

DOI:10.11784/tdxbz202407013

基于图像处理和时序模型的气液两相流流型识别

孙立军^{1,2}, 胡雨龙^{1,2}, 张佳伟^{1,2}, 杨子涵^{1,2}, 杨 铎³

(1. 天津大学电气自动化与信息工程学院, 天津 300072; 2. 天津市过程检测与控制重点实验室, 天津 300072;
3. 天津福路瑞特测控技术有限公司, 天津 300384)

摘要: 气液两相流工况, 因为存在多种流型, 导致科氏流量计的测量误差修正效果不佳. 为解决该问题, 本文提出了一种流型识别方法, 识别科氏流量计入口水平管内的流型. 针对 DN10 管径、量程 0~1 000 kg/h 的科氏流量计, 在液相质量流量 200~900 kg/h, 体积含气率 0~30% 的两相流工况进行实验. 在选择的工作点, 用高清摄像机, 按照 1 s 间隔连续拍摄流型图像; 并对每个工况点的图像数据进行滑动窗处理, 构建时间序列数据集. 利用灰度直方图、几何不变矩、灰度共生矩阵和 Tamura 纹理特征等, 多种图像特征提取方法提取特征. 将多种图像特征组合使用, 并利用排列重要性, 对特征组进行特征工程. 将得到的优化特征组, 作为长短时记忆网络的数据集输入, 对流型进行分类识别. 结果表明, 该方法在较短迭代内就可达到 95% 以上的准确率, 最终准确率达 99%, 与随机森林、卷积神经网络、支持向量机等传统识别算法相比, 对各流型识别的准确率都有一定提升. 并通过互斥流量点图像数据集的泛化测试, 验证了模型的泛化能力. 证明所提模型能在一定程度上, 对流量范围内的多种流型进行准确识别, 对流型识别中错误的流量点进行分析, 给出了进一步改进的方向, 为气液两相流测量工况的科氏流量计误差修正提供了有效的流型识别依据, 有利于进一步地提高误差修正精度.

关键词: 气液两相流测量; 流型识别; 图像分类; 长短时记忆 (LSTM); 特征提取

中图分类号: O359.1

文献标志码: A

文章编号: 0493-2137(2025)07-0683-10

Identification of Gas-Liquid Two-Phase Flow Patterns Based on Image Processing and Time Series Models

Sun Lijun^{1,2}, Hu Yulong^{1,2}, Zhang Jiawei^{1,2}, Yang Zihan^{1,2}, Yang Duo³

(1. School of Electrical and Information Engineering, Tianjin University, Tianjin 300072, China;
2. Tianjin Key Laboratory of Process Measurement and Control, Tianjin 300072, China;
3. Tianjin Flowrate Measurement and Control Technology Co., Ltd., Tianjin 300384, China)

Abstract: Under gas-liquid two-phase flow conditions, varying flow patterns considerably hinder the correction of measurement errors in Coriolis mass flowmeters (CMF). To address this issue, this study proposed a flow pattern recognition method to identify the flow patterns in the horizontal inlet pipe of a CMF. Experiments were conducted using a CMF with a DN10 pipe diameter and a flow range of 0—1 000 kg/h. This study focused on two-phase flow scenarios with liquid phase mass flow rates ranging from 200 to 900 kg/h and gas volume fractions ranging from 0 to 30%. At selected operating points, high-definition cameras captured flow pattern images at 1 s intervals. These images were processed using a sliding window approach to construct a time series dataset. Various image feature extraction methods were used to extract features, including grayscale histograms, geometric invariant moments, gray-level co-occurrence matrices, and Tamura texture features. These features from these different extraction methods were combined and refined using permutation importance, enabling the creation of a filtered dataset. This dataset then served as input for a long short-term memory network designed to recognize flow patterns. The results show that this

收稿日期: 2024-07-22; 修回日期: 2024-11-25.

作者简介: 孙立军 (1974—), 男, 博士, 副教授.

通信作者: 孙立军, sunlijun@tju.edu.cn.

基金项目: 国家重点研发计划资助项目 (2023YFB3209303).

Supported by the National Key Research and Development Program of China (No. 2023YFB3209303).

method achieves an accuracy of over 95% within a short number of iterations, eventually reaching 99% accuracy. Compared with conventional identification algorithms, such as random forests, convolutional neural networks, and support vector machines, this method demonstrates superior accuracy in identifying flow patterns. Generalized testing with a separate flow rate dataset confirmed the generalizability and ability of the model to accurately recognize multiple flow patterns within a certain flow rate range. Misclassified flow rate points were analyzed to explore potential areas of improvement in flow regime identification, paving the way for future refinements. This method provides a strong foundation for improving flow pattern identification, ultimately contributing to effective error correction in CMFs under gas-liquid two-phase flow conditions, which is beneficial for further improving the accuracy of error correction.

Keywords: gas-liquid two-phase flow measurement; flow pattern identification; image classification; long short-term memory (LSTM); feature extraction

多相流是常见的流体形态,广泛存在于石油化工、航空航天、医疗设备、储能等诸多行业中^[1]。多相流流量精确测量是重要的研究方向。多相分离单独测量方法,在很多实际应用中的成本无法接受。根据科里奥利力原理制作的科氏流量计,被认为有非常大的潜力成为直接测量多相流流量的手段^[1-3]。在气液两相流工况下,由于液体中夹杂气体,振动阻尼变化和流动形态变化,这种变化严重影响测量,导致测量误差急剧增加^[4]。针对两相流工况下科氏质量流量计的误差校正问题,目前较为广泛采用的是机理建模和数据驱动建模的方法。

数据驱动模型的方法由于其适用性广、修正效果好的特点得到更多科研团队的重视。基于数据驱动的机器学习模型,可以直接利用实验数据建立起非线性模型,并对未知数据进行预测,泛化性和矫正效果均优于机理建模^[5]。马龙博等^[6]对油水两相流工况的双 U 型 Coriolis 流量计测量,提出了基于支持向量机 (support vector machine, SVM) 的油水分相质量流量直接预测方法,总质量流量测量误差在 $\pm 1\%$ 以内。Wang 等^[7]利用反向传播人工神经网络 (back propagation artificial neural network, BP-ANN) 模型对气液两相流进行流量修正,修正后的液体质量流量相对误差小于 2.5%,气体体积分数相对误差在 20% 以内。Zhuang 等^[8]分别利用基于 PSO 搜索方法的 SVM 和 BP-ANN 对气液两相流进行了流量修正,对比得出 SVM 较优于 BP-ANN 网络。

上述研究建立的数据驱动模型,多数是基于整个测量工况范围的数据集,包括了气泡流、段塞流在内的多种流型。根据 Hemp 等^[9]提出的气泡模型,以及 Basse^[10]在气泡模型基础上提出的粒子对震荡流体的作用力分析,不同流动形态的测量误差范围有明显差异且影响因素复杂,不适合用统一的模型进行修正。在 Zhuang 等^[8]的研究中,减少数据集中的非同种

流型数据使得模型准确率提升也佐证了这一点。将数据驱动的气液两相流流量修正模型与气液两相流流型识别结合,在不同流动形态采用不同的修正模型,是一个可行的方案。

目前,流型识别方法可分为两类:一类是根据两相流流动图像直接确定流型,如目测法、摄影法、过程层析成像法等。周云龙等^[11]基于流型图像的灰度直方图特征,结合 Elman 网络提出了一种流型识别方法,平均准确率达 98.6%。刘俊宏^[12]利用小波卷积变换对图像进行特征提取,并且将小波卷积提取的局部特征与灰度直方图等全局特征融合输入分类器进行分类,平均准确率达 98%。梁法春等^[13]通过迁移学习,解决了流型识别中特征提取效率不高的问题,提高了泛化能力。另一类是间接方法,将特征提取和分类预测结合进行流型识别。翁润滢等^[14]利用自适应最优核算法对两相流波动的差压信号进行分析,提取出了气液两相流的动态特征。陈思睿等^[15]将卷积自编码器应用在了流型图像特征提取上,实现了图像特征的无监督提取。

上述研究包括了流型识别的两种主流做法。一是将流型图像直接作为输入,进行流型识别。另一种则是将特征提取与分类检测结合,进行流型识别。两种方法都有一定效果。然而,无论是直接法还是间接法,大多忽视了时序性的影响。由于管道内流型的发展变化和存在形式都具有时序性,信号随时间的变化特点是两相流信号处理过程的重要因素之一。然而,目前的摄影法流型识别大多忽视了图像的时序性因素。此外,在图像特征选取及特征提取方面,人工选择特征工作效率较低。流型识别方法采用的数据集,也都是依据流型不同划分的数据集,这些数据集没有与流量建立直接联系。上述因素都导致流型识别的成果难以应用于流量。

综上所述,本文针对上述问题,依据科氏流量计

的测量工况和流量范围,采集了不同流量点的图像数据.对每个流量点的图像进行分类标签,构成流型识别数据集.利用排列重要性方法对多种特征提取方法的大量特征进行筛选,得到最适合本文实验的特征组.将 LSTM 与筛选后的特征组结合,进行流型分类.相关研究可为两相流流量测量提供新的思路和方法.

1 实验

1.1 实验装置

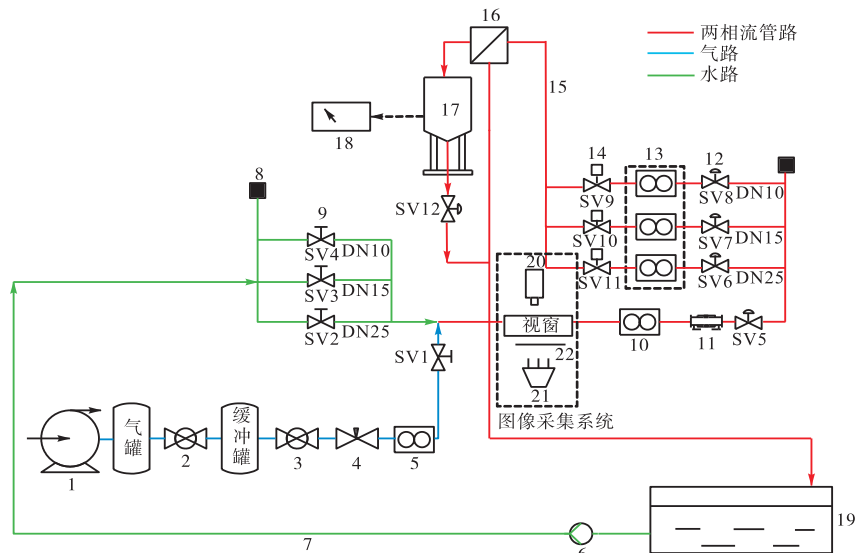
实验装置如图 1 所示,由水路和气路组成.水由水泵从储水箱抽出.气路通过气泵产生气体,通过储气罐、调压阀、缓冲罐、针形阀后,气流量达到稳定.气路和水路在实验管段前交汇,形成稳定的气液两相流.两相流依次流过图像采集管段、科氏流量计、换向器,最终流回水箱,空气从水中逸出.

根据实验精度和量程要求,选用 Walsn VS 系列 DN10V 型双弯管科氏流量计,最大流量 1 000 kg/h,单相液体工况,质量流量计量精度 $\pm 0.1\%$,重复性优于 0.02%.气路采用 HORIBA 的 S600 型气体流量计,最大流量 7 L/min(标准状态下),仪表精度为

$\pm 1\%FS$.图像采集系统,由光源、透明视窗和摄像机组成.考虑流型充分发展及实际应用工况,选择内径 15 mm、长 220 mm 的透明视窗作为观察窗.考虑气相和液相分界面拍摄的清晰度,选用 LED 灯管作为光源,采用逆光照明方法.为了使光线分布均匀,在光源和透明管道之间布置两层硫酸纸.摄像机选择高清摄像头,分辨率为 4 096 像素 \times 3 072 像素,以 1/4 000 s 的曝光时间拍摄,能快速抓取比较清晰的流型图像.

1.2 实验方法

实验目标是在选用科氏流量计的流量范围内,针对两相流测量研究需要的含气率范围进行图像数据采集.选择液相质量流量范围 200 ~ 900 kg/h、体积含气率 0 ~ 30% 进行实验,作为本文流型识别建模所用的样本数据.为得到两相流工况下稳定的液相流量,本文选用称重法进行实验.该相较于标准表法,该方法测量精度更高.实验流程为:用阀门调节装置水流量;用换向器切换水流方向,在形成稳定的气液两相流后,切换至称重容器进行称重,累积 30 s 的质量流量,计算平均质量流量;重复此过程,直至调节到实验流量点.



1—空压机; 2—调节阀; 3—稳压阀; 4—针形阀; 5—气体流量计; 6—水泵; 7—供水管路; 8—排气孔; 9—手动阀; 10—科氏流量计; 11—夹表器; 12—气动阀; 13—电磁流量计; 14—电动阀; 15—分管流; 16—换向器; 17—称重容器; 18—电子秤; 19—储水箱; 20—摄像机; 21—光源; 22—硫酸纸

图 1 两相流实验装置工艺流程

Fig.1 Progress flow of the two-phase flow experimental equipment

考虑到工业实际应用中,流量测量环境较为复杂,测量设备的反应速度通常较慢,长时间高速连续图像采集不符合经济和技术实际状况.在较长的一段时间内,管道中的流型总体较为稳定.但在较短的时间内,会出现流动形态波动.根据固定时间间隔的单

张图像进行流型识别,并以此选择流量矫正模型,在实际工况中可能会导致矫正模型的多次变更,会导致较大测量误差.部分间歇流型所采集到的图像,会与其他间歇流或连续流发生偶然性的相似.这也会导致矫正模型的错误变更,出现测量误差.因此,建立

一个精确度高、偶然性误差小、稳定性好、波动小的流型识别模型是必要的. 为了减少偶然性误差和不必要的波动, 并且考虑到流型发展的连续性, 本文采用时间序列的图像数据组作为模型输入, 并依此选择合适的模型. 为了构造合适的数据集, 本文在每个实验点下, 按照 1 s 固定间隔连续采集 30 张图像, 并对 30 张图像按照模型所需输入长度进行滑窗处理, 得到初步的模型输入数据集.

结合实验采集的图像数据与文献[16]中的流型图, 将实验流量范围内的实验点划分为段塞流、气泡流和过渡流 3 种流型, 如图 2 所示.




图 2 实验流量点示意

Fig.2 Schematic of experimental flow points

在液相速度较低的工况, 液相将气相分割成一个一个不相通的塞状气泡, 如图 3 所示. 在这种液相流速下, 整个实验体积含气率范围的流型都是段塞流. 随着液相速度提高, 液相开始打散气相的塞状完整气泡. 液相的湍流脉动效应逐渐大于气泡的浮力作用, 气相的完整塞状气泡难以形成, 被打散成不规则形状. 管道中开始出现小气泡, 但仍有塞状不规则气泡频繁出现, 流型从段塞流逐渐向气泡流发展. 液相流速达到一定程度后, 液相的湍流脉动效应完全超过气泡的浮力作用, 阻止气泡聚合在管道顶部形成段塞, 而是分散在管道内. 在这种液相速度下, 较低体积含气率范围内彻底形成气泡流. 在较高体积含气率范围里, 气体增多, 浮力增大, 流型仍处于过渡流状态.

2 方法介绍

实验过程中, 受环境、设备、人工等因素干扰, 初步图像数据集存在噪声、尺寸等问题. 对初步数据集进行图像预处理, 得到更突出流型特征的图像数据集. 对图像数据集进行特征提取和特征工程, 得到合适的输入特征, 构成图像特征数据集. 将图像特征数据集作为输入, 训练得到模型结果.

2.1 图像特征提取

2.1.1 图像预处理

为了减少后续特征提取和训练模型的计算量, 提高后续流程的质量. 对实验采集到的初步图像数据集, 进行去噪、裁剪、灰度化等一系列的预处理操作, 减少图像中的干扰因素. 实验采集的图像可能存在噪声, 为了防止噪声影响进一步的图像特征提取效果, 通过均值滤波对图像进行去噪处理. 将图像剪切为 2 600 像素 × 520 像素大小, 去除图像中与流型无关的环境信息, 只保留有效信息. 将图像灰度化, 减少计算量并提高特征提取效率. 预处理后的流型如图 3 所示.




图 3 3种流型示意

Fig.3 Schematic of three flow patterns

2.1.2 灰度直方图

灰度直方图特征是最基本的灰度图统计特征, 如表 1 所示. 其中: z_n 是代表灰度的一个随机变量; $p(z_n)$ 代表 z_n 灰度级在整幅图中出现的概率; N 代表最大灰度级数. 灰度直方图是对图像窗口内不同灰度级像素分布的概率统计. 灰度直方图特征是基于一定公式从灰度直方图中提取出的统计特征量. 这些特征值能够较好的区分不同的灰度直方图, 从而达到区分灰度图的目标.

表 1 灰度直方图特征

Tab.1 Features of gray-scale histogram

特征	表达式	特征表征含义
平均灰度	$\mu_h = \sum_{n=0}^{N-1} z_n p(z_n)$	图像整体亮暗程度度量
灰度方差	$\sigma_h = \sqrt{\sum_{n=0}^{N-1} (z_n - \mu_h)^2 p(z_n)}$	图像亮暗差异程度度量
平滑度	$R_h = 1 - 1 / (1 + \sigma_h^2)$	灰度的均匀程度度量, R_h 值越大, 灰度级的值偏移越大
熵	$e = - \sum_{n=0}^{N-1} p(z_n) \lg p(z_n)$	灰度分布随机性的度量

灰度图像必然对应于一定概率分布的灰度直方图. 同种图像的灰度直方图具有相似性, 它们的灰度直方图特征也具有相似性. 通过灰度直方图特征的

相似性判别,可以对灰度图进行分类.但灰度直方图特征对应的灰度图不具有唯一性.灰度直方图特征是基于像素灰度级数量的统计特征,不包含灰度图中像素之间的位置关系.单独使用灰度直方图特征进行图像识别,具有一定的不合理性和误差.

2.1.3 灰度共生矩阵

灰度共生矩阵是反映图像纹理结构的一种统计方法.它是从数学角度对图像纹理中灰度级的空间依赖关系的分析,是对像素点与其邻域内的其他像素点的固定灰度关系的一种统计,是对像素点与其邻域的二维信息的量化,是一种描述图像纹理特性的有效特征^[17].

灰度共生矩阵的基本原理是通过灰度图像的空间相关性对图像的纹理特征进行描述.它被定义为从灰度为*i*的像素点出发,离开固定位置(包含距离*d*和方位*θ*)的点上灰度为*j*的概率,可以用一个2阶联合条件概率密度函数*P(i, j, d, θ)*表示.所有灰度对概率{*P(i, j ∈ N)*}的统计就构成了灰度共生矩阵.灰度共生矩阵的维度为*N × N*.整个灰度共生矩阵数据较大,一般通过灰度共生矩阵特征(见表2)参数来分类图像.

表2 灰度共生矩阵特征
Tab.2 Features of gray-level co-occurrence matrix

特征	表达式	特征表征含义
同质性	$P_{\text{Hom}} = \sum_{i,j=0}^{N-1} \frac{P_{i,j}}{1+(i-j)^2}$	灰度共生矩阵中像素分布到对角线的紧密程度的度量
对比度	$P_{\text{Con}} = \sum_{i,j=0}^{N-1} P_{i,j} (i-j)^2$	图像中相邻像素的亮度反差的度量
相关性	$P_{\text{Corr}} = \frac{\sum_{i,j=0}^{N-1} (ijP_{i,j}) - \mu_1\mu_2}{\sigma_1\sigma_2}$	图像的灰度级的行或列方向上相似度的度量
能量	$P_{\text{Asm}} = \sum_{i,j=0}^{N-1} P_{i,j}^2$	图像中纹理的灰度变化稳定程度的度量

表2中:*P_{i,j}*为共生矩阵中灰度级是*i*、*j*的概率;*μ₁*、*μ₂*、*σ₁*、*σ₂*分别表示为

$$\begin{cases} \mu_1 = \sum_{i,j=0}^{N-1} iP_{i,j} \\ \mu_2 = \sum_{i,j=0}^{N-1} jP_{i,j} \\ \sigma_1 = \sqrt{\sum_{i,j=0}^{N-1} (i-\mu_1)^2 \sum_{j=0}^{N-1} P_{i,j}} \\ \sigma_2 = \sqrt{\sum_{i,j=0}^{N-1} (j-\mu_2)^2 \sum_{i=0}^{N-1} P_{i,j}} \end{cases} \quad (1)$$

2.1.4 不变矩

几何矩是图像经过平移、旋转以及缩放变换后,

仍然保持不变的矩特征量,所以又被称为不变矩. Hu^[18]利用二阶和三阶中心距构造了7个不变矩.相关具体定义如下.

对于灰度分布为*f(x, y)*的流型图像,其(*p+q*)阶普通矩*m_{pq}*和中心距*μ_{pq}*分别定义为

$$m_{pq} = \sum_{x=1}^X \sum_{y=1}^Y x^p y^q f(x, y) \quad p, q = 0, 1, 2, \dots \quad (2)$$

$$\mu_{pq} = \sum_{x=1}^X \sum_{y=1}^Y (x-x_0)^p (y-y_0)^q f(x, y) \quad p, q = 0, 1, 2, \dots \quad (3)$$

其中,矩心(*x₀*, *y₀*)定义为

$$\begin{cases} x_0 = \frac{m_{10}}{m_{00}} \\ y_0 = \frac{m_{01}}{m_{00}} \end{cases} \quad (4)$$

直接使用中心距构造 Hu 矩,不能同时具有平移、旋转和尺度不变性,必须将中心距进行归一化,构成的 Hu 矩才能同时具备以上特性.归一化中心距的定义如下.

$$\eta_{pq} = \frac{\mu_{pq}}{\mu_{00}^r} \quad r = \frac{p+q+2}{2}, p+q = 2, 3, \dots \quad (5)$$

利用2阶和3阶中心距构造7个不变矩,能够保持平移、缩放和旋转不变,具体构造公式如下.

$$M_1 = \eta_{20} + \eta_{02} \quad (6)$$

$$M_2 = (\eta_{20} - \eta_{02})^2 + 4\eta_{11}^2 \quad (7)$$

$$M_3 = (\eta_{30} - 3\eta_{12})^2 + (3\eta_{21} - \eta_{03})^2 \quad (8)$$

$$M_4 = (\eta_{30} + \eta_{12})^2 + (\eta_{21} + \eta_{03})^2 \quad (9)$$

$$M_5 = (\eta_{30} - 3\eta_{12})(\eta_{30} + \eta_{12})((\eta_{30} + \eta_{12})^2 - 3(\eta_{21} + \eta_{03})^2) + (3\eta_{21} - \eta_{03})(\eta_{21} + \eta_{03}) \cdot (3(\eta_{30} + \eta_{12})^2 - (\eta_{21} + \eta_{03})^2) \quad (10)$$

$$M_6 = (\eta_{20} - \eta_{02})((\eta_{30} + \eta_{12})^2 - (\eta_{21} + \eta_{03})^2) + 4\eta_{11}(\eta_{30} + \eta_{12})(\eta_{21} + \eta_{03}) \quad (11)$$

$$M_7 = (3\eta_{21} - \eta_{03})(\eta_{30} + \eta_{12})((\eta_{30} - \eta_{12})^2 - 3(\eta_{21} + \eta_{03})^2) + (3\eta_{21} - \eta_{03})(\eta_{21} + \eta_{03}) \cdot (3(\eta_{30} + \eta_{12})^2 - (\eta_{12} + \eta_{03})^2) \quad (12)$$

2.1.5 Tamura 纹理特征

Tamura 纹理特征是 Tamura 等^[19]在1978年提出的一种基于心理学测量的图像纹理特征.图像纹理特征的提取通常基于统计学和结构学,例如灰度共生矩阵、自相关法等.在纹理区分方面,这些图像特征都是针对图像的特定纹理,但实际的自然纹理可以说

是一个无限的集合,通过统计学和结构学分析只能区分出其中的一小部分.对于元素上没有太大差异的纹理,这种方法能通过统计学和结构学方法得到较好的结果,但也会出现该方法无法克服的例子.在特征分析方面,这种方法与人类视觉的工作方式脱节,纹理分析过程与人类的主观判断方法不符.

在这种前提下,Tamura 等^[19]提出了一种基于心理学测量的图像纹理特征.其核心概念是提出一组特征,每种特征都代表了人类心理对图像的一种判断标准.这组特征结合在一起就将人类对图像的判断进行了一个量化,包含了 6 种特征分别是粗糙度、对比度、方向度、线性度、规则度、粗略度.这 6 种特征量化了人在看到一幅图像时对该幅图像的心理判断.因为特征的相关性关系,前 3 种特征较为常用.

粗糙度是反映纹理粒度的一个特征.Tamura 等^[19]利用算子的大小反映纹理的粗细,其公式可表示为

$$F_{CRS} = \frac{1}{XY} \sum_x \sum_y S_{best}(x, y) \quad (13)$$

式中 $S_{best}(x, y)$ 代表最适合的算子大小,可按如下方法获取.

$$A_k(x, y) = \sum_{\tilde{x}=x-2^{k-1}}^{x+2^{k-1}-1} \sum_{\tilde{y}=y-2^{k-1}}^{y+2^{k-1}-1} f(\tilde{x}, \tilde{y}) / 2^{2k} \quad (14)$$

$$\begin{cases} E_{k,h}(x, y) = |A_k(x+2^{k-1}, y) - A_k(x-2^{k-1}, y)| \\ E_{k,v}(x, y) = |A_k(x, y+2^{k-1}) - A_k(x, y-2^{k-1})| \end{cases} \quad (15)$$

$$E_k(x, y) = \max\{E_{k,h}(x, y), E_{k,v}(x, y)\} \quad (16)$$

$$E_{max} = \max\{E_1(x, y), E_2(x, y), \dots, E_L(x, y)\} \quad (17)$$

$$S_{best}(x, y) = 2^K \quad (18)$$

式中: $A_k(x, y)$ 代表 (x, y) 点周围 k 范围内的平均灰度; $E_{k,h}(x, y)$ 和 $E_{k,v}(x, y)$ 分别代表水平和垂直方向上相对两侧非重叠区域平均值的差异; L 代表最大窗口的 k 值; K 为 E_{max} 时的 k 值.

文献[19]采用的对比度和一般对比度不同.该对比度采用了灰度概率密度分布的均方差,并加以一个极化的度量来表示,即

$$F_{con} = \sigma_{con} / \alpha_4^e \quad (19)$$

式中: σ_{con} 代表灰度分布概率密度的均方差; α_4 代表两极化的度量; e 利用逐步逼近获得,取值 1/4.

$$\alpha_4 = \mu_4 / \sigma^4 \quad (20)$$

式中 μ_4 代表 4 阶矩.

方向度是表征图像中灰度分布方向趋势的特征.这种特征一般在傅里叶域中取得,但单独为了方向度将整个数据转换到傅里叶域并不值得.文献[19]

用一种空间域中的方法获得该特征,即

$$F_{dir} = 1 - \rho n_\tau \sum_{\phi \in w_\tau} (\phi - \phi_\tau)^2 \cdot H_D(\phi) \quad (21)$$

式中: n_τ 代表峰数; ϕ_τ 代表 H_τ 的第 τ 个峰的位置; w_τ 代表山谷之间第 τ 个峰的范围; ρ 代表与 ϕ 相关的标准化因素; ϕ 代表量化方向码; H_D 用来表示方向值的直方图.

2.2 排列重要性

前文提到的 4 种图像特征各有优缺点.本文利用特征工程,选出最适合本文模型方法的特征.特征工程选用排列重要性(permutation importance)对特征进行筛选,以得到最合适的特征组.

排列重要性对特征重要性的评判标准,取决于该特征被随机打乱后模型分数的下降程度.评判过程可以概括为以下步骤:

步骤 1 用完整的特征数据集训练目标模型 χ ;

步骤 2 选择评判模型的分数标准(回归模型有误差平方和(SSE)、决定系数(R-square)等,分类模型有受试者工作特征曲线下面积(AUC)、受试者工作特征曲线(ROC)、F1 值等);

步骤 3 计算原数据组在模型上的性能评分 s ;

步骤 4 对特征组 D 中的每个特征 δ , 在 \tilde{K} 次迭代中的每一轮迭代 \tilde{k} 中,依次随机重排特征 δ 的所有数据,重新构成一个污染数据集 $D_{\tilde{k},\delta}$;

步骤 5 计算模型上污染数据集 $D_{\tilde{k},\delta}$ 的性能评分 $s_{\tilde{k},\delta}$, 每一个特征 δ 的重要性评分,其表达式为

$$I_\delta = s - \frac{1}{\tilde{K}} \sum_{k=1}^{\tilde{K}} s_{k,\delta} \quad (22)$$

按照排列重要性得出的特征权重排序,依次删除特征组中权重最低的特征,直到得到满足多方面要求的综合最优特征组.

2.3 时间序列模型

循环神经网络(recurrent neural network, RNN)是根据人的认知方式提出的一种特殊神经网络结构.人的认知在对当前目标进行分析时,通常包含着以往经验记忆的影响.基于这一观点,循环神经网络的模型算法中,模型的输出不仅与当前时序的输入有关,还和前面时序的输出有关.具体的表现形式为:网络会对前面时刻的信息进行记忆,并应用于当前时刻.隐藏层之间的节点存在连接,并且隐藏层的输入由输入层的输出和上一时刻隐藏层的输出共同构成,具体结构如图 4 所示,其中 A 代表 RNN 细胞状态.

循环神经网络的计算过程如下.

$$\tilde{s}_t = f_s(U\tilde{x}_t + W\tilde{s}_{t-1} + \tilde{b}_s) \quad (23)$$

$$\tilde{o}_t = f_o(V\tilde{s}_t + \tilde{b}_o) \quad (24)$$

式中： \tilde{s}_{t-1} 、 \tilde{s}_t 分别为 $t-1$ 时刻和 t 时刻隐含层神经元的输出； \tilde{x}_t 为 t 时刻的输入数据； U 、 W 、 V 分别为输入层、输出层和隐藏层的权值矩阵； \tilde{b}_s 和 \tilde{b}_o 分别为隐藏层和输出层的偏置； f_s 和 f_o 为隐藏层和输出层的激活函数； \tilde{o}_t 为 t 时刻的输出。




图 4 RNN 数据流程示意
Fig.4 Schematic of RNN data flow

长短时记忆神经网络 (LSTM) 是改进的 RNN. 标准 RNN 拥有记忆功能, 对时序信息的处理能力得到提升. 但 RNN 对记忆信息的重要性没有区分, 对信息的重要程度评判只依靠时序. 时序越近, 记忆信息的重要性就越高, 在输入中的占比就越大, 这导致长时序距离的重要信息丢失. 显然这不是本文要达到的模仿“人类的认知方法”. 在众多的 RNN 变体中, LSTM 解决了这一问题. LSTM 是一种特殊的 RNN 类型. 它可以衡量信息的重要性, 并始终将重要信息保留在网络中, 避免了长期依赖问题^[20].

所有 RNN 都具有一种重复神经网络模块的链式结构. 在标准 RNN 中, 此模块是一个非常简单的结构, 例如一个简单的激活函数层. 但在 LSTM 中, 为了解决长期依赖问题, 这一重复网络模块被设计为由忘却门、记忆门、输出门 3 部分组成的网络模块, 具体结构如图 5 所示.

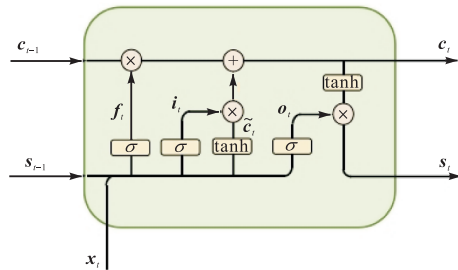


图 5 LSTM 细胞结构示意图
Fig.5 Illustration of LSTM cell structure

LSTM 的循环模块工作过程如下.

$$f_t = \sigma(W_f \cdot [s_{t-1}, x_t] + b_f) \quad (25)$$

$$i_t = \sigma(W_i \cdot [s_{t-1}, x_t] + b_i) \quad (26)$$

$$\tilde{c}_t = \tanh(W_c \cdot [s_{t-1}, x_t] + b_c) \quad (27)$$

$$c_t = f_t * c_{t-1} + i_t * \tilde{c}_t \quad (28)$$

$$o_t = W_o \cdot [s_{t-1}, x_t] + b_o \quad (29)$$

$$s_t = o_t * \tanh c_t \quad (30)$$

式中： f_t 表示历史信息保留程度, 取值[0, 1], 1 表示完全保留, 0 表示完全舍弃； W 表示各个位置的权重矩阵； b 表示各个位置的偏置； i_t 表示当前输入的更新位置； \tilde{c}_t 表示更新信息； c_{t-1} 表示旧细胞状态； c_t 表示新细胞状态。

3 实验结果

3.1 特征工程

目前, 已有非常多的图像特征提取方法. 这些特征组用于流型识别都有一定的效果, 但都不够理想. 结合使用不同特征提取方法能达到更好的流型识别效果, 但特征过多会导致特征提取时间增加, 实时性变差. 不同特征提取方法提取出的特征, 也存在关联性. 简单叠加的不同特征组中, 存在对识别意义不大, 甚至阻碍识别的特征.

综上所述, 需要对特征进行筛选. 本文初步选出 4 种提取方法的 30 种特征如表 3 所示, 最终由这 30 种特征中筛选出满足实验要求的特征组.

表 3 初步筛选的特征组
Tab.3 Preliminary screening feature group

特征提取	特征
不变矩	1 阶矩 2 阶矩 3 阶矩 4 阶矩 5 阶矩 6 阶矩 7 阶矩
共生矩阵	同质性 对比度 相关性 能量
直方图	平均灰度 灰度方差 熵 平滑度
Tamura	粗糙度 对比度 方向度

注:共生矩阵分别在 0°、45°、90°、135°共 4 个方向进行提取.

根据第 2 节提出的排列重要性方法, 对初步选出的 30 种特征进行特征工程, 模型评判的分数标准采用 F1 值, 结果如图 6 所示.




图 6 特征权重示意

Fig.6 Illustration of feature weight

$$F1 = \frac{2PR}{P+R} \quad (31)$$

式中: P 代表综合查准率, 取各个流型查准率的均值, 各个流型的查准率表示为(判断正确的数量/所有判断为该流型的数量) $\times 100\%$; R 代表综合查全率, 取各个流型查全率的均值, 各个流型的查全率表示为(判断正确的数量/数据集中真实为该流型的数量) $\times 100\%$.

按照第 2 节中的排列重要性方法, 删除特征权重中得分最低的特征, 并持续循环该过程, 直到获得的特征组满足本文对模型判断时间和分类准确度的综合要求. 整体特征提取时间控制在 0.5 s 以内, 准确度保证能够最终迭代到 99%, 最终得到的特征组如表 4 所示.

表 4 筛选后的特征组

Tab.4 Filtered feature groups

特征提取	特征
直方图	平均灰度 熵
不变矩	2 阶矩
Tamura	对比度 方向度
共生矩阵	45°相关性 90°对比度 90°能量 135°对比度 135°同质性

3.2 模型预测

本文采用的预测模型输入维度为[5, 10], 将输入数据先进行批归一化, 先后经过两层 LSTM 层、全连接层、dropout 层、输出层. 在全连接层和输出层之间加入 dropout 层减少过拟合, dropout 层的丢弃率为 0.2. 整个网络的损失计算采用稀疏分类交叉熵, 优化器选择 adam-optimizer, 初始学习率为 0.001. 数据集大小为 774, 按照训练集 80%、测试集 20% 划分.

将所选特征组的数据集输入到 LSTM 网络中进行分类, 训练集的准确率在迭代 20 次后趋于稳定, 最终准确率稳定在 99% 以上, 如图 7 所示.




图 7 LSTM 训练准确率

Fig.7 Train accuracy of LSTM

图 8 所示的混淆矩阵中, 主要的分类错误出现在过渡流和另外两种流型之间. 这是过渡流与两种标准流型之间人工划分的界限存在模糊性和主观性导致的. 过渡流型区域内包含了偏向塞状流和偏向泡状流的演化过程, 这种过程是随着流量和体积含气率的变化而变化的连续过程, 而不是一种阶跃式变化.




图 8 LSTM 预测混淆矩阵

Fig.8 Confusion matrix for LSTM predictions

图 9 为 4 种分类器的准确率. 对比 LSTM、SVM、随机森林和 CNN 的流型图像识别结果, LSTM 对 3 种流型的分类准确率高于其他 3 种算法.




图 9 4 种分类器的准确率对比

Fig.9 Comparison of accuracy for four classifiers

为验证所选特征组与 LSTM 网络结合的泛化效

果,本文选择一组与原数据集流量点互斥的流量点,进行图像数据采集.对新数据集进行相同的预处理、特征提取、标签分类等操作.将原图像数据集作为训练集,新图像数据集作为测试集,测试利用原图像数据集训练出的模型,在互斥的新数据集上的分类效果.图10为训练集和测试集采集数据的流量点.




图10 泛化测试训练集与测试集实验流量点

Fig.10 Experimental flow points for training and testing sets in generalization test

将新数据集输入到以原数据集作为训练集训练出的模型中进行分类,分类结果如图11所示.由图可见,塞状流与过渡流之间和泡状流与过渡流之间的识别准确率在泛化测试中都略有下降,但平均识别准确率仍达到87%~90%.在泛化测试中过渡流与两种流型之间的误差问题,本文认为是人工为流型进行标签有所缺陷.在标准的流型中,流型的特征较为明显,通过学习得到的模型能够比较好地进行分类.但是在过渡流型上,过渡流与标准流型的特征区分不明显,且人工分类存在模糊性和主观性,因此在泛化测试中出现了过渡流的较大误差.本文认为明确过渡流和标准流型之间的边界,进一步找出更有代表性的特征能够减小这种误差.




图11 泛化测试混淆矩阵

Fig.11 Confusion matrix for generalization test

4 结 语

为解决气液两相流工况下的流型识别问题,本文

在液相质量流量200~900 kg/h、体积含气率0~30%的范围内,以质量流量和体积含气率为依照进行了数据集构建,将此范围内的流型分为塞状流、泡状流和过渡流3类,在此基础上构建了时间序列数据集.并利用特征重要性方法进行特征工程,对4种常见特征提取方法的30种特征进行了处理,得到由10种特征构成的特征组.优化后的特征组提高了算法的准确性和快速性,在实验数据集上使用LSTM时间序列模型,流型预测准确度达到99%.

为验证模型的泛化能力,在工作体积含气率范围内进行了泛化测试.取互斥流量点的2组数据集,分别作为训练集和测试集,进行建模测试.泛化测试的分类准确率达到87%~90%,在可接受的范围之内.

本文提出的流型分类模型,通过排列重要性将多种不同的图像特征重构成新的特征组,并将重构的图像特征组与LSTM结合.在考虑到了工业实际应用的前提下,保证了流型识别的准确性,并具有一定的泛化能力.

参考文献:

- [1] Anklin M, Drahm M, Rieder A. Coriolis mass flowmeters: Overview of the current state of the art and latest research[J]. Flow Measurement and Instrumentation, 2006, 17(6): 317-323.
- [2] Wang T, Baker R. Coriolis flowmeters: A review of developments over the past 20 years, and an assessment of the state of the art and likely future directions[J]. Flow Measurement and Instrumentation, 2014, 40(2): 99-123.
- [3] Oko E, Yeung E, Arubi T. Performance assessment study of multiphase flow measurement with Coriolis flowmeter using pattern recognition technique[C]//Proceedings of the 8th International Conference on Multiphase Flow ICMF. Jeju, Republic of Korea, 2013: 26-31.
- [4] Ortiz-vidal L E, Mureithi N W, Rodriguez O M H. Vibration response of a pipe subjected to two-phase flow: Analytical formulations and experiments[J]. Nuclear Engineering and Design, 2017, 313: 214-224.
- [5] 孙立军, 赵子辉, 高静宇, 等. 基于RS-Stacking模型的科氏流量计两相流测量研究[J]. 天津大学学报(自然科学与工程技术版), 2023, 56(11): 1195-1204.

Sun Lijun, Zhao Zihui, Gao Jingyu, et al. Research on Coriolis flowmeters metering two-phase flow based on RS-Stacking model[J]. Journal of Tianjin University

- (Science and Technology), 2023, 56(11): 1195-1204 (in Chinese).
- [6] 马龙博, 张宏建, 周洪亮, 等. 基于 Coriolis 流量计和 SVM 的油水两相流质量流量测量的研究[J]. 高校化学工程学报, 2007, 21(2): 200-205.
Ma Longbo, Zhang Hongjian, Zhou Hongliang, et al. Mass flow measurement of oil-water two-phase flow based on Coriolis flow meter and SVM[J]. Journal of Chemical Engineering of Chinese Universities, 2007, 21(2): 200-205 (in Chinese).
- [7] Wang L J, Liu J Y, Yan Y, et al. Gas-liquid two-phase flow measurement using Coriolis flowmeters incorporating artificial neural network, support vector machine, and genetic programming algorithms[J]. IEEE Transactions on Instrumentation and Measurement, 2016, 66(5): 852-868.
- [8] Zhuang X, Sun L J, Zhao Z H, et al. Gas-liquid two-phase flow measurement models for Coriolis mass flowmeters based on SVM and ANN[C]//42nd Chinese Control Conference(CCC). Tianjin, China, DOI: 10.23919/CCC58697.2023.10239752.
- [9] Hemp J, Yeung H. Coriolis meters in two phase conditions[J]. IEEE Computing & Control Engineering, 2003, 14(4): 36-36.
- [10] Basse N T. A review of the theory of Coriolis flowmeter measurement errors due to entrained particles[J]. Flow Measurement and Instrumentation, 2014, 37: 107-118.
- [11] 周云龙, 陈飞, 刘川. 基于图像处理和 Elman 神经网络的气液两相流型识别[J]. 中国电机工程学报, 2007, 27(29): 108-112.
Zhou Yunlong, Chen Fei, Liu Chuan. Identification method of gas-liquid two-phase flow regime based on images processing and Elman neural network[J]. Proceedings of the CSEE, 2007, 27(29): 108-112 (in Chinese).
- [12] 刘俊宏. 基于图像处理和卷积神经网络的气液两相流型识别方法[D]. 吉林: 东北电力大学, 2022.
Liu Junhong. Identification Method of Gas-Liquid Two-phase Flow Regime Based on Image Processing and Wavelet Convolutional Neural Network[D]. Jilin: Northeast Electric Power University, 2022 (in Chinese).
- [13] 梁法春, 陈婧, 冉云麒, 等. 基于迁移学习的水平管气液两相流型智能识别[J]. 实验室研究与探索, 2021, 40(7): 1-5.
Liang Fachun, Chen Jing, Ran Yunqi, et al. Intelligent identification of gas-liquid two-phase flow patterns in horizontal pipes based on transfer learning[J]. Laboratory Research and Exploration, 2021, 40(7): 1-5 (in Chinese).
- [14] 翁润滢, 孙斌, 赵玉晓, 等. 基于自适应最优核和卷积神经网络的气液两相流型识别方法[J]. 化工学报, 2018, 69(12): 5065-5072.
Weng Runying, Sun Bin, Zhao Yuxiao, et al. Gas-liquid two-phase flow pattern recognition method based on adaptive optimal kernel and convolutional neural network[J]. Journal of Chemical Industry and Engineering, 2018, 69(12): 5065-5072 (in Chinese).
- [15] 陈思睿, 毕景良, 王雷, 等. 气液两相流型特征无监督提取的卷积自编码器: 机理及应用[J]. 化工学报, 2024, 75(3): 847-857.
Chen Sirui, Bi Jingliang, Wang Lei, et al. Convolutional autoencoder for unsupervised feature extraction of gas-liquid two-phase flow patterns: Mechanism and application[J]. Journal of Chemical Industry and Engineering, 2024, 75(3): 847-857 (in Chinese).
- [16] Mandhane J M, Gregory G A, Aziz K. A flow pattern map for gas-liquid flow in horizontal pipe[J]. International Journal of Multiphase Flow, 1974, 1(4): 537-553.
- [17] Haralick R M, Shanmugam K, Dinstein I. Textural features for image classification[J]. IEEE Transactions on Systems, Man, and Cybernetics, 1973, 3(6): 610-621.
- [18] Hu M K. Visual pattern recognition by moment invariants[J]. IRE Transactions on Information Theory, 1962, 8(2): 179-187.
- [19] Tamura H, Mori S, Yamawaki J. Texture feature-corresponding to visual perception[J]. IEEE Transactions on Systems, Man, and Cybernetics, 1978, 8(6): 460-473.
- [20] Graves A. Long Shorttermmemory[M]. Berlin: Springer, 2012.

(责任编辑: 孙立华)