

基于深度学习的上倾管气液两相流流型识别

汤 亮,蔡凯翼,徐适斐

(湖北工业大学 机械工程学院,湖北 武汉 430068)

摘 要:针对目前两相流流型识别率不高且通常依赖精密仪器获取流型特征等问题,提出一种基于深度神经网络的流型识别方法。通过文献报告中已收集的流型数据集,分析影响流型的关键变量,利用粒子群优化后的深度神经网络结合 Softmax 分类器在 Tensorflow 平台上进行训练,并将其分类结果与统一模型进行对比。结果表明:流型识别的最终综合识别准确率在 97.44%;流型分类结果与流型统一模型基本一致;与目前流型识别的主流方法相比,具有特征易提取、神经网络模型收敛速度快等优点。

关 键 词:深度学习;流型识别;粒子群优化算法;深度神经网络

中图分类号:O359

文献标识码:A

DOI:10.16146/j.cnki.rndlgc.2023.02.009

[引用本文格式]汤 亮,蔡凯翼,徐适斐.基于深度学习的上倾管气液两相流流型识别[J].热能动力工程,2023,38(2):64-69.
TANG Liang,CAI Kai-yi,XU Shi-fei. Identification of gas-liquid two-phase flow pattern in upward inclined pipe based on deep learning[J].
Journal of Engineering for Thermal Energy and Power,2023,38(2):64-69.

Identification of Gas-liquid Two-phase Flow Pattern in Upward Inclined Pipe based on Deep Learning

TANG Liang,CAI Kai-yi,XU Shi-fei

(School of mechanical Engineering, Hubei University of Technology, Wuhan, China, Post Code:430068)

Abstract: At present, the flow pattern recognition rate of two-phase flow is not high, and it usually depends on precise instruments to obtain flow pattern characteristics. To solve these problems, a flow pattern recognition method based on deep neural network is proposed. Through the flow pattern data set collected in the literature reports, the key variables affecting the flow pattern are analyzed, the combination of the deep neural network optimized by particle swarm and the Softmax classifier is used for training on the Tensorflow platform, and its classification results and the unified model are compared. The experimental results show that the final comprehensive recognition accuracy of flow pattern recognition is 97.44%, and the classification result of flow pattern is basically consistent with the unified flow pattern model. Compared with the current mainstream methods of flow pattern recognition, it has the advantages of easy feature extraction and fast convergence speed of neural network model.

Key words: deep learning, flow pattern identification, particle swarm optimization algorithm, deep neural network

引 言

气液两相流广泛存在于石油、化工、能源、动力等多个工业领域。两相流介质的相界面分布状况即流型,作为表征气液两相流动的重要参数之一,极大影响着气液两相流的流动特性、传热特性及两相流系统的运行^[1]。

目前,气液两相流流型识别方法主要有目测法、波动分析法以及层析成像法等^[2]。目测法指实验人员通过对系统工作中管壁的观察来判断流型,这种方法很大程度上会受到实验人员主观的影响,导致识别不够精确。波动分析法属于一种间接流型识别方法,从波动具体状态进行分析研究,需提取的特征参数通常有功率谱密度、标准偏差、斜度、多尺度熵、分型维数等^[3-5]。层析成像法通过测量管内气液三维分布来判断流型,该方法具有可视化、非侵入等优点,其在流型识别领域得到广泛应用。随着计算机技术的发展,深度学习由于其强大的非线性关联性被应用于流型识别领域^[6-8]。周云龙等人^[9]运用改进的支持向量机分类对水平管内的气液两相流流型进行了识别,但在面对大样本的情况下支持向量机的分类器性能会明显下降。翁润滢等人^[10]采用时频谱结合卷积神经网络的方法,将水平管内流型分为 3 类并进行识别。全卫国等人^[11]利用电阻层析成像系统获取流型样本数据,然后通过深度学习多层感知机进行训练和识别。但层析成像法往往需要采用大量传感器构建流型测量系统,以确保系统的实时性;部分成像法还要求被检测管道为不导电的绝缘材料,感测元件需布置在管道内壁,难以直接应用于已建气液两相流系统。李爽等人^[12]利用小波变换法提取不同信号的系数以及标准差,再结合概率神经网络的识别方法,流型识别准确率可以达到 96.63%,但其对于特征的筛选需依赖主观选择。

上述研究虽然在流型识别任务上取得不错的效果,但通常都是在水平或竖直管道的工况条件下。现实工作生产过程更多使用的是倾斜管道,并且上述研究所依赖的一些流型间接信号往往需要精密仪器才能测得,因此在实际生产监测活动中存在一定的局限性。本文提出了一种基于深度神经网络的识

别方法,将文献[13]中已收集的数据作为原始流型数据集,筛选出流型敏感特征后放入深度神经网络中进行训练,利用粒子群算法确定网络训练批次和隐含层节点数,再利用交叉熵损失函数对模型损失率进行评估。经过 500 次的迭代之后可以看到流型整体分类的准确率达到 97.44%,相较于传统网络结构提升了 5.12%,该网络模型可以准确识别双相介质为空气和水的气液两相流流型。

1 模型构建

建立神经网络模型,首先需要获取合适的实验数据集,从中筛选出对流型敏感的特征输入神经网络的输入层,经过神经网络训练,最终得出流型分类的准确率。

1.1 实验数据集

采用数据从文献[13]中获得,这些数据集最初由 Barnea 等人^[14]在关于倾斜管道中流型转换的研究中记录。其中,观测倾管流型的实验管路的装置,由直径为 50.8 mm 的透明玻璃管组成,实验环境为大气环境,实验中管道的倾斜角度从 0°到 90°不等,两相介质为水和空气。在对实验装置进行 1 952 次观测后,观测到在上倾斜管道内的环形流、气泡流、分散气泡流、间歇流、分层光滑流和分层波浪流 6 种流型。

1.2 特征变量的筛选

根据现有的实验研究,将影响流型的因素分为非相关变量组和相关变量组。非相关变量组包括气相表观速度 v_{sg} 、液相表观速度 v_{sl} 、液相密度 ρ_l 、气相密度 ρ_g 、温度 T 、液相粘度 μ_l 、气相粘度 μ_g 、重力 g 、管道粗糙度 ε 和管道倾角 θ 。相关变量组包括压力梯度 ∇p 、持液率 H_l 、雷诺数 Re 和弗劳德数 Fr 。文献[10]的实验环境为恒温恒压,气相为空气,液相为水,两相密度以及粘度为常量。因此,在非相关变量组中,除了两相的表面速度和管道倾角之外,其余参数均可视为定值。在非相关变量组中通常使用雷诺数和弗劳德数来描述两相流的特性,其中弗劳德数用于处理重力与惯性力之间的关系,雷诺数用于处理摩擦力与惯性力间的关系。本文并未考虑相关变量组中的参数,因为其参数均可以由非相关变量组中的参数表示出来。

弗劳德数公式:

$$Fr = \frac{\nu}{\sqrt{g \left(1 - \frac{\rho_g}{\rho_l} \right) D}} \quad (1)$$

式中: ν —气相或液相表观速度, m/s; ρ_g —气相密度, kg/m³; ρ_l —液相密度, kg/m³; g —重力常数; D —管内径, m; Fr —弗劳德数。

雷诺数公式:

$$Re = \rho \nu D / \mu \quad (2)$$

式中: Re —雷诺数; ρ —气相或液相的密度, kg/m³; μ —气相或者液相的粘度, Pa·s。

由文献[14]实验工况可知, 两相密度、粘度、温度以及重力常数均为定值。因此, 在神经网络模型中, 仅选择非相关变量中的气相表观速度、液相表观速度以及管道倾角为输入特征, 管道内的流型类别为输出变量。

1.3 传统深层神经网络模型构建

深层神经网络相对于单层神经网络具有更多的隐藏层和神经元, 分类识别准确率更高。所选深层神经网络共 7 层: 1 个输入层、5 个隐藏层和 1 个输出层。输入层有 3 个神经元, 分别代表 3 个敏感输入特征: 管道倾角、液相表观速度和气相表观速度。隐藏层均使用 DNN 层, 并配合 ReLU 激活函数增加网络模型的非线性, ReLU 激活函数公式为:

$$h = \text{ReLU}(H_i) = \max(0, H_i) \quad (3)$$

式中: H_i —上一层的输出。

相较于 sigmoid 函数和 tanh 函数, ReLU 激活函数有防止梯度消失的优点。隐藏层均使用全连接神经网络, 激活函数采用 ReLU 激活函数。输出层的输出单元数为 6, 分别代表 6 种相应的流型。在训练过程中, 为了使模型中预测数据分布与真实数据分布更相近, 损失函数选择交叉熵损失函数, 迭代优化器选择自适应学习率优化器, 分类器选择 Softmax 分类器。该分类器是一种对逻辑回归模型进行扩展得到的模型, 主要解决多分类问题, 公式为:

$$y_i = e^{x_i} / \sum_{j \in j} e^{x_j} \quad (4)$$

式中: x_i —分类器的第 i 个输入; j —固定值, 即两相流流型种类; y_i —分类器的第 i 个输出。

新的输出满足概率分布的所有要求, 其结果被归一化, 概率之和为 1, 通过该分类器可以明显地看出各种流型的所属概率。对于多分类问题, 通常采用交叉熵损失函数来计算预测值概率分布与真实值

概率分布之间的距离。将数据集以随机的方式进行分组, 其中 80% 为训练集, 20% 为测试集。具体网络模型如图 1 所示。




图 1 深度神经网络模型

Fig. 1 Deep neural networks model

1.4 粒子群算法优化深度神经网络

1.4.1 粒子群优化算法

粒子群优化算法是一种基于鸟类觅食研究的群体智能优化算法, 假设在 1 个 D 维的搜索空间中, 存在 n 个粒子组成的集群, 其中第 i 个粒子的位置为 $\mathbf{n}_i = \{n_1, n_2, \dots, n_i\}$, 第 i 个粒子的速度为 $\mathbf{v}_i = \{v_1, v_2, \dots, v_i\}$ 。在粒子群算法中的迭代过程中, 粒子可以依据个体的最优位置和群体的最优位置不断调整自身移动方向并移动到下一位置。个体最优位置可以称为个体极值 (gbest), 群体最优位置则为全局极值 (pbest), 粒子移动中的更新公式为:

$$\mathbf{v}_i = \mathbf{v}_i + c_1 \times \text{rand}() \times (\text{pbest}_i - \mathbf{n}_i) + c_2 \times \text{rand}() \times (\text{gbest}_i - \mathbf{n}_i) \quad (5)$$

$$\mathbf{x}_i = \mathbf{x}_i + \mathbf{v}_i \quad (6)$$

式中: $i = 1, 2, 3, \dots, n$, n 为此粒子群中的粒子总数; $\mathbf{v}_i$ —该群中第 i 个粒子的速度; $\text{rand}()$ —介于 (0, 1) 中的随机数; $\mathbf{n}_i$ —第 i 个粒子的当前所在位置; c_1 和 c_2 —粒子群算法的学习因子。

1.4.2 粒子群算法优化深度神经网络节点数

在神经网络的训练过程中, 神经网络隐藏层的节点数和训练批次往往对最终识别结果有重要影响, 如何选取一个合适的节点数和训练批次对深度神经网络模型至关重要。采用粒子群算法对其完成超参数的寻优需求, 具体步骤为:

(1) 粒子初始化。在粒子群优化算法中, 粒子仅具备两个属性, 即速度和位置, 因此初始化粒子也

是初始化这两个属性。设置最大的速度区间,防止速度超过最大值。位置信息则是整个搜索空间,在速度区间和搜索空间内随机初始化速度以及位置。初始化学习因子选择 $c_1 = 2, c_2 = 2$, 节点数区间为 $[32, 256]$, 需要优化的粒子数为 5, 适应度函数为交叉熵损失函数, 粒子群算法的最大迭代次数为 10;

(2) 计算各粒子的目标函数, 找到各粒子的个体极值, 找到整体粒子群的当前最优解;

(3) 更新粒子的速度和位置;

(4) 使用最优超参数建立深度神经网络预测模型, 将测试集输入该模型, 得到流型预测结果。

2 实验结果分析

2.1 神经网络评定标准

为客观评价神经网络的分类精度, 需要评估当前训练得到的概率分布与真实概率分布的差异情况。本模型选取的损失函数是交叉熵损失函数 (categorical_crossentropy), 交叉熵的值越小, 两个概率分布就越接近。损失函数公式为:

$$L = - \frac{1}{N} \sum_i \sum_{c=1}^M y_{ic} \log(p_{ic})$$

(7)

式中: M —流型分类的类别数量; y_{ic} —符号函数 (0 或 1), 样本 i 的真实类别等于 c 时取 1, 否则为 0; p_{ic} —观测样本 i 属于类别 c 的预测概率。

通过式 (7) 可以求出损失值, 将其作为神经网络模型的损失率评定标准。以传统的准确率评定标准作为该模型的准确率评定标准, 该标准指在一个批次中预测出来的正确样本数占总体样本数的比例。选取超参数区间的均值代表传统神经网络的识别结果, 经过 500 次迭代之后, 识别结果如图 2 所示。可以看到, 模型基本得到收敛, 但是其损失率比较高, 达到了 0.192 3。

2.2 PSO-DNN 的结果分析

粒子群优化可以帮助神经网络模型找到最佳隐藏层的节点数, 从而降低迭代过程中的损失率。经过粒子群群体优化算法优化后的各隐藏层参数分别确定为 155, 250, 131, 193 和 140, 训练批次为 64。优化后深度神经网络 PSO-DNN 迭代准确率以及损失率如图 3 所示。




图 2 传统神经网络训练过程
Fig.2 Neural network training process




图 3 PSO-DNN 网络模型训练过程
Fig.3 PSO-DNN network model training process

对比图 2 和图 3 可知,经过粒子群优化后的深度神经网络的准确率和损失率都有明显改善,其中测试集准确率达到 97.44%,损失率降低至 0.112 9。相较于传统网络模型,迭代过程中测试集准确率提升了 5.12%,损失率降低了 7.94%。最终预测结果的混淆矩阵如图 4 所示。另外,为了更容易识别神经网络模型,通常将输出特征和输入特征以数字的形式表示,这里使用 0,1,2,3,4,5 来表示神经网络模型中所进行训练和预测的流型,分别代表环形流、气泡流、分散气泡流、间歇流、分层光滑流和分层波浪流 6 种流型。矩阵主对角线上的元素均为模型预测正确的流型样本数,主对角线上元素在相应列上的占比则表示模型对各种流型识别的准确率。




图 4 训练批次为 64 时的混淆矩阵

Fig. 4 Confusion matrix when the training batch is 64

从数据集中随机选取 389 组流型数据作为参考,其中标签为 1,2,4 的 3 列中对角线元素占比均为 100%,即表明气泡流、分散气泡流和分层光滑流这 3 种流型识别的准确率最高,均达到 100%,而标签为 0 和 3 的两列中对角线元素占比次之,即模型对于环形流和间歇流的准确率次之,分别为 97.72% 和 98.06%;标签为 5 的这列中对角线元素占比最低,即模型对于分层波浪流识别准确率最低,为 92.86%。由于分层波浪流在气相表面速度较高而液相表面速度较低的工况下才出现,而环形流也是在这一工况下产生的,所以神经网络模型容易误识别。在神经网络分类的过程中,当预测环形流的概率大于 50% 时,Softmax 函数会将测试流型识别成环形流。

2.3 神经网络模型的验证

为进一步验证深度学习的准确性,将神经网络模型分类出来的流型与文献[15]的无量纲流型图做对比。本文仅针对管道倾角为 30°的气液两相流流型图做对比,如图 5 所示。其中,液体表面速度范围为 0.004 ~ 3.756 m/s,气体表面速度范围为 0.037 ~ 26.749 m/s。在图 5 中,实线代表文献[14]中的流型分界曲线,正方形代表环形流,圆形代表分散气泡流,三角形代表间歇流。由图 5 可知,深度学习预测的流型和文献[14]中模型流型图基本匹配,在倾角为向上 30°时,管道内可以观察到分散气泡流、间歇流和环形流 3 种流型。




图 5 倾角向上 30°两相流的神经网络分类模型与统一模型对比图

Fig. 5 Comparison between neural network classification and unified model of two-phase flow with upward inclination of 30°

3 结 论

提出了一种 PSO-DNN 网络的流型识别方法,用于识别倾斜管道内气液两相流的流型。利用文献中所收集的数据集,筛选其中对流型敏感的特征作为输入,并结合粒子群算法确定模型的训练批次以及隐含层神经元参数后,对于存在倾角的气液两相流流型进行了分类识别,结论为:

- (1) PSO-DNN 网络模型识别方法利用管道倾角、液相表观速度和气相表观速度这些变量,无需精密的仪器即可在实际生产中应用。
- (2) 在简化特征的同时,流型识别的整体准确率达到 97.44%,其中气泡流、分散气泡流和分层光

滑流准确率达到 100%, 满足对气液两相流流型分类的要求。

参考文献:

[1] LI X N, LIU M Y, MA Y L. Experiments and meso-scale modeling of phase holdups and bubble behavior in gas-liquid-solid mini-fluidized beds [J]. Chemical Engineering Science, 2015, 192: 725 – 738.

[2] 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 Fa-chun, CHEN Jing, RAN Yun-qi, et al. Intelligent identification of gas-liquid two-phase flow pattern in horizontal pipe based on transfer learning [J]. Research and Exploration in Laboratory, 2021, 40(7): 1 – 5.

[3] 刘耀徽. 基于随机森林的气液两相流型识别研究[D]. 吉林: 东北电力大学, 2021.

LIU Yao-hui. Study on identification of gas-liquid two-phase flow pattern based on random forest [D]. Jilin: Northeast Electric Power University, 2021.

[4] 姚 添, 郭烈锦, 徐 强, 等. 基于压差信号融合特征的集输立管流型识别研究[J]. 工程热物理学报, 2020, 41(12): 3014 – 3019.

YAO Tian, GUO Lie-jin, XU Qiang, et al. Investigation on flow regimes recognition in pipeline-riser based on fusion features of differential pressure signals [J]. Journal of Engineering Thermophysics, 2020, 41(12): 3014 – 3019.

[5] 尹洪梅. 基于熵分析棒束通道气液两相流型识别及动力学特性分析[D]. 吉林: 东北电力大学, 2017.

YIN Hong-mei. Identification of gas-liquid two-phase flow pattern and analysis of dynamic characteristics in rod bundle channel based on entropy analysis [D]. Jilin: Northeast Electric Power University, 2017.

[6] 全卫国, 曾世超, 李芝翔, 等. 基于 LSTM 的气液两相流液相流量测量方法[J]. 仪表技术与传感器, 2021(11): 94 – 98.

TONG Wei-guo, ZENG Shi-chao, LI Zhi-xiang, et al. Liquid phase flow measurement method of gas-liquid two-phase flow based on LSTM [J]. Instrumentation Technology and Sensors, 2021(11): 94 – 98.

[7] DU M, YIN H, CHEN X, et al. Oil-in-water two-phase flow pattern identification from experimental snapshots using convolutional neural network[J]. IEEE Access, 2018, 7: 6219 – 6225.

[8] LIN Zi, LIU Xiao-lei, LAO Li-yun, et al. Prediction of two-phase flow patterns in upward inclined pipes via deep learning[J]. Energy, 2020, 210: 118541.

[9] 周云龙, 孙 斌, 陆 军. 改进 BP 神经网络在气液两相流流型识别中的应用[J]. 化工学报, 2005, 56(1): 110 – 115.

ZHOU Yun-long, SUN Bin, LU Jun. Application of improved BP neural network in flow pattern identification of gas-liquid two-phase flow [J]. CIESC Journal, 2005, 56(1): 110 – 115.

[10] 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流型识别方法[J]. 化工学报, 2018, 69(12): 5065 – 5072.

WENG Run-ying, SUN Bin, ZHAO Yu-xiao, et al. Flow pattern identification method of gas-liquid two-phase flow based on adaptive optimal kernel and convolutional neural network [J]. Journal, 2018, 69(12): 5065 – 5072.

[11] 全卫国, 朱赓宏. 基于多层感知器的气液两相流流型识别方法[J]. 热能动力工程, 2020, 35(6): 116 – 122.

TONG Wei-guo, ZHU Geng-hong. Gas-liquid two-phase flow pattern recognition method based on multilayer perceptron[J]. Journal of Engineering for Thermal Energy and Power, 2020, 35(6): 116 – 122.

[12] 李 爽, 李玉星, 王冬旭. 基于小波变换与神经网络的上倾管流型识别方法[J]. 油气储运, 2020, 39(8): 912 – 918.

LI Shuang, LI Yu-xing, WANG Dong-xu. Identification method for flow pattern in upward pipe based on wavelet transform and neural network [J]. Oil and Gas Storage and Transportation, 2020, 39(8): 912 – 918.

[13] PERERYRA E, TORRES C, MOHAN R, et al. A methodology and database to quantify the confidence level of methods for gas-liquid two-phase flow pattern prediction[J]. Chemical Engineering Research and Design, 2011, 90: 507 – 513.

[14] BARNEA D, SHOHAM O, TAITEL Y, et al. Flow pattern transition for gas-liquid flow in horizontal and inclined pipes. Comparison of experimental data with theory[J]. International Journal of Multiphase Flow, 1980, 6(3): 217 – 225.

[15] BARNEA D. A unified model for predicting transitions for the whole pipe inclinations[J]. International Journal of Multiphase Flow, 1987, 13(1): 1 – 12.

(刘 颖 编辑)