

基于混合神经网络参数优化的两相流流型识别方法

王萌,张松,施艳艳,杨珍,史水娥

(河南师范大学 河南省光电传感集成应用重点实验室,河南 新乡 453007)

摘要:针对气液两相流传感器测量数据的强非线性和非平稳性导致流型识别困难的问题,提出一种基于混合神经网络参数优化的流型识别方法.所提方法首先采用滑动窗口法将传感器测得的不同流型电导率数据分割为若干子序列,再利用变分模态分解算法获得各子序列的固有模式函数,通过提取固有模式函数的 Hjorth 特征数据集实现对各子序列非线性特征的描述.接着,将随机森林算法引入卷积神经网络的分类层,进而构建混合神经网络,并采用鲸鱼算法对混合神经网络中 3 个超参数进行优化.最后,采用优化后的混合神经网络对 Hjorth 参数特征向量数据集进行分类,进而实现流型识别.实验结果表明,所提方法对 4 种流型的平均辨识准确率达到 98.52%.

关键词:气液两相流;Hjorth 参数;混合神经网络;随机森林

中图分类号:O359

文献标志码:A

文章编号:1000-2367(2025)03-0121-07

气液两相流广泛存在于石油、化工、核工业等众多工程领域^[1],其流型识别对提高工业生产经济性和安全性具有重要意义^[2].然而,受流动状态的随机性、时变性等因素影响,作用在流体上的力与参数之间的关系非常复杂,难以定量描述^[3],导致流型的准确识别较为困难.

现有流型识别方法主要分为两类^[4]:一类是直接观测高速摄像机拍摄的流体流动状态图片进行流型识别^[5],此类方法仅能在透明管道情况下使用,具有较大的局限性^[6];另一类则是根据传感器采集的压力信号、压差信号、电导率信号等测量信号进行流型识别^[7],该类方法具有适应性强、灵活性高、实时性好等优点,目前已成为流型识别的主流方法^[8].通过传感器采集信号进行流型识别的方法主要涉及特征信息的提取与流型分类两个关键步骤.文献[9]将得到的测量信号通过多尺度小波分析分解为 6 个尺度,然后提取每个尺度的平均值和标准差等统计特征信息并采用支持向量机(support vector machine,SVM)进行特征信息分类;文献[10]基于传感器测量的电阻率信息,提取每个流型的统计特征信息并采用人工神经网络进行流型分类;文献[11]在提取各流型统计特征信息基础上,采用最小二乘支持向量机(least square-support vector machine,LS-SVM)对流型进行分类.然而,在特征信息提取方面,以上方法只提取信号的统计特征将遗失其非线性特征,造成流型识别准确率下降;在流型分类方面,以上方法受单一分类算法性能的限制,特征信息分类精度不高.基于以上问题,文献[12]采用优化的范围排列熵方法进行特征信息提取,可准确获得测量信号的非线性特征;文献[13]将 CNN(convolutional neural network,CNN)和 SVM 结合构建混合分类算法并将其用于流型识别,获得了较好的分类效果.

鉴于此,本文提出了一种基于混合神经网络参数优化的气液两相流流型识别方法.首先,采用滑动窗口法

收稿日期:2024-01-10;**修回日期:**2024-02-08.

基金项目:国家自然科学基金(61903127);河南省高校科技创新人才支持计划(21HASTIT018).

作者简介:王萌(1980—),男,河南新乡人,河南师范大学教授,博士,研究方向为两相流在线检测技术,E-mail:wangmeng@htu.edu.cn.

通信作者:施艳艳(1982—),女,山东莱芜人,河南师范大学教授,博士生导师,研究方向为两相流在线检测技术,E-mail:yyshil13@hotmail.com.

引用本文:王萌,张松,施艳艳,等.基于混合神经网络参数优化的两相流流型识别方法[J].河南师范大学学报(自然科学版),2025,53(3):121-127.(Wang Meng,Zhang Song,Shi Yanyan,et al.Flow pattern identification of two-phase flow based on an optimized hybrid neural network[J].Journal of Henan Normal University(Natural Science Edition),2025,53(3):121-127.DOI:10.16366/j.cnki.1000-2367.2024.01.10.0005.)

将不同流型的电导率测量信号分割为若干子序列,并利用变分模态分解(variational mode decomposition, VMD)提取子序列的固有模态函数;然后,提取固有模态函数的 Hjorth 特征数据以描述各子序列的非线性特征;接着,将随机森林算法作为卷积神经网络的分类层构建混合神经网络,并采用鲸鱼算法对混合神经网络中的小批量参数、初始学习率、正则化系数 3 个超参数进行优化;最后,采用优化后的混合神经网络对 Hjorth 参数特征向量数据集进行分类,从而实现流型识别.

1 实验数据的特征信息提取

1.1 实验设置

采用气液两相流测量系统对两相流动状态进行检测和数据采集,实验中,气相为空气,液相为自来水.气液两相流测量系统示意图如图 1 所示.图 1 中,首先将空气和水注入混合罐,再将混合罐中的气液混合物注入到传感器管道进行在线测量,最后测量后的气液混合物在分离罐中进行分离,将获得的水流回水箱以重复使用.根据流量计数值,通过调节阀整气、水流量,从而配比出不同的相含率进而获得不同流型.实验中采用环形电导传感器对流型数据进行采集,其结构如图 2 所示.




图1 测量系统结构图

Fig.1 Schematic diagram of measurement system




图2 6电极环形电导传感器结构示意图

Fig.2 Schematic diagram of the structure of a six-electrode annular conductance sensor

图 2 中, E_1 和 E_2 为激励电极, C_1 和 C_2 为上游相关电极, C_3 和 C_4 为下游相关电极, C_2 和 C_3 为相含率电极.环形电导传感器的采集频率为 1 kHz,采集周期为 20 s,对每个流型重复采集 3 次得到 3 组测量数据,将每组测量数据定义为 1 个样本,1 个样本包含 20 000 个测量值.本实验测量的 4 种流型分别为长塞流、短塞流、泡状流、塞状流.

1.2 数据预处理

为了减少样本数据中异常值的影响,提高样本数据的质量,采用 max-min 归一化对采集的样本进行归一化处理,公式如下: $x'_i = (x_i - x_{\min}) / (x_{\max} - x_{\min})$, $i = 1, 2, 3, \dots, n$.式中, n 为 20 000, x_i 为样本中的第 i 个数据, x'_i 为得到的新样本中第 i 个数据, $x_{\max}$ 为样本中的最大值, $x_{\min}$ 为样本中的最小值.经过归一化后得到的新样本为无量纲数据,范围为 $[0, 1]$.

新样本的长度与流型识别的实时性成反比,为此,采用滑动窗口法^[14]将时间长度为 20 s 的新样本分割为时间长度为 4 s 的子序列以保证流型识别的实时性.设定窗口大小为 W ,步长为 S ,样本时间序列长度为 L ,得到的子序列长度等同于窗口大小,子序列个数的计算公式为: $m = ((L - W) / S) + 1$.设置窗口大小为 4 000,步长为 2 000,可知,每一个新样本可以分割为 9 个子序列.取长塞流、短塞流、塞状流各 20 个样本和泡状流 15 个新样本,经过滑动窗口法处理后共得到 675 个子序列,组成原始数据集.

由于原始数据集具有较强的非平稳性,需对其进行平稳化处理再进行特征提取.VMD 算法可以将原始数据集中的每条数据转换为多个平稳的固有模态函数(intrinsic mode functions,IMFs),且相较于经验模态分解算法,VMD 算法可以避免模态混叠的现象^[15],因此,本文采用 VMD 算法对原始数据集进行平稳化处理.需要注意的是,使用 VMD 算法进行数据处理时需要提前设定分解层数 K ,本文设定 $K = 8$.数据处理结果如图 3 所示.

图 3 中,VMD 算法将 4 种流型的原始数据从高频到低频分解为 8 个 IMFs,在高频范围内,因为该范围内的成分变化较快,波动幅度较小,故信号的幅值相对较小.而随着频率降低,信号中的较低频成分具有更大的幅值.可以看出,每个子序列经分解后可以得到 8 个固有模态函数,且该固有模态函数在时间上没有明显

的趋势和周期性,平稳性较好.然而,图 3 中固有模态函数仍具有较强的非线性特性,还需要进一步提取合适的特征值以便准确获得固有模态函数的非线性特征.

1.3 测量信号的非线性特征提取

相对于平均值、方差等统计特征,Hjorth 参数综合考虑了信号 1 阶到 3 阶的非线性特征,因此 Hjorth 参数可以更好地提取固有模态函数中的非线性信息,进而更为全面地反映信号特性.Hjorth 参数包括活动度、移动度和复杂度 3 个参数,其中,活动度是指信号振幅变化程度,活动度越大,信号的振幅变化越大;移动度是指信号在一定时间范围内的变化程度.移动度越高,信号具有的纹理或起伏越多;复杂度描述了信号在时间和振幅的变化程度,复杂度越大,信号在时间和幅度范围内的变化越复杂,包含的不规则性越多.3 个参数计算公式如下:活动度为 $\sigma^2(x)$;移动度为 $\sigma'(x)/\sigma(x)$;复杂度为 $[\sigma''(x)/\sigma'(x)]^{1/2}/[\sigma'(x)/\sigma(x)]^{1/2}$.式中, x 表示原始信号, σ 表示信号的标准差, σ' 表示原始信号一阶差分的标准差, σ'' 表示原始信号二阶差分的标准差.

每个固有模态函数可以提取一组 Hjorth 参数,每条子序列可以得到 8 组 Hjorth 参数作为特征向量.因此,根据原始数据集可得到 675 个特征向量,组成 4 种流型的特征向量数据集.为了分析 4 种流型的非线性特性,分别随机抽取特征向量数据集中各流型数据对应的 1 个特征向量,其 Hjorth 参数如图 4 所示.




图4 Hjorth 参数图

Fig.4 Hjorth parameter graph

图 4(a)中泡状流的活动度参数最高,这反映了其对应的泡状流信号的振幅变化最剧烈,短塞流和塞状流的活动度参数相近,对应的二者信号的振幅变化程度相近,长塞流的活动度参数最低,说明长塞流信号的振幅变化平缓;图 4(b)4 种流型信号的移动度参数相近,代表 4 种流型信号的变化程度相近,且由于第 7、第 8 个 IMFs 幅值高于前面的 6 个 IMFs 的幅值,故 4 种流型信号的后 2 个移动度参数要高于前 6 个移动度参数;图 4(c)泡状流和塞状流的复杂度参数相近,可以推断出泡状流和塞状流信号的不规则程度相近,在时间和幅度范围内的变化最为复杂.短塞流信号的不规则程度弱于泡状流和塞状流,长塞流复杂度参数最低,反映了长塞流信号在时间和幅度范围内的变化最为简单.因此,用 Hjorth 参数可以获取不同流型固有模态函数的非线性特征,在此基础上对非线性特征信息进行分类即可实现流型识别.

2 非线性特征分类算法

非线性特征提取获得的一维数据可采用一维卷积神经网络(1D convolutional neural network, 1DCNN)对特征数据集进行分类^[16].1DCNN 将 Softmax 层作为分类层,其作用是将全连接层输出的特征向量转化为类别的概率分布.然而,特征向量在经过卷积等一系列运算后会包含更多的信息量,造成 Softmax 层对特征向量的计算不稳定,导致分类算法过拟合,影响流型识别的准确率,而随机森林算法可以通过随机抽样和特征选择生成多个不同的决策树模型并进行集成学习,进而解决算法过拟合问题^[17].基于以上原因,本文在 1DCNN 中引入随机森林算法(random forest, RF)替代 1DCNN 中的 Softmax 层,进而构建混合神经网络(1DCNN-RF),1DCNN-RF 流程图如图 5 所示.

图 5 中,首先,对输入数据进行预处理操作,预处理包括规范化和格式转换,经预处理后的输入数据按 4 : 1 的比例被分为训练集和测试集,训练集用于训练网络,利用测试集检测网络的分类性能;接着,将训练集输入卷积层和池化层,通过卷积层和池化层提取训练集的主要特征信息;之后,将训练集的主要特征信息分为 n 个子集,每个子集可以训练一颗决策树,每颗决策树在训练中生成两个包含不同类别特征向量的支节点,计算每个支节点的基尼指数(Gini Index),在基尼指数小的支节点下生成 2 个新的支节点并计算基尼指数.当支节点内包含的特征向量仅为一类时,停止产生新的支节点,完成网络训练;最后,将测试集输入到训练后的 1DCNN-RF 中即可对混合神经网络的分类性能进行验证.




图5 1DCNN-RF算法流程图
Fig.5 Flowchart of the 1DCNN-RF algorithm

另外,为了使 1DCNN-RF 性能达到最优,本文采用鲸鱼算法(whale optimization algorithm, WOA)对 1DCNN-RF 超参数进行优化,该算法在求解优化问题时具有较强的搜索能力和并行性.WOA 的计算步骤如下:

1)选择位置向量和搜索方向,计算公式如下: $\mathbf{D}=(|C_1X_1^*(t)-X_1(t)|, |C_2X_2^*(t)-X_2(t)|, \dots)$; $\mathbf{X}(t+1)=\mathbf{X}^*(t)-\mathbf{D}\cdot\mathbf{A}$.式中, $\mathbf{D}$ 是当前搜索个体与当前解的距离向量, $\mathbf{X}^*(t)$ 是目前得到的最佳解的位置向量, $\mathbf{X}(t)$ 是位置向量, t 表示当前迭代次数, $\mathbf{A}$ 和 $\mathbf{C}$ 是系数向量,计算公式为: $\mathbf{A}=2a\mathbf{r}_1-a$; $\mathbf{C}=2\mathbf{r}_2$, $\mathbf{r}_1$ 和 $\mathbf{r}_2$ 是 $[0,1]$ 中的随机向量,在迭代过程中, a 由 2 线性减小到 0.

2)螺旋更新位置.计算公式如下: $\mathbf{X}(t+1)=\begin{cases} \mathbf{X}^*(t)-\mathbf{D}\cdot\mathbf{A}, & p < 0.5, \\ e^{bl}\cos(2\pi l)\mathbf{D}' + \mathbf{X}^*(t), & p \geq 0.5, \end{cases}$; $\mathbf{D}'=(|X_1^*(t)-X_1(t)|, |X_2^*(t)-X_2(t)|, \dots)$.式中, p 是值为 $[0,1]$ 的随机数, $\mathbf{D}'$ 表示当前搜索个体与当前最优解的距离向量, b 用于定义螺旋形状参数, l 为服从均匀分布的随机数 $[0,1]$.

3)搜索全局解.当 $|\mathbf{A}| \geq 1$ 时,从当前解空间中随机选择一个解为目标进行位置更新,计算公式如下: $\mathbf{D}=(|C_1X_{\text{rand},1}^*(t)-X_1(t)|, |C_2X_{\text{rand},2}^*(t)-X_2(t)|, \dots)$; $\mathbf{X}(t+1)=\mathbf{X}_{\text{rand}}(t)-\mathbf{D}\cdot\mathbf{A}$.式中, $\mathbf{X}_{\text{rand}}(t)$ 表示从当前种群选择的随机位置向量.

在 WOA 算法中,首先将小批量参数(mini batch size)、初始学习率(initial learn rate)、正则化系数(L2Regularization)3 个超参数随机取值作为当前解;接着,根据步骤 2 更新 3 个超参数的最优解;最后,达到最大迭代次数后停止更新并将解返回 1DCNN-RF.根据以上所述,所提基于 Hjorth 特征数据提取的 WOA-1DCNN-RF 流程图如图 6 所示.

图 6 中,输入数据为 Hjorth 参数特征向量数据集.首先,对特征向量数据集进行预处理操作,预处理包括规范化和格式转换,经预处理后的数据集被分为训练集和测试集,训练集和测试集数据量之比为 4 : 1;接着,将训练集输入 WOA,对 1DCNN-RF 中的超参数进行更新;然后,按照图 5 的流程利用训练集训练

1DCNN-RF;最后,将测试集输入训练好的 1DCNN-RF 中进行分类,获得流型分类结果.




图6 WOA-1DCNN-RF算法流程图
Fig.6 Flowchart of the WOA-1DCNN-RF algorithm

3 结果分析

为了验证 Hjorth 参数对固有模态函数非线性特征的表征效果,分别提取每个样本常规时域特征 (conventional time-domain features, TF) 和近似熵 (approximate entropy, APEN)^[18] 作为 2 个特征向量数据集,采用 WOA-1DCNN-RF 算法进行分类,并与本文所提基于 Hjorth 特征数据提取的 WOA-1DCNN-RF 分类方法进行比较,其结果如表 1 所示.

表 1 3 个数据集在 WOA-1DCNN-RF 算法中的分类结果

Tab. 1 Identification results of three datasets in the WOA-1DCNN-RF algorithms

特征	分类正确率/%				
	长塞流	短塞流	泡状流	塞状流	平均
Hjorth	97.3	97.2	100.0	100.0	98.52
TF	94.6	78.4	100.0	85.3	88.89
APEN	97.1	88.9	100.0	89.2	93.33

对于长塞流来说,基于 Hjorth 参数特征向量数据集和近似熵特征向量数据集的分类效果优于基于常规时域特征所组成特征向量数据集的分类效果;对于短塞流和塞状流,基于 Hjorth 参数特征向量数据集的分类效果要优于其他两种特征向量数据集;对于泡状流,由于其振幅相对于其他流型信号变化最为剧烈,故算法对 3 种特征向量数据集的分类效果均达到 100%.从以上数据可以看出,相对于常规时域特征和近似熵,由于 Hjorth 参数可以更好地获取固有模态函数的非线性特征,因此流型分类准确率最高.

为了评估所提算法性能,引入准确率、精确度、召回率和 F_1 (F1 Score) 作为性能评价指标.其中,准确率指算法分类正确样本数占总样本数的比例;精确度表示算法分类为正例的样本正确率;召回率指算法正确分类为正例的样本数占有所有实际为正例样本的比例; F_1 是精确度和召回率的加权调和平均值.准确率 $P_{Acc} = (N_{TP} + N_{TN}) / (N_{TP} + N_{TN} + N_{FP} + N_{FN})$;精确度 $P_{Pre} = N_{TP} / (N_{TP} + N_{FP})$;召回率 $P_{Rec} = N_{TP} / (N_{TP} + N_{FN})$; $F_1 = 2P_{Pre}(P_{Rec}/P_{Pre}) + P_{Rec}$. 式中, N_{TP} 为真正例 (true positives, TP), 指算法正确识别出的正例数量; N_{FP} 为假正例 (false positives, FP), 指算法错误地将负例预测为正例的数量; N_{TN} 为真负例 (true negatives, TN), 指算法正确识别出的负例数量; N_{FN} 为假负例 (false negatives, FN), 指模型错误地将正例预测为负例的数量.

为评估 WOA 的寻优能力,使用粒子群算法 (particle swarm optimization, PSO) 和麻雀搜索算法 (sparrow search algorithm, SSA) 优化 1DCNN-RF 构建 PSO-1DCNN-RF 和 SSA-1DCNN-RF,再将 Hjorth 参数特征向量数据集分别输入到 1DCNN-SVM (hybrid network of 1DCNN and SVM)、1DCNN-LSTM (hybrid network of 1DCNN and long short-term memory network)、1DCNN-RF、PSO-1DCNN-RF、SSA-1DCNN-RF 和 WOA-1DCNN-RF 算法中进行分类并计算性能指标评估算法性能,6 种算法的性能指标结果如表 2 所示.

表 2 6 种算法的性能指标结果

Tab. 2 Performance metric results of the six algorithms

算法	P_{Acc}	P_{Pre}	P_{Rec}	F_1	算法	P_{Acc}	P_{Pre}	P_{Rec}	F_1
WOA-1DCNN-RF	98.52	99.63	98.61	98.57	1DCNN-SVM	93.10	94.32	93.22	93.05
PSO-1DCNN-RF	95.83	96.77	96.14	96.45	1DCNN-LSTM	93.33	94.59	93.75	93.49
SSA-1DCNN-RF	95.31	96.25	95.64	95.94	1DCNN-RF	94.81	95.74	95.14	94.48

从表 2 中可以看出,1DCNN-SVM 与 1DCNN-LSTM 的结果相近,1DCNN-RF 算法的 4 个指标结果则略高于 1DCNN-SVM 和 1DCNN-LSTM,SSA-1DCNN-RF 的 4 个指标较 1DCNN-RF 算法有所提高,而 PSO-1DCNN-RF 的 4 个指标较 SSA-1DCNN-RF 均提升了 0.5%左右,所提 WOA-1DCNN-RF 的 4 个性能指标均高于 PSO-1DCNN-RF 和 SSA-1DCNN-RF 算法.这是因为 PSO 和 SSA 在搜索最优解时易陷入局部最优,进而使 1DCNN-RF 的性能无法达到最优,而 WOA 算法易于实现对全局最优解的搜索,因此 WOA-1DCNN-RF 分类算法的性能优于其他 5 种算法,其精确度达到 99.63%.图 7 给出了所提基于 Hjorth 特征数据提取的 WOA-1DCNN-RF 分法分类结果混淆矩阵.所提算法对 4 种流型特征向量的分类有很高的准确率,36 个短塞流特征向量中的 1 个被预测为长塞流,36 个塞状流特征向量中有 1 个被预测为短塞流.135 个特征向量仅有 2 个被错误分类,证明了所提方法的有效性和可靠性.

4 结 论

针对传感器测量电导波动信号强非线性和非平稳性造成流型识别困难的问题,提出一种基于 Hjorth 特征数据提取的混合神经网络气液两相流流型识别方法.首先,采用滑动窗口法将时长 20 s 的测量数据处理成时长为 4 s 的子序列;接着采用 VMD 算法提取信号的模态函数,然后在模态函数中提取 Hjorth 特征数据集以获取测量信号的非线性特征;之后,引入随机森林算法对神经网络的分类层进行优化,并采用鲸鱼算法获得混合神经网络的超参数;最后,利用优化后的混合神经网络模型对气液两相流流型进行分类预测.实验结果表明,所提方法对 4 种流型分类预测的平均准确率达 98.52%,证明了该方法的准确性和可行性,并得出以下结论:

- 1)Hjorth 参数可以较好地获取固有模态函数的非线性特征.
- 2)随机森林算法可以有效降低分类算法的过拟合风险,提高泛化能力.
- 3)采用鲸鱼算法优化网络超参数可提升网络预测精度,与 1DCNN-SVM 算法、1DCNN-LSTM 算法和未优化的 1DCNN-RF 算法相比,WOA-1DCNN-RF 算法的流型识别精度更高.




图7 测试集分类结果的混淆矩阵

Fig.7 Confusion matrix of the test set classification results

参 考 文 献

[1] ZHANG L F,ZHANG S J.Gas/liquid two-phase flow pattern identification method using gramian angular field and densely connected network[J].IEEE Sensors Journal,2023,23(4):4022-4032.

[2] SHI Y Y,LIAO J J,WANG M,et al.Total fractional-order variation regularization based image reconstruction method for capacitively coupled electrical resistance tomography[J].Flow Measurement and Instrumentation,2021,82:102081.

[3] YANG C,LU H C,WANG B,et al.Flow regime identification using pressure fluctuation signals in an aerated vessel stirred[J].Chemical Engineering Science,2023,280:119058.

[4] DU M,JIN N D,GAO Z K,et al.Analysis of total energy and time-frequency entropy of gas-liquid two-phase flow pattern[J].Chemical Engineering Science,2012,82:144-158.

[5] RAFAŁKO G,MOSDORF R,GÓRSKI G.Two-phase flow pattern identification in minichannels using image correlation analysis[J].International Communications in Heat and Mass Transfer,2020,113:104508.

[6] ZHANG L F,ZHANG S J.Analysis and identification of gas-liquid two-phase flow pattern based on multi-scale power spectral entropy and pseudo-image encoding[J].Energy,2023,282:128835.

[7] XU Q,ZHOU H Z,ZHU Y S,et al.Study of identification of global flow regime in a long pipeline transportation system[J].Powder Technology,2020,362:507-516.

[8] ZHANG P,CAO X W,PENG F Y,et al.High-accuracy recognition of gas-liquid two-phase flow patterns: a Flow-Hilbert-CNN hybrid model[J].Geoenergy Science and Engineering,2023,230:212206.

[9] XU Q,JIA P,WANG X Y,et al.Flow regime recognition in a long pipeline-riser system based on signals at the top of the riser[J].Flow Measurement and Instrumentation,2021,80:101987.

[10] ROSA E S,SALGADO R M,OHISHI T,et al.Performance comparison of artificial neural networks and expert systems applied to flow pattern identification in vertical ascendant gas-liquid flows[J].International Journal of Multiphase Flow,2010,36(9):738-754.

[11] ZOU S F,GUO L J,XIE C.Fast recognition of global flow regime in pipeline-riser system by spatial correlation of differential pressures [J].International Journal of Multiphase Flow,2017,88:222-237.

[12] REN W K,ZHANG J C,JIN N D.Rescaled range permutation entropy:a method for quantifying the dynamical complexity of gas-liquid two-phase slug flow[J].Nonlinear Dynamics,2021,104(4):4035-4043.

[13] XU H,TANG T,ZHANG B R,et al.Identification of two-phase flow regime in the energy industry based on modified convolutional neural network[J].Progress in Nuclear Energy,2022,147:104191.

[14] YANG J,SHI Z P,WANG C X,et al.Design of optimized sliding-window BATS codes[J].IEEE Communications Letters,2019,23(3): 410-413.

[15] LI C J,WU Y C,LIN H J,et al.ECG denoising method based on an improved VMD algorithm[J].IEEE Sensors Journal,2022,22(23): 22725-22733.

[16] 魏甫豫,张振宇,梁桂珍.基于卷积神经网络下昆虫种类图像识别应用研究[J].河南师范大学学报(自然科学版),2022,50(6):96-105.

WEI F Y,ZHANG Z Y,LIANG G Z.Research on application of insect species image recognition based on convolutional neural network [J].Journal of Henan Normal University(Natural Science Edition),2022,50(6):96-105.

[17] DONG L F,DU H Q,MAO F J,et al.Very high resolution remote sensing imagery classification using a fusion of random forest and deep learning technique:subtropical area for example[J].IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2020,13:113-128.

[18] SUN L T,WANG X,YANG A F,et al.Radio frequency fingerprint extraction based on multi-dimension approximate entropy[J].IEEE Signal Processing Letters,2020,27:471-475.

Flow pattern identification of two-phase flow based on an optimized hybrid neural network

Wang Meng, Zhang Song, Shi Yanyan, Yang Zhen, Shi Shuie

(Henan Key Laboratory of Optoelectronic Sensing Integrated Application, Henan Normal University, Xinxiang 453007, China)

Abstract: Accurate flow pattern identification is a great challenge due to strong nonlinearity and non-stationary of measurement data in gas-liquid two-phase flow. In this work, a new flow pattern identification method based on optimized hybrid neural network is proposed. In the proposed method, the measured conductivity data of different flow patterns is firstly segmented using the sliding window method. Then, the variational mode decomposition algorithm is utilized to obtain the intrinsic mode functions of each subsequence. The nonlinear features of each subsequence are described by extracting the Hjorth features from the intrinsic mode functions. Next, the random forest algorithm is introduced into the classification layer of the convolutional neural network to construct a hybrid neural network. The whale algorithm is employed to optimize the three hyperparameters in the hybrid neural network. Finally, flow pattern is identified by classifying the feature vector dataset of Hjorth parameters with the optimized hybrid neural network. The experimental results show that an average identification accuracy of 98.52% can be realized for the four flow patterns when the proposed method is used.

Keywords: gas-liquid two-phase flow; Hjorth parameters; hybrid neural network; random forest

[责任编辑 杨浦 刘洋]