of Automatica Sinica*, 2021, 8(8): 1428-1439.
- [11] MOSTOFA M, FERDOUS S N, RIGGAN B S, et al. Joint-SRVDNet: joint super resolution and vehicle detection network [J]. *IEEE Access*, 2020, 8: 82306-82319.
- [12] HE Kaiming, ZHANG Xiangyu, REN Shaoqing, et al. Deep residual learning for image recognition [C]//2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Piscataway, NJ, USA: IEEE, 2016: 770-778.
- [13] SIMONYAN K, ZISSERMAN A. Very deep convolutional networks for large-scale image recognition [C/OL]//Proceedings of the 3rd International Conference on Learning Representations. London, UK: ICLR, 2015 [2022-06-20]. https://www.engineeringvillage.com/app/doc/?docid=cpx_M2fa5a91416ccf2afed5M7ae310178163131&pageSize=25&index=1&searchId=11caf3da2de742aca9c94f85991467f2&resultsCount=1&usageZone=resultslist&usageOrigin=searchresults&searchType=Quick.
- [14] HUANG Gao, LIU Zhuang, VAN DER MAATEN L, et al. Densely connected convolutional networks [C]//2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Piscataway, NJ, USA: IEEE, 2017: 2261-2269.
- [15] ZHAO Jiejie, DU Bowen, SUN Leilei, et al. Deep multi-task learning with relational attention for business success prediction [J]. *Pattern Recognition*, 2021, 110: 107469.
- [16] PATEL V S, NIE Zhongliang, LE T N, et al. Masked face analysis via multi-task deep learning [J]. *Journal of Imaging*, 2021, 7(10): 204.
- [17] ZHANG Yu, YANG Qiang. A survey on multi-task learning [J]. *IEEE Transactions on Knowledge and Data Engineering*, 2022, 34(12): 5586-5609.
- [18] 王化祥, 王超, 陈磊. 基于 Landweber 迭代的图像重建算法 [J]. *信号处理*, 2000, 16(4): 354-356, 328. WANG Huaxiang, WANG Chao, CHEN Lei. An image reconstruction algorithm based on the Landweber iteration method [J]. *Signal Processing*, 2000, 16(4): 354-356, 328.
- [19] YE Jiamin, YANG Wuqiang, WANG Chao. Investigation of spatial resolution of electrical capacitance tomography based on coupling simulation [J]. *IEEE Transactions on Instrumentation and Measurement*, 2020, 69(11): 8919-8929.
- [20] ZHENG Jin, PENG Lihui. A deep learning compensated back projection for image reconstruction of electrical capacitance tomography [J]. *IEEE Sensors Journal*, 2020, 20(9): 4879-4890.
- [21] ZHU Hai, SUN Jiangtao, XU Lijun, et al. Permittivity reconstruction in electrical capacitance tomography based on visual representation of deep neural network [J]. *IEEE Sensors Journal*, 2020, 20(9): 4803-4815.
- [22] ZHANG Lifeng, DAI Li. Image reconstruction of electrical capacitance tomography based on adaptive support driven Bayesian reweighted algorithm [J]. *IEEE Sensors Journal*, 2021, 21(18): 20648-20656.
- [23] OSPINA-ACERO D, MARASHDEH Q M, TEIXEIRA F L. Relevance vector machine image reconstruction algorithm for electrical capacitance tomography with explicit uncertainty estimates [J]. *IEEE Sensors Journal*, 2020, 20(9): 4925-4939.
- [24] LI Jianwei, YANG Xiaoguang, WANG Youhua, et al. An image reconstruction algorithm based on RBF neural network for electrical capacitance tomography

[C]//2012 Sixth International Conference on Electromagnetic Field Problems and Applications. Piscataway, NJ, USA: IEEE, 2012: 1-4.

[25] 陈露阳, 尹佳雯, 孙志强, 等. 基于 EEMD-Hilbert 谱的气液两相流钝体绕流流型识别 [J]. 仪器仪表学报, 2017, 38(10): 2536-2546.

CHEN Luyang, YIN Jiawen, SUN Zhiqiang, et al. Flow regime identification of gas-liquid two-phase flow with flow around bluff-body based on EEMD-Hilbert spectrum [J]. Chinese Journal of Scientific Instrument, 2017, 38(10): 2536-2546.

[26] DEABES W, ABDEL-HAKIM A E, BOUAZZA K E, et al. Adversarial resolution enhancement for electrical capacitance tomography image reconstruction [J]. Sensors, 2022, 22(9): 3142.

[27] OTSU N. A threshold selection method from gray-level histograms [J]. IEEE Transactions on Systems, Man, and Cybernetics, 1979, 9(1): 62-66.

[28] 王小鑫. 基于静电/电容传感器的气固两相流动参数检测方法研究 [D]. 西安: 西安交通大学, 2017.

(编辑 刘杨)