

DOI:10.19651/j.cnki.emt.2108304

基于双通道混合网络融合支持向量机的 电容层析成像流型辨识^{*}

马敏 李继伟 曾田

(中国民航大学电子信息与自动化学院 天津 300300)

摘要: 针对两相流流型辨识精度低的问题,提出一种基于双通道混合网络融合支持向量机的流型辨识算法。通过多尺度卷积核对电容向量进行多尺度特征提取丰富特征层信息,利用压缩激励网络(SENet)关注卷积核通道上重要特征张量,调整各通道的重要占比,此外引入多头自注意力机制对电容向量的深度特征进行学习。将带有SENet的多尺度卷积通道与多头自注意力通道进行特征融合形成双通道辨识模型,最后将双通道模型有效捕捉到的电容向量特征的特征送入支持向量机中进行训练并测试。仿真实验结果表明,相比于BP神经网络、SVM、1DCNN算法,所提算法在流型辨识中的平均辨识率显著提升,高达98.6%。

关键词: 多尺度特征;压缩激励网络;支持向量机;电容层析成像;流型辨识

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

Flow pattern identification of capacitance tomography based on dual-channel hybrid network fusion support vector machine

Ma Min Li Jiwei Zeng Tian

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

Abstract: To solve the problem of low identification accuracy of two-phase flow pattern, a flow pattern identification algorithm based on two-channel hybrid network fusion support vector machine was proposed. Multi-scale feature extraction of rich feature layer information was carried out by multi-scale convolution check of capacitance vector. Squeeze-and-excitation networks was used to focus on the important feature tensor of convolutional kernel channel and adjust the importance proportion of each channel. In addition, multi-scale attention mechanism was introduced to learn the depth feature of capacitance vector. The multi-scale convolutional channel with SENet and multi-attention channel were fused to form a two-channel identification model. Finally, the features of capacitance vector effectively captured by the two-channel model were sent to support vector machine for training and testing. Simulation results show that compared with BP neural network, SVM and 1DCNN algorithms, the average identification rate of the proposed algorithm in flow pattern identification is significantly improved, reaching 98.6%.

Keywords: multi-scale feature; squeeze-and-excitation networks; support vector machine; electrical capacitance tomography; flow pattern identification

0 引言

实际工业化生产过程中,不同形态物质混合流动的情况频频发生,称之为两相流^[1]。例如,航空航天领域中发动机滑油管中的滑油和金属颗粒,能源领域中天然气和油的混合等。流型是两相流测量的重要研究方向之一,不同流型具有不同的传热、传质性,无法准确辨识流型将影响两相

流的监测^[2]。

电容层析成像技术(electrical capacitance tomography, ECT)作为一种工艺层析成像技术,具备非侵入性、安全系数高、响应速度快、安装便捷以及成本低廉等特点,得到了国内外研究人员的广泛关注^[3]。目前基于电容层析成像技术的流型辨识方法主要有两种:1)通过ECT图像重建进行的流型辨识^[4];2)根据ECT测量数据进行流型辨识。如:

收稿日期:2021-11-09

*基金项目:国家基金面上项目(61871379)资助

2010 年, 乔立勇^[5]提出基于 BP 神经网络算法的流型辨识; 2018 年, Fu 等^[6]通过搭建人工神经网络对气固两相流进行辨识; 2021 年, 张立峰等^[7]又提出基于 MO-PLP-ELM 算法的流型辨识。上述学者所提方法在流型区别度较大时有较好的辨识效果, 但在复杂、区分度小的工业化生产过程中流型辨识效果不佳, 无法满足高精度的需求, 而深度学习凭借其强大的学习和表征能力独树一帜^[8], 为 ECT 的流型辨识提供了新的解决途径。

针对复杂、区分度小的流型辨识效果不佳的问题, 在深度学习理论的基础上进行拓展性研究实验, 提出一种基于双通道混合网络融合支持向量机的流型辨识算法。首先根据 ECT 测量电容数据中电容个数少的特点, 设计一维多尺度卷积神经网络模型 (multiscale convolutional neural network, MSCNN), 在不同感受野下进行多特征提取^[9]。其次, 将多头自注意力 (multi-head self-attention, MA) 与多尺度卷积神经网络结合, 通过计算电容向量中单一值与其他值之间的权重来得到它们之间的相关程度, 捕获电容序列可能存在的长距离依赖特征, 从而达到对输入电容向量关键特征的获取。此外, MSCNN 中多尺寸卷积核通道会获取无效的特征张量信息, 加入压缩激励网络, 对不同的特

征通道进行加权将有用的特征信息加强并抑制无用的特征^[10]。最后, 将 MA 通道和带有压缩激励网络 (squeeze-and-excitation networks, SENet) 的多尺度卷积神经网络通道得出的特征融合后输入支持向量机 (support vector machine, SVM) 中, 在保证输入特征正确的情况下寻找到最优超平面从而完成流型的辨识^[11]。

1 算法原理与方法

双通道混合网络融合支持向量机算法 (two-channel hybrid network fusion support vector machine, TCSVM) 的网络结构如图 1 所示, 其中 Input 是多组 66×1 电容向量值, Output 代表流型类别, MSCNN 为多尺度卷积神经网络结构, Linear 为线性变换, Q, K, V 为输入向量乘上不同的权重矩阵后得到的结果, Scale Dot-Product Attention 是缩放的点积注意力, Concat 为数组的合并操作。TCSVM 将多组电容值作为输入, 通过一维多尺度卷积网络获取更宽泛的特征信息, 利用 SENet 关注卷积核通道上重要特征张量, 调整各通道的重要占比, 此外引入多头自注意力机制对电容向量的深度特征进行学习。特征提取层将有效捕捉到的电容向量特征的特征输入支持向量机中进行训练, 最后进行流型辨识。

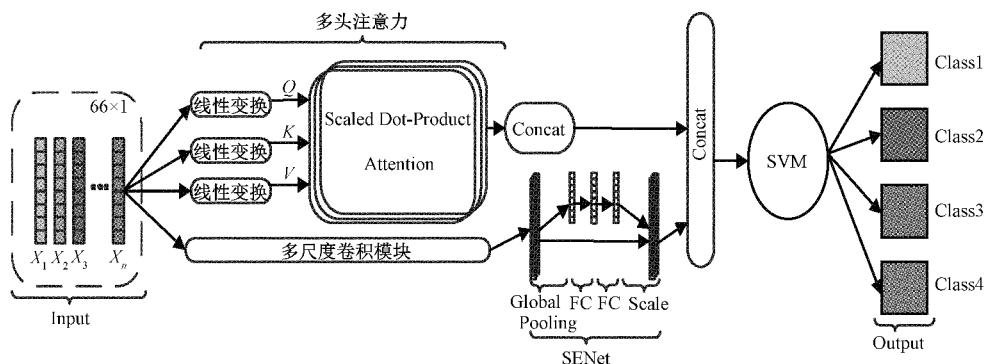


图 1 TCSVM 网络结构

1.1 多尺度卷积神经网络

卷积神经网络的单一卷积核在提取特征时无法完整获取输入的特征信息^[12]。多尺度卷积神经网络用多尺度卷积层代替原始的单一卷积层, 使得网络变得更宽而不是简单的变深, 达到实现对特征的多尺度提取^[13], 多尺度卷积层设计结构如图 2 所示。

卷积层特点是通过多层卷积核对输入数据进行特征提取, 运算过程可以看成是输入特征矩阵与卷积核的内积, 多尺度卷积基本表达式如式(1)所示。

$$\mathbf{y}_j^{k+1} = f \left[\sum_{m \in M} (\mathbf{x}_j^k * \mathbf{w}_j^k) + b_j^k \right] \quad (1)$$

式中: \mathbf{y}_j^{k+1} 是第 $k+1$ 个卷积层的第 j 个输入的特征张量; M 代表输入的全部特征向量; \mathbf{x}_j^k 是第 k 个卷积层的第 j 个输出的特征张量, k 在多尺度卷积层中代表所属分支; \mathbf{w}_j^k 为第 k 层的第 j 个权值; b_j^k 为第 k 个输出的偏差; $f(\cdot)$ 为激活函数。

在保证映射关系不变的情况下, 池化层通过对卷积层得到的特征张量进行降采样, 实现降低维度的目的。池化的基本计算公式如式(2)所示。

$$\mathbf{y}_i^{(k-1)} = \text{pooling}(\mathbf{y}_i^k) \quad (2)$$

式中: $\text{pooling}(\cdot)$ 代表池化函数。

1.2 多头自注意力

自注意力机制是注意力机制的变形, 它可以减少网络对过多冗余无用信息的关注, 更有效的聚焦数据内部少量的重要信息^[14], 自注意力机制结构如图 3 所示。

具体计算过程抽象化后可以总结为两个步骤: 1) 根据 Query 和 Key 计算权重系数; 2) 通过权重系数对 Value 进行加权求和。其中过程 1 可细分为根据 Query 和 Key 计算两者的相似度和分值的归一化处理^[15], 计算过程如式(3)所示。

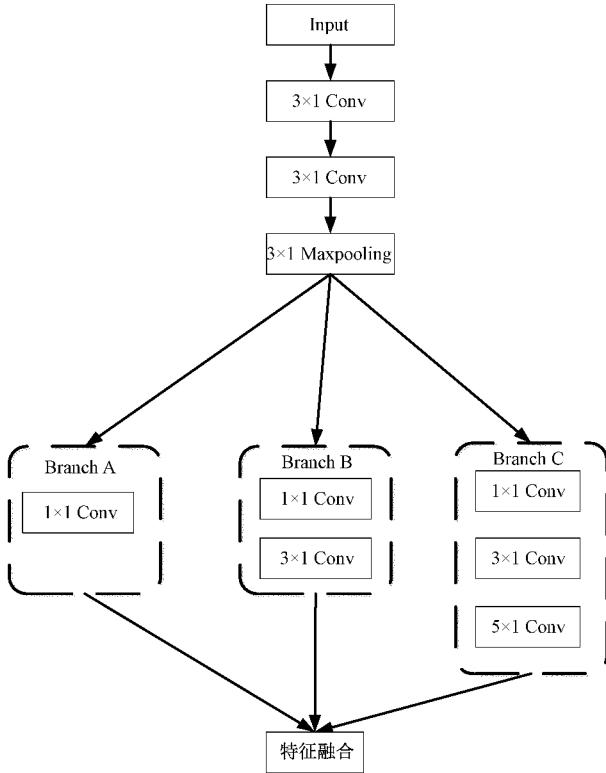


图 2 多尺度卷积层结构

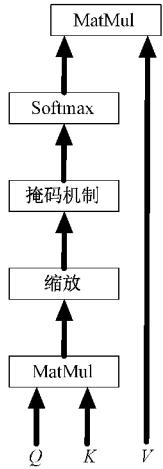


图 3 自注意力机制结构

$$\begin{cases} \mathbf{Q} = \mathbf{X} \cdot \mathbf{W}^Q \\ \mathbf{K} = \mathbf{X} \cdot \mathbf{W}^K \\ \mathbf{V} = \mathbf{X} \cdot \mathbf{W}^V \end{cases} \quad (3)$$

式中: \mathbf{X} 为自注意力机制的输入电容向量序列; \mathbf{W}^Q 、 \mathbf{W}^K 、 \mathbf{W}^V 为电容向量序列乘上不同的权值矩阵; \mathbf{Q} 、 \mathbf{K} 、 \mathbf{V} 分别是 Query、Key、Value 的简写。

单头注意力的输出计算公式为:

$$\text{Attention}(\mathbf{Q}, \mathbf{K}, \mathbf{V}) = \text{softmax}\left(\frac{\mathbf{Q}\mathbf{K}^T}{\sqrt{d_k}}\right)\mathbf{V} \quad (4)$$

式中: \mathbf{Q} 、 \mathbf{K} 、 \mathbf{V} 分别为式(3)得到的矩阵, \mathbf{K} 的第二维度为

d_k , 除以 $\sqrt{d_k}$ 的过程就是图 3 中 scale 的过程

多头自注意力机制本质上可以理解为 Query 和一系列的 Key-Value 对映射出一个输出, 也就是自注意力进行多次运算后将其结果进行拼接成一个矩阵。

$$\text{MultiHead}(\mathbf{Q}, \mathbf{K}, \mathbf{V}) = \text{Concat}(\text{head}_1, \dots, \text{head}_h)\mathbf{W}^O \quad (5)$$

$$\text{head}_m = \text{Attention}(\mathbf{Q}\mathbf{W}_m^Q, \mathbf{K}\mathbf{W}_m^K, \mathbf{V}\mathbf{W}_m^V), m \in [1, h] \quad (6)$$

式中: h 为注意力头的数量, Concat 是拼接各个注意力头的输出值的函数, \mathbf{W}^O 是多头注意力的权数矩阵, \mathbf{W}_m^Q 、 \mathbf{W}_m^K 、 \mathbf{W}_m^V 为第 m 个注意力头的权重矩阵。

1.3 高效通道注意力

在多尺度卷积神经网络的作用下, 网络可以学习到更加宽泛的电容特征, 但输入电容值特征张量中无效的特征同样也会被捕捉, 这极大地阻碍了网络本身对于信息的获取, 为此引入高效通道注意力机制。采用特征重标定的策略表示通道之间的相互依赖关系, 从而获取通道特征间的重要程度提升网络性能^[16]。SENet 有挤压(squeeze)、激励(excitation)和缩放(scale)三个关键操作。

1) squeeze

挤压通常通过全局平均池化将 $H \times W \times C$ 的原始输入压缩为 $1 \times 1 \times C$, 从而获得较广阔的感受野, 具体计算过程如下:

$$Z_C = F_{sq}(u_c) = \frac{1}{H \times W} \sum_{i=1}^H \sum_{j=1}^W u_c(i, j) \quad (7)$$

式中: u_c 第 C 个卷积层的输出, H 和 W 是特征张量的高度和宽度, Z_C 是第 C 个通道的特征权重。

2) excitation

激励操作通过参数 w 为特征通道生成不同的权重, 在得到上述式中的 Z_C 后通过全连接层对 MSCNN 的各个通道的重要性进行预测, 其中各个通道之间的关系通过 Sigmoid 的选通机制获取^[17]:

$$s = F_{ex}(Z, W) = \sigma(g(Z, W)) = \sigma(W_2 \text{Relu}(W_1 Z)) \quad (8)$$

式中: W_1, W_2 是参数矩阵, σ 是 Sigmoid 激活函数

激励操作采取两个全连接层的沙漏型结构降低网络复杂程度提高泛化能力, 第 1 个全连接层作用是降维, 后一个全连接层起到恢复原始维度的作用。

3) scale

缩放操作是将激励的输出权重通过运算逐通道的加入到之前的特征上, 从而完成 SENet 对原始特征张量的重新标定, 计算公式如式(9)所示。

$$\tilde{\mathbf{X}}_c = F_{scale}(u_c, s_c) = u_c \times s_c \quad (9)$$

式中: $\tilde{\mathbf{X}}_c$ 是加权得到的新特征张量, u_c 是二维矩阵, s_c 是权重。

1.4 支持向量机

支持向量机是一种进行分类和回归分析的监督式学

习方法^[18]。增加软间隔后,目标优化求解如下:

$$\min_{\omega} \frac{1}{2} \|\omega\|^2 + C \sum_{i=1}^m \delta_i \quad (10)$$

$$\text{s.t. } y_i(\omega * x_i + b) \geq 1 - \delta_i, \delta_i \geq 0, i = 1, \dots, N \quad (11)$$

式中: ω 是权重向量, C 是目标优化的惩罚参数, δ_i 是松弛变量, b 是标量。

每一个样本中都有一个与之对应的松弛变量,表示样本不满足约束的程度,而惩罚参数越大,对分类的惩罚也就越大。

针对电容传感器所测电容数据非线性可分的特点,非线性支持向量机将有限维度的电容数据特征映射到更高维度向量空间内,此时非线性问题就转变成线性可分的电容数据特征分类问题,从而可以按照线性支持向量机的方法去优化目标函数。“电容向量一流型”数据集从而可以表示为 $A = \{(x_1, y_1), (x_2, y_2), (x_3, y_3), \dots, (x_N, y_N)\}$, $x_N \in R^n$, $y_N \in [-1, 1]$, 其中 x_N 是第 N 个输入特征, y_N 是 x_N 对应的标签。

为实现非线性 SVM 模型,采用一种局部性很强的高斯径向基函数,将电容向量特征映射到无穷维的空间内,数据集的数据特征无论大小都具有不错的效果。其本质上还是将非线性可分的数据线性可分,其中高斯核函数定义为:

$$k(x, x_i) = \exp\left(-\frac{x - x_i^2}{2\beta^2}\right) \quad (12)$$

式中: x_i 为核函数中心, β 为带宽控制其作用的范围。在选择合适的核函数 $k(x, x_i)$ 与参数 C 之后,即获得最终的分离超曲面。

分类决策函数定义为:

$$f(x) = \text{sign} \left[\sum_{i=1}^N \alpha_i^* y_i k(x, x_i) + \theta^* \right] \quad (13)$$

式中: α_i^* 、 θ^* 均为优化参数。

每个 SVM 根据决策函数对一个新的数据 x_i 得出结果,将其与其他的决策函数得出的结果进行投票,得票最多就是该数据的分类结果^[19],若平票则取索引小的类别。其中径向基函数中的参数和惩罚因子采取网格化搜索的方法去寻找最优的参数。

2 基于 TCSVM 的电容层析成像流型辨识

2.1 ECT 系统的基本原理

ECT 系统主要是由电容传感器模块、电容数据采集模块、图像重建模块 3 部分所构成,ECT 系统装置如图 4 所示。

管内非导电物质发生变化时会导致系统两侧传感器测量的电容值发生变化,ECT 系统就是通过测量电容值的变化去重建管内的介电常数,最后从重建图像信息中提取两相流的相关参数,实时监测两相流变化的装置。若电容



图 4 ECT 系统装置图

传感有 N 个电极,由互易定理可知,能够获得的独立电容值数目 P 为:

$$P = \frac{N(N-1)}{2} \quad (14)$$

选用天津大学研制的 12 电极 ECT 系统,获得 66 个独立电容值,电容幅值如图 5 所示。

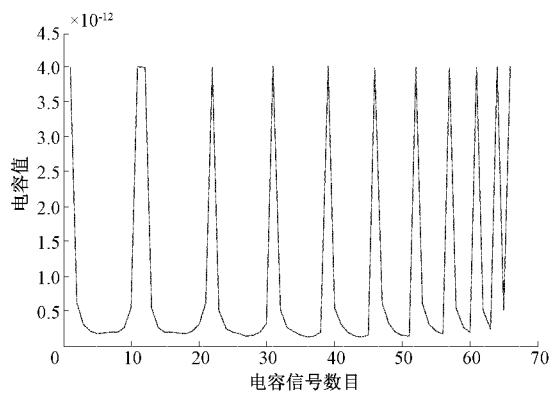


图 5 电容幅值图

2.2 基于 TCSVM 的电容层析成像流型辨识算法模型设计

在构建 MSCNN 通道的过程中,为了提高辨识的准确性选取交叉熵损失函数,为了解决梯度消失以及模型收敛速度不稳定选用 ReLU 激活函数,采用 RMSProp 优化器以消除梯度下降过程中的摆动来加速梯度下降,其中学习率设置为 0.001,采用小批量的方法每次训练输入 8 组数据,Branch A、B、C 中均为 Conv1D。MA 通道将电容向量线性变换为 3 组 32 维的向量,以对应自注意力机制的 Q 、 K 、 V ,其中多头个数为 2。对于算法模型对应的参数,如表 1 所示。

TCSVM 算法模型将 MA 通道和带有 SENet 的多尺度卷积神经网络通道得出的特征融合后输入支持向量机,训练模型后用测试集去验证模型的效果,获得的算法模型较之 1DCNN 有较大的提升。算法模型流程分为 5 个步骤:

1)选取多种典型流型,将其电容值进行归一化处理,并将每一种电容值打上标签,使之形成“电容向量一流型”数据集。

表 1 网络结构设计

通道	特征提取网络	卷积核尺寸
多尺度卷积模块	Conv1D_1	3×1
	Conv1D_2	3×1
	MaxPooling1	3×1
	Branch A	1×1
	Branch B	1×1
		3×1
	Branch C	1×1
		3×1
		5×1
	MaxPooling1	3×1
多头注意力模块	Dropout	0.2
	多头个数	2

2) 将电容值作为模型的输入, MSCNN 通道在 SENet 的作用下抑制无用特征信息, 使得该通道能聚焦有效特征张量, 而 MA 通道会更加关注输入电容向量的深度信息。

3) 将双通道模型所获取的特征进行融合操作后输入支持向量机中。

4) SVM 的径向基函数中的参数和惩罚因子采用网格化搜索寻找适合特征的最优参数。

5) 将测试集的数据输入训练好的算法模型中, 得到两相流的流型辨识结果。

3 实验及结果分析

3.1 数据集的构建

针对两相流中的气固两相流流型辨识问题, 采用 COMSOL 仿真软件建立 12 电极 ECT 管道模型, 用 MATLAB 去获取网络模型的输入样本即 4 类典型流型电容向量。管道内壁和外壁的半径, 分别为 46 mm 和 50 mm, 管道内填充材料为玻璃以及空气, 相对介电常数分别为 4.2 和 1.0。对模型的管道、壁面和屏蔽层进行剖分, 剖分有效单元数目为 3 228 个网格, 如图 6 所示。

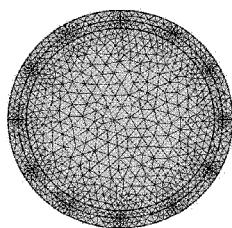


图 6 网格剖分图

选取的 4 类两相流流型, 如图 7 所示包括核心流、双泡流、十字流以及环形流, 依此将 4 种流型定义为 0、1、2、3 的标签。其中 4 种流型各有 1 210 组样本, 合计 4 840 组。每类流型选取 1 010 组作为训练集, 200 组作为测试集, 同时在训练集中选取 600 组样本作为验证集来验证训练后模型的准确性。

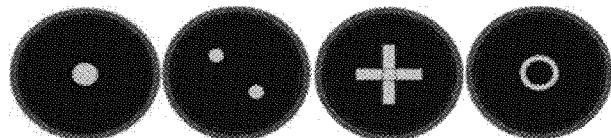


图 7 数据集样本模型

3.2 评价指标

为了客观的定量分析不同算法的流型辨识效果优劣, 引入辨识精度和召回率作为综合评价指标。

辨识精度表示算法对给定电容向量测试集, 预测正确样本个数占总样本个数的比例, 计算公式如式(15)所示。

$$Acc = \frac{\sum_{i=1}^n T_i P_i}{\sum_{i=1}^n T_i P_i + \sum_{j=1, j \neq i}^n F_j P_i} \quad (15)$$

式中: $T_i P_i$ 和 $F_j P_i$ 分别代表不同流型预测准确的个数, 错误的误判为其他流型的个数。

召回率表示预测准确样本个数在真实流型分布中所占比例, 对应计算公式如式(16)所示。

$$Recall = \frac{T_i P_i}{T_i P_i + \sum_{j=1, j \neq i}^n F_j P_i} \quad (16)$$

其中出现的参数与式(15)中保持一致。

3.3 实验结果分析

实验的运行平台是 AMD Ryzen 7 4800H CPU@2.9 GHz, GPU 为 GeForce GTX1650, Windows 10 64 位的操作系统, 内存容量为 16 GB, 基于 keras 深度学习框架搭建网络模型。

为验证双通道混合网络融合支持向量机算法对解决流型辨识精度低的问题比单通道算法模型有更好的效果, 将使用带有 Softmax 分类器的多尺度卷积神经网络、多尺度卷积神经网络融合支持向量机算法以及带有 SENet 的多尺度卷积神经网络融合支持向量机算法进行测试, 结果如图 8 所示。测试结果表明双通道混合网络融合支持向量机算法能够更深层次、更宽泛的提取电容特征张量特征, 提高流型辨识的精度。

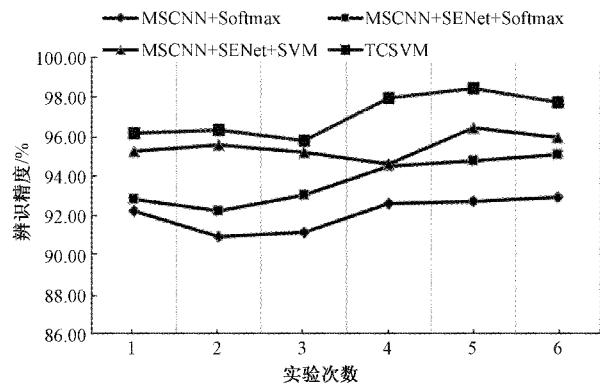


图 8 不同模型辨识精度对比

以外,将 TCSVM 算法模型与已发表论文中的 BP 神经网络、支持向量机以及 1DCNN 算法进行实验比较,其平均辨识精度如图 9 所示。

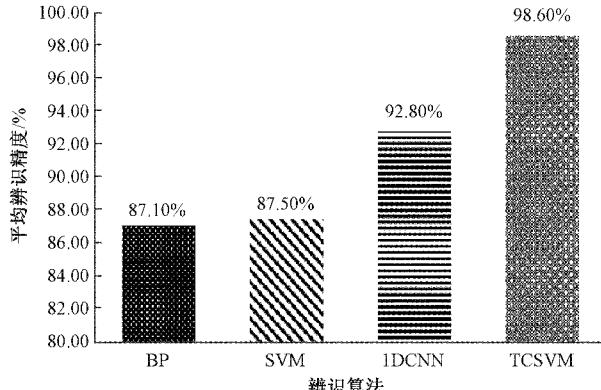


图 9 平均辨识精度

由图(9)可知,采用 BP 神经网算法的平均辨识率最低,SVM 次之,1DCNN 算法做出的两相流流型辨识精度比 BP 神经网络有所提高,而 TCSVM 算法的平均辨识结果明显优于其他算法。

平均辨识结果无法显示测试集中各个流型辨识的程度,为此引入召回率混淆矩阵表示测试集各个流型的辨识精度,横轴为实际判别结果的流型的标签,纵轴是真实流型的标签,TCSVM 算法与其他算法结果如图 10 所示。

由图 10(a)和(b)比较得出 BP 神经网络和 SVM 算法对流型 3 的辨识效果较差,此时传统算法无法准确识别复杂流型的问题很容易就凸显出来。同时,前 3 种算法对于环形流和核心流这两种相似程度高的流型也没有较高的辨识精度。而 TCSVM 算法对于流型的辨识准确率非常高,与其他 3 种算法相比具有很好的效果,对于前 3 种流型的辨识几乎完全正确,且平均准确率可达到 98.6%。

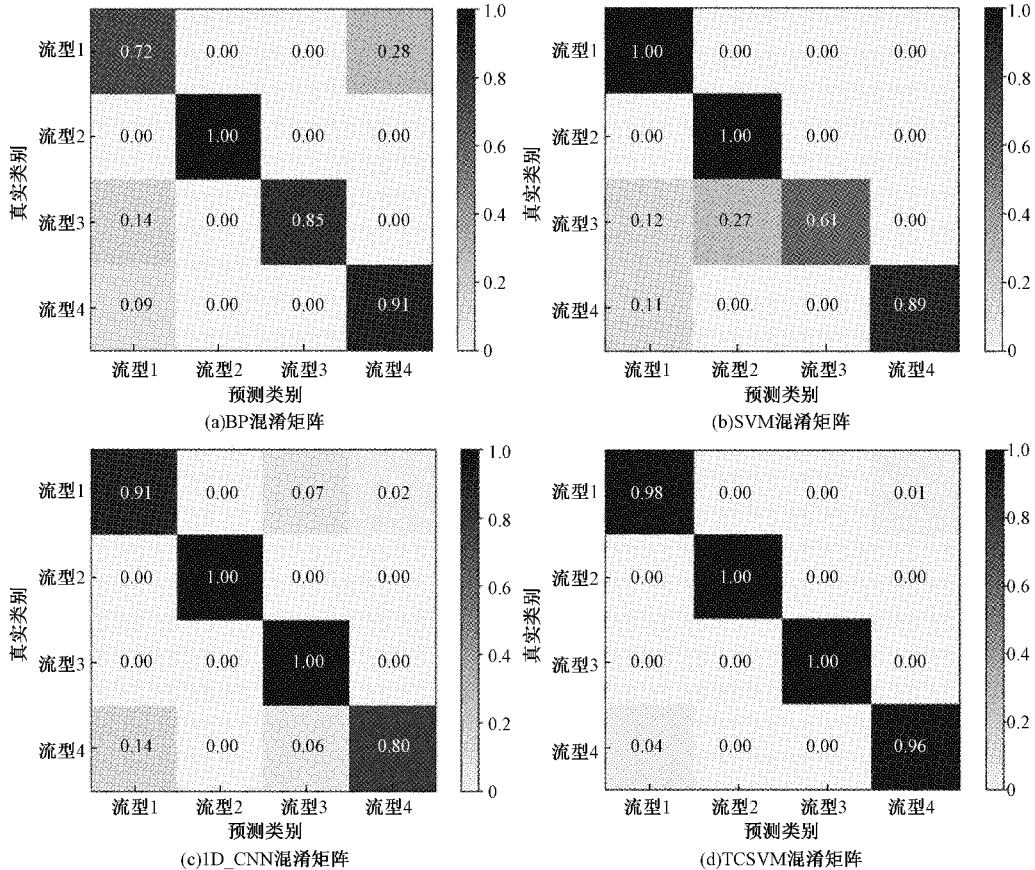


图 10 模型混淆矩阵

采用 t 分布随机邻域嵌入(t-distributed stochastic neighbor embedding, t-SNE)对 TCSVM 进行特征可视化,

图像显示用 TCSVM 提取的特征在二维空间上的聚类较为清晰,结果如图 11 所示。

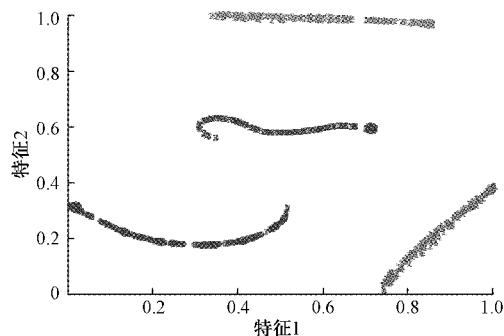


图 11 输出特征分布

4 结 论

针对两相流流型辨识难的问题,构建双通道混合网络模型,通过多头注意力机制挖掘电容特征张量深层表征特性,并利用 SENet 模块对多尺度卷积神经网络捕获的电容细节特征校准重分配,使网络模型具备双向特征提取能力。流型辨识测试结果表明,TCSVM 算法在复杂、相似程度高的流型中,具有更高的辨识精度,平均辨识率比 BP 神经网络、SVM 以及 1DCNN 算法分别提高 11.5%、11.1%、5.8%,为工业化生产过程中所出现的两相流流型辨识问题提供了新的解决方案。

由于采用的多尺度卷积神经网络模块获得不同感受野的同时也增加了网络的计算复杂度,使得训练过程耗费较多的时间,下一步工作将考虑采用空洞卷积等方法进一步减少模型的复杂程度。

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] 张立峰, 王化祥. 基于 SVM 及电容层析成像的两相流流型识别[J]. 仪器仪表学报, 2009, 30(4): 812-816.
- [3] 马敏, 王涛, 王力. 基于深度学习的滑油监测方法研究[J]. 推进技术, 2020, 41(5): 1159-1167.
- [4] 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.
- [5] 乔立勇. 基于特征提取和神经网络的 ECT 流型辨识的研究[D]. 哈尔滨: 哈尔滨理工大学, 2010.
- [6] FU F F, LI J. Gas-solid two-phase flow pattern identification based on artificial neural network and electrostatic sensor array[J]. Sensors, 2018, 18(10): 3522-3533.
- [7] 张立峰, 朱炎峰. 基于 MO-PLP-ELM 及电容层析成像的两相流流型辨识[J]. 计量学报, 2021, 42(3): 334-338.
- [8] MD Z A, TAREK M T, CHRIS Y. A State-of-the-art survey on deep learning theory and architectures[J]. Electronics, 2019, 8(3): 292.
- [9] 卞景艺, 刘秀丽, 徐小力, 等. 基于多尺度深度卷积神经网络的故障诊断方法[J]. 振动与冲击, 2021, 40(18): 204-211.
- [10] 蔡伟龙, 毛建华. 基于多头自注意力和 SENet 的远程监督关系抽取[J]. 电子测量技术, 2020, 43(21): 132-136.
- [11] 赵燕锋, 冯早, 朱雪峰, 等. 复杂工况下基于时频图像和 CNN-SVM 的管道堵塞识别研究[J]. 电子测量与仪器学报, 2021, 35(2): 161-170.
- [12] 胡晓依, 荆云建, 宋志坤, 等. 基于 CNN-SVM 的深度卷积神经网络轴承故障识别研究[J]. 振动与冲击, 2019, 38(18): 173-178.
- [13] 郭晨, 简涛, 徐从安, 等. 基于深度多尺度一维卷积神经网络的雷达舰船目标识别[J]. 电子与信息学报, 2019, 41(6): 1302-1309.
- [14] 熊璇, 严佩敏. 融合多头自注意力机制的中文分类方法[J]. 电子测量技术, 2020, 43(10): 125-130.
- [15] 张仰森, 周炜翔, 张禹尧, 等. 一种基于情感计算与层次化多头注意力机制的负面新闻识别方法[J]. 电子学报, 2020, 48(9): 1720-1728.
- [16] 王立鹏, 张智, 苏丽, 等. 基于多特征融合的自适应权重目标分类方法[J]. 华中科技大学学报(自然科学版), 2020, 48(9): 38-43.
- [17] 常昊, 陈晓雷, 张爱华, 等. 嵌入改进 SENet 的卷积神经网络连续血压预测[J]. 计算机工程与应用, 2021, 57(7): 130-135.
- [18] QIAO S, SHEN D, WANG X, et al. A self-adaptive parameter selection trajectory prediction approach via hidden Markov models[J]. Journal of Engineering, 2015, 16(1): 284-296.
- [19] YUAN C, CLARENCE W S, BING L, et al. Application of feature extraction through convolution neural networks and SVM classifier for robust grading of apples[J]. Instrumentation, 2019, 6(4): 59-71.

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