

DOI: 10.19650/j.cnki.cjsi.J2107873

基于门控循环单元的动态过程下两相 CO₂ 质量流量测量*

丁宁¹, 邵丁¹, 闫勇², 张文彪¹

(1. 华北电力大学控制与计算机工程学院 北京 102206; 2. 英国肯特大学工程学院 坎特伯雷 CT2 7NT, UK)

摘要:针对碳捕集与封存条件下科里奥利质量流量计测量气液两相 CO₂ 动态过程质量流量时误差较大的问题,本文提出了一种基于门控循环单元(GRU)的动态过程下气液两相 CO₂ 质量流量校正方法。利用 GRU 适合动态过程预测的特点,使用来自 CO₂ 气液两相流实验平台的采集数据,对 GRU 网络模型进行训练,并使用网格搜索法结合 K 折交叉验证优化模型参数。使用八组典型工况下的测试集对优化后的 GRU 模型在测量精度和泛化性能方面进行了评估,并与最小二乘支持向量机(LS-SVM)模型进行了对比分析。实验结果表明 GRU 模型优于 LS-SVM 模型,并且 GRU 模型在动态波动发生后的平稳阶段,其输出结果能够快速跟随 CO₂ 质量流量变化,相对误差在±5%以内。

关键词: 碳捕集与封存; 质量流量测量; 科里奥利质量流量计; 气液两相 CO₂; 门控循环单元

中图分类号: TH814 TP183 **文献标识码:** A **国家标准学科分类代码:** 460.40

Mass flowrate measurement of two-phase CO₂ in a transient process using a gated recurrent unit neural network model

Ding Ning¹, Shao Ding¹, Yan Yong², Zhang Wenbiao¹

(1. School of Control and Computer Engineering, North China Electric Power University, Beijing 102206, China;

2. School of Engineering, University of Kent, Canterbury CT2 7NT, UK)

Abstract: The transient process of gas-liquid two-phase CO₂ flow can occur in carbon capture and storage pipelines. Large measurement errors exist when Coriolis mass flowmeters are used to measure the mass flowrate of CO₂ under such conditions. To solve this problem, a method for mass flowrate correction based on a gated recurrent unit (GRU) neural network is proposed. Since the GRU is suitable for dynamic process prediction, the GRU model is trained by using the collected datasets from a CO₂ gas-liquid two-phase flow rig and optimized by using a grid search method combined with the K-fold cross-validation. The optimized GRU model is evaluated in terms of measurement accuracy and generalization capability by using eight groups of datasets under typical experimental conditions. The GRU model is compared with the least squares support vector machine (LS-SVM) model. Experimental results show that the GRU model could achieve better results than the LS-SVM model. The output of the GRU model can follow the change of CO₂ mass flowrate in the steady state after the transient process, and relative error is within ±5%.

Keywords: carbon capture and storage; mass flow measurement; Coriolis mass flowmeter; gas-liquid two-phase CO₂; gated recurrent unit

0 引言

在碳捕集与封存(carbon capture and storage, CCS)过程中,准确计量输送管道内 CO₂ 的质量流量对输送过程的安全稳定运行至关重要^[1-2],同时也能为碳交易

提供可靠的计量依据^[3]。由于 CO₂ 特殊的热力学特性,CCS 条件下 CO₂ 的流量测量相较其他工业过程中油气或气水两相流的流量测量更具挑战性。输送管道的工作压力和温度非常接近 CO₂ 的临界压力和温度,使得管道内 CO₂ 容易发生相变,管道压力和温度的微小变化都会显著改变 CO₂ 混合物的相态,进而可导致

收稿日期:2021-06-28 Received Date: 2021-06-28

* 基金项目:国家自然科学基金(61973113,62073135)、英国 UKCCSRC、中央高校基本科研业务费(2020MS015)项目资助

气体体积分数和流型的变化,给流量测量带来困难。Collie 等^[4]针对 CCS 条件下的 CO₂ 计量难题,对现有流量测量方法进行了总结。通过对比不同测量方法,指出科里奥利质量流量计(Coriolis mass flowmeter, CMF)在 CCS 中有较好的应用前景。CMF 测量单相流量时准确度高、测量范围广、重复性好,但 CMF 测量多相流体时测量误差较大。

多相流测量具有高度复杂、动态且非线性特点。测量过程涉及多个参数间非线性的耦合,且受复杂流型的影响,因此通过机理方面分析减小测量误差通常十分困难^[5]。由于数据驱动模型善于处理复杂和非线性问题,且具有实现简单和测量精度高等优点,通过建立数据驱动模型解决多相流测量难题成为可能。数据驱动模型通过从传感器输出结果中提取特征数据,建立模型,进而估计多相流的流量和含率或实现流型识别^[6]。Wang 等^[7]将数据驱动模型引入到 CMF 对气水两相流的测量中,以校正液相质量流量并预测气体体积分数为目标,比较了支持向量机(support vector machine, SVM)、反向传播神经网络(back propagation artificial neural network, BP-ANN)、径向基函数神经网络(radical basis function artificial neural network, RBF-ANN)和遗传编程(genetic programming, GP)4 种模型的测量准确性,结果表明 SVM 相较其他 3 种模型更有优势。其中,使用 SVM 模型测量液相质量流量时,水平和垂直管道分别有 93.49% 和 93.17% 的实验数据相对误差在 $\pm 1\%$ 内;使用 SVM 模型预测气体体积分数时,水平和垂直管道分别有 93.10% 和 94.25% 的实验数据相对误差在 $\pm 10\%$ 内。陶波波等^[8]将 BP 神经网络模型应用于气水两相流的质量流量测量校正,结合基于数字信号处理的 CMF,测量含气量达到 20% 的气水两相流时,实时测量精度优于 $\pm 4\%$ 。但 CCS 条件下的 CO₂ 热力学特性与以上研究中的流体大不相同。针对 CCS 条件下气液两相 CO₂ 流量测量, Wang 等^[9]将 CMF 与最小二乘支持向量机(least squares support vector machine, LS-SVM)模型结合,使用基于流型分类的 LS-SVM 模型校正 CMF 质量流量并预测含气率,其中质量流量测量的相对误差在水平和垂直管道分别小于 2% 和 1.5%,而含气率的预测误差在 $\pm 10\%$ 内。但是该数据驱动模型仅适用于稳态两相 CO₂ 质量流量测量,无法对动态过程中 CMF 的误差进行校正。在动态 CCS 过程中 CMF 测量气液两相 CO₂ 会产生较大的误差,特别是当两相中气体体积分数变化时,由于气态 CO₂ 的可压缩性,气体流量的大幅变化会影响 CMF 中流体与其输送管道之间的振动,从而导致质量流量在陡增或陡减过程中出现超调或欠调^[10]。

循环神经网络(recurrent neural network, RNN)具有记忆能力,适合于动态过程预测,其变体长短时记忆

(long short-term memory, LSTM)神经网络和门控循环单元(gated recurrent unit, GRU)神经网络进一步克服了 RNN 的缺陷。Zhang 等^[11]利用 LSTM 处理单相液体的 CMF 输出信号,以 CMF 的振动信号作为输入,质量流量作为输出,进行回归,实验结果表明 LSTM 优于 ANN 和传统 RNN,同时证明了在单相液体条件下使用循环神经网络校正 CMF 输出的可行性,但该研究并未考虑两相动态工况。并且 GRU 的单元结构相比于 LSTM 更为简化,其网络训练的复杂度更低,训练时间更短^[12],因此更适合基于 CMF 的动态过程 CO₂ 质量流量测量问题。本文首次提出了一种基于 GRU 神经网络的 CMF 动态误差校正模型,并与 LS-SVM 模型进行了对比分析,最终验证了 GRU 模型的测量准确性和泛化性能。

1 测量原理

1.1 CMF 测量原理及两相测量误差分析

CMF 的结构组成主要包括测量管、驱动器、电磁感应器、温度传感器和转换器等。如图 1 所示的科里奥利流量计,其测量管为常见的平行双 U 型输送管,驱动器在 U 型测量管的底部中点施加谐振频率的激励,使得流经的被测流体受科里奥利力产生振动。受流体影响,测量管前后半段产生方向相反的挠曲,测量管两端位置对称的电磁感应器 A、B 所得信号会存在相位差^[13]。转换器通过处理上述传感器所得信号,求解出被测流体的质量流量及密度等信息。




图 1 科里奥利质量流量计示意图^[13]

Fig. 1 Schematic diagram of Coriolis mass flowmeter^[13]

以双 U 型 CMF 为例,理论计算公式如下:

$$\begin{cases} F_c = 2mv \times \omega \\ dT = 2R \times dF_c \\ v = \frac{dx}{dt} \\ q_m = \frac{dm}{dt} \end{cases} \quad (1)$$

式中: F_c 为流体受到的科里奥利力; m 为受力流体的质量; v 为流体流速; ω 为测量管的振动频率; dT 为受到的力

矩; R 为测量管弯曲部分的半径; q_m 为流体质量流量。结合式(1)可得力矩为:

$$T = \int_0^L dT = 4R\omega q_m L \quad (2)$$

式中: L 为电磁感应器距离测量管上端的距离。同时, 测量管在力矩作用下有如下公式:

$$T = K_s \theta \quad (3)$$

式中: K_s 为 U 型管的扭转弹性模量; θ 为力矩作用下测量管产生的扭转角。根据式(2)和(3)联立可得:

$$q_m = \frac{K_s \theta}{4R\omega L} \quad (4)$$

由式(4)可知质量流量 q_m 正比于扭转角 θ 。

电磁感应器 A、B 检测到 U 型管振动信号的时间差和相位差分别为:

$$\Delta t = \frac{2R\theta}{L\omega} \quad (5)$$

$$\theta = \frac{L\omega\Delta t}{2R} \quad (6)$$

代入式(6)到式(4)中可得:

$$q_m = \frac{K_s}{8R^2} \Delta t \quad (7)$$

理论上, 通过检测出 A、B 两路传感器测得信号的时间差 Δt 即可求解出质量流量 q_m 。

CMF 在单向流工况下的测量准确性较高, 但在两相工况下气体的可压缩性会导致 CMF 测量时产生较大的误差^[14]。特别在气液两相动态过程中, 流体流动时气体和液体的密度差异会导致测量管的机械损失和阻尼比变化, 驱动器难以跟随这种变化, 即无法保证测量管谐振激励的稳定性, 造成流量测量出现更大的误差。

1.2 GRU 循环神经网络

使用数据驱动模型对 CMF 测量两相 CO_2 质量流量进行校正需要首先确定适用的网络结构。在各类数据驱动模型中, RNN 拥有处理时间序列数据的能力, 而其变体 LSTM 和 GRU 进一步克服了 RNN 处理长序列时易出现的梯度消失或爆炸的问题, 实验证明两者表现完全优于传统的 RNN^[15]。本文中的数据驱动模型使用 GRU 神经网络。与 LSTM 相比, GRU 的网络结构更为简化, 如图 2 所示。

GRU 单元结构中具有更新门和重置门, 更新门决定了上一层隐藏状态中有多少信息传递到当前隐藏状态中, 重置门作用于当前记忆内容, 决定了上一时刻隐藏状态的信息中有多少被遗忘。详细的计算公式如下:

$$z_t = \sigma(W_z \times [h_{t-1}, x_t]) \quad (8)$$

$$r_t = \sigma(W_r \times [h_{t-1}, x_t]) \quad (9)$$

式中: z_t 为更新门; r_t 为重置门; W_z 、 W_r 分别是它们的权




图2 GRU网络的单元结构

Fig. 2 Unit structure of the GRU network

重矩阵; σ 为 Sigmoid 激活函数, h_{t-1} 为 $t-1$ 时刻隐藏状态, x_t 为 t 时刻的输入向量。

$$\tilde{h}_t = \tanh(W_h \times [r_t * h_{t-1}, x_t]) \quad (10)$$

式中: $\tilde{h}_t$ 为当前记忆内容; $\tanh$ 为双曲正切函数; W_h 为权重矩阵, “*” 表示矩阵中对应元素相乘。

$$h_t = (1 - z_t) * h_{t-1} + z_t * \tilde{h}_t \quad (11)$$

式中: h_t 为当前隐藏状态, 也是本单元最终输出的记忆信息。

1.3 数据驱动模型输入和输出变量的选择

使用数据驱动模型对 CMF 测量两相 CO_2 质量流量进行校正还需要选择合适的输入变量。测量两相 CO_2 时, CMF 的输出质量流量是表观质量流量, 其与两相 CO_2 真实质量流量是强关联的, 应作为 GRU 数据驱动模型的输入变量之一。CMF 在输出表观质量流量的同时也可以提供密度和温度信息, 其中温度信息由 CMF 中包含的温度传感器得到。表观密度和温度间接反映了两相中的含气率^[16], 而含气率的改变正是导致 CMF 测量 CO_2 质量流量动态误差较大的主要原因, 所以表观密度和温度也应作为输入变量。利用差压变送器测量 CMF 两端的压降, 差压与流体的流量和含率有关, 可以在一定程度上反映流量的动态波动信息, 所以也被选为数据驱动模型的输入变量。GRU 网络的输出是两相的真实质量流量。基于 GRU 网络的数据驱动模型的结构如图 3 所示。




图3 数据驱动模型的结构

Fig. 3 Structure of the data-driven model

1.4 GRU 网络参数寻优

在确定 GRU 网络的输入输出参数后,需要对 GRU 网络的超参数进行寻优,使训练模型满足要求。

K 折交叉验证(K-fold cross-validation, CV)是通过将样本均分成 K 份,每次使用 $K-1$ 份作为训练集,剩余的一份作为验证集来计算误差,这个过程重复 K 次。最后将 K 次误差的平均值作为外部样本误差的 CV 估计值^[17]。

网格搜索优化是一种穷举法,对需要寻优的超参数进行列举或分隔,计算时遍历超参数的所有组合并比较评价指标后得到最优解^[18]。当超参数的数量增长时,网格搜索的计算复杂度会呈现指数增长。如果样本量较大,一次性对过多的超参数进行网格搜索通常是不现实的。这时可以用坐标下降的快速调优方法,按照超参数对模型的影响权重,先对影响最大的超参数进行优化,再对其他参数依次进行优化。但这种方法会有陷入局部最优的风险。

通过结合网格搜索法和 K 折交叉验证对超参数进行寻优,能在一定程度上避免寻优过程陷入局部最优解。

2 实验条件与数据预处理

2.1 实验装置及条件

本文实验装置的示意图如图 4 所示。气相和液相 CO₂ 分别由压缩机与泵驱动,分别从分离器的上部 and 底部流出,在混合器混合后,经过测试管段流回分离器。因为 CMF 测量单相流质量流量时具有非常高的准确度,在气相和液相管道分别安装了一块 CMF,用于获得气相和液相 CO₂ 的质量流量。其中,气相 CO₂ 质量流量测量的不确定度为 0.35%,液相 CO₂ 质量流量测量的不确定度

为 0.16%^[19],包含因子 $k=2$,即有 95% 置信率。根据质量守恒原理,测试管段的质量流量,即模型训练时使用的真实质量流量,可由气液单相质量流量相加获得。在混合器的入口和测试段分别安装有温度和压力传感器,用于提供单相和两相 CO₂ 流体的温度及压力信息。差压变送器安装在测试段 CMF 两端,用于提供差压信息。考虑到管道方位对两相 CO₂ 流体的影响,实验包括水平和竖直两种安装方式。

GRU 模型训练数据集是在两相 CO₂ 全工况条件下获取的,所采集的数据涉及流量平稳和动态变化的全过程。实验过程中液态 CO₂ 的质量流量变化范围是 200~3 100 kg/h,气体体积分数是 0~84%。测试数据集主要涉及两相 CO₂ 动态过程,包括在稳定液相流量的条件下陡增或陡减气相流量和稳定气相流量的条件下陡增或陡减液相流量。

2.2 数据预处理

CMF 的采样频率约为 48 Hz,两相中流量突变导致的动态波动会在 5~10 s 内结束,被控对象的频率较低。本文通过降采样的预处理手段使采样频率变为 4.8 Hz,一方面 4.8 Hz 的采样频率已经足够表征动态变化过程,另一方面避免不必要的多余数据造成模型训练负担过大。在 4.8 Hz 的采样频率下,共采集到 30 万个有效数据样本点。

在实验过程中设备的启停及工况的更换会导致训练数据集中出现尖峰或低谷等异常值。这些异常数据点的出现在连续实验采集过程中不可避免,但其本身与本文所研究的两相 CO₂ 动态过程下的数据波动规律无关且有明显差异,为消除异常值对数据驱动模型的干扰,对其进行了剔除。




图 4 气液两相 CO₂ 实验装置

Fig. 4 Schematic of the gas-liquid two-phase CO₂ flow rig

为了消除不同参数数值差异以及量纲不同的影响,需要对数据进行标准化处理^[20]。数据标准化处理是对每一个特征维度单独进行的,处理后的数据符合标准正态分布,即均值为 0,标准差为 1,公式如下:

$$x^* = \frac{x - \mu_x}{\sigma_x} \quad (12)$$

式中: x 为带量纲的原始数据; x^* 为标准化后的数据; μ_x 为原始数据的平均值; σ_x 为原始数据的标准差。

3 实验结果与性能分析

3.1 GRU 模型的训练及优化

首先通过网格搜索结合 5 折交叉验证对 GRU 网络的超参数进行寻优,损失选用均方误差(mean square error, MSE),最终确定优化器种类为 Adam^[21],激活函数为 sigmoid,权值和循环核初始化方法分别为 Glorot 正态分布和随机正交矩阵,隐含神经元个数为 60。在循环神经网络的数据集输入格式中,时间步长也是一个可调参数,会影响到模型拟合的效果。针对本实验中的数据集,在训练过程中发现时间步长为 5,即用过去 5 个时刻的数据可以决定当前时刻的输出,相比于更长的时间步长更有优势。

通过在模型拟合过程中引入学习率衰减及早停等回调函数对网络进一步优化,这个过程中将数据按照 4:1 分为训练集和验证集。设置 Adam 优化器的初始学习率为 0.000 1,利用学习率衰减的回调函数监控验证集上的损失,若损失在连续迭代 5 次后依然没有降低,则将学习率调整为原先的一半,并设置学习率降低的下限为 0.000 01。当验证集的损失在连续迭代 10 次后依然没有降低,则触发早停的回调函数,避免过拟合。

GRU 网络模型优化完毕后,分别使用水平和竖直管道的数据集进行训练,训练过程中 80% 的数据作为训练集,20% 作为验证集。使用水平测试段数据集时,最终迭代至 84 次时停止,使用竖直测试段数据集时,最终迭代至 65 次时停止。

本文同时建立了 LS-SVM 模型对 CMF 在动态过程下两相 CO₂ 的质量流量测量结果进行校正。LS-SVM 模型使用了和 GRU 模型相同的训练数据,优化过程中使用网格搜索法结合 5 折交叉验证获得了最优的平衡参数 γ 和核函数参数 σ^2 。

3.2 GRU 模型测量准确性及泛化性能分析

选取动态过程下两相 CO₂ 典型工况的实验数据用于评估所训练 GRU 和 LS-SVM 模型的性能,共选取了 8 组实验测试集,这 8 组测试集在模型训练及调优的过程中

均未出现,因此可以反映模型的泛化性能。8 组测试集的具体工况如表 1 中所示。这些选取的测试工况涵盖了本实验装置能够提供的多种流量范围及多种动态变化过程,能够表征典型的两相 CO₂ 动态过程。

表 1 气相或液相质量流量陡增或陡减的实验工况

Table 1 Experimental conditions with step changes in gas or liquid mass flow rate kg/h

测试工况	气相质量流量	液相质量流量
L500Q-UP	120~180	500
L500Q-DN	120~20	500
L2000Q-UP	40~110	2 000
L2000Q-DN	110~40	2 000
Q70 L-UP	70	350~600
Q70 L-DN	70	600~350
Q120 L-UP	120	500~750
Q120 L-DN	120	750~500

工况 L500Q-UP 和 L500Q-DN 为液相流量保持低流量 500 kg/h,气相流量陡增和陡减。工况 L2000Q-UP 和 L2000Q-DN 为液相流量保持高流量 2 000 kg/h,气相流量陡增和陡减。工况 Q70 L-UP 和 Q70 L-DN 为气相流量保持 70 kg/h,液相流量陡增和陡减。工况 Q120 L-UP 和 Q120 L-DN 为气相流量保持 120 kg/h,液相流量陡增和陡减。

部分测试工况下质量流量及相对误差对比如图 5~8 所示。如图 5 所示,在气相陡减的动态过程发生前,GRU 和 LS-SVM 都表现出了较好的校正效果,相对误差分别为 $\pm 3.31\%$ 和 $\pm 3.33\%$,而 CMF 直接测量的相对误差达到 $\pm 9.07\%$ 。在气相陡减以及后续动态过程中,GRU 模型始终跟随参考质量流量变化,比 CMF 直接测量和 LS-SVM 模型具有更小的相对误差,相对误差仅 $\pm 4.95\%$,而 CMF 直接测量的相对误差为 $\pm 8.80\%$,LS-SVM 模型的相对误差甚至达到 $\pm 19.17\%$,其模型严重丧失了校正能力。如图 6 所示,对于液相质量流量高达 2 000 kg/h 的工况,LS-SVM 模型表现出了一定的校正效果,且在气相陡增或陡减的动态过程中校正效果较好。但在波动发生后的稳定阶段,GRU 模型输出曲线比 LS-SVM 模型更加平稳,GRU 和 LS-SVM 在稳定阶段的相对误差分别为 $\pm 2.09\%$ 和 $\pm 2.82\%$ 。如图 7 所示,气相维持稳定但液相陡增的工况下,动态波动发生后,GRU 模型依然能跟随参考质量流量,GRU 和 LS-SVM 模型在稳定阶段的相对误差分别为 $\pm 4.23\%$ 和 $\pm 4.96\%$ 。如图 8 所示的工况下,

GRU 和 LS-SVM 模型在动态波动发生前及波动过程中并不能有效地校正质量流量输出曲线,不可避免地出现较大的相对误差。但在动态波动后的稳定阶段,GRU 模型凭借其优异的动态预测能力,能够跟随参考质量流量变化,相对误差为 $\pm 2.69\%$,而 LS-SVM 模型和 CMF 直接测量的相对误差分别达到 $\pm 6.40\%$ 和 $\pm 10.13\%$ 。全部测试工况下 CMF 直接测量及两种模型所得的相对误差如表 2 所示。




图 5 水平测试段工况 L500Q-DN 下的结果对比
Fig. 5 Results comparison of test L500Q-DN under horizontal test conditions





图 6 竖直测试段工况 L2000Q-UP 下的结果对比
Fig. 6 Results comparison of test L2000Q-UP under vertical test conditions




图 7 竖直测试段工况 Q70 L-UP 下的结果对比
Fig. 7 Results comparison of test Q70 L-UP under vertical test conditions

表 2 中只给出了波动发生阶段和波动后稳定阶段的相对误差。其中,波动发生阶段的相对误差表征两相 CO₂ 中某一相发生流量突变而导致 CMF 测量失调时两种模型的校正能力,波动后稳定阶段的相对误差表征




图 8 水平测试段工况 Q120 L-DN 下的结果对比

Fig. 8 Results comparison of test Q120 L-DN under horizontal test conditions

CMF 或模型快速跟随真实质量流量的能力及跟随准确度。波动发生前的阶段不属于动态过程,不在本文考虑范围内,因此并未在表 2 中列出。

使用 GRU 和 LS-SVM 模型对水平或竖直测试段的 CMF 动态测量结果进行校正时,质量流量和相对误差的对比表明:

1) GRU 模型具有出色的动态预测能力,特别是当气相或液相陡增或陡减的波动过程结束后,GRU 模型输出能快速跟随参考质量流量变化。除去竖直段工况 L500Q-DN 和 Q70 L-DN,GRU 模型在动态波动结束后的稳定阶段相对误差在 $\pm 5\%$ 以内,从质量流量的结果对比可以看出 GRU 模型校正效果明显优于 LS-SVM 模型。反观 LS-SVM 模型在大部分工况下都无法在动态波动后较好地跟随参考质量流量变化,所以 LS-SVM 模型并不适合用于动态过程下两相 CO_2 质量流量的校正。导致 LS-SVM 表现较差的原因之一是其模型内部结构无法处理 CMF 表观质量流量的历史数据,只能依据当前时刻的模型输入确定校正后的质量流量。GRU 因为其模型结构中具有能够记忆历史质量流量信息的门控单元,在动态过程流量校正中更具优势。

2) 导致 LS-SVM 模型结果较差的另一个主要原因是其模型的泛化性能较弱。本文中训练模型所用的数据集虽然包含多种动态过程下的工况,但并不可能完全包括测试集的工况,此种情况下要获得较低的相对误差就需要模型具有出色的泛化性能。从相对误差对比的结果来

表 2 全部测试工况下相对误差的对比

Table 2 Comparison of relative errors under all test conditions

%

全部测试工况		CMF 直接测量		GRU 模型		LS-SVM 模型	
		波动发生阶段	稳定阶段	波动发生阶段	稳定阶段	波动发生阶段	稳定阶段
L500Q-UP	水平	± 13.22	± 7.72	± 4.01	± 2.93	± 6.27	± 2.51
	竖直	± 13.58	± 2.87	± 5.61	± 4.10	± 17.36	± 3.88
L500Q-DN	水平	± 8.80	± 6.24	± 4.17	± 4.95	± 19.17	± 15.12
	竖直	± 26.85	± 17.24	± 5.98	± 11.23	± 20.40	± 28.92
L2000Q-UP	水平	± 1.99	± 3.80	± 3.29	± 2.06	± 1.88	± 1.51
	竖直	± 1.78	± 4.60	± 2.69	± 2.09	± 1.47	± 2.82
L2000Q-DN	水平	± 3.98	± 0.96	± 2.67	± 1.37	± 1.00	± 0.76
	竖直	± 6.18	± 2.79	± 2.18	± 1.76	± 4.16	± 1.89
Q70 L-UP	水平	± 16.17	± 3.28	± 12.95	± 3.28	± 11.78	± 6.56
	竖直	± 15.30	± 5.52	± 10.87	± 4.53	± 12.47	± 4.96
Q70 L-DN	水平	± 23.26	± 14.81	± 21.84	± 4.70	± 14.73	± 11.45
	竖直	± 15.02	± 2.37	± 14.12	± 6.31	± 19.43	± 11.25
Q120 L-UP	水平	± 11.50	± 1.27	± 10.75	± 2.49	± 12.22	± 4.52
	竖直	± 13.77	± 3.88	± 10.93	± 3.34	± 14.16	± 6.34
Q120 L-DN	水平	± 16.27	± 10.13	± 18.80	± 2.69	± 15.60	± 6.40
	竖直	± 14.84	± 3.01	± 14.96	± 4.76	± 17.80	± 9.62

看,GRU模型比LS-SVM模型表现出了更强的泛化性能。

3)处于波动发生阶段时,无论是GRU还是LS-SVM模型,其输出都不可避免地出现较大的动态误差。但是在工况L500Q-UP和L500Q-DN的波动发生阶段,GRU模型表现出了良好的校正效果。这是由于这两种工况中液相流量较低,因此两相CO₂的气体体积分数比高流量的工况L2000Q-UP和L2000Q-DN中更大。气体体积分数越高,则流体的可压缩性越大,导致的CMF直接测量结果与两相真实质量流量的相对误差越大。GRU模型的输出在气体体积分数较大的情况下依然能够跟随真实质量流量的变化,所以在低流量且高含气率的工况下起到了良好的动态校正效果。

综上所述,通过对比GRU、LS-SVM模型测量误差与两相测试段CMF直接测量误差,可以得出在气液两相CO₂动态测量过程中,采用GRU模型进行校正,可以明显提升测量准确性。GRU模型在面对未曾训练过的工况时有较好的准确性,证明了模型的泛化性能。

4 结 论

本文提出了基于GRU循环神经网络的数据驱动模型,利用其适合动态过程预测的特点,用于降低CMF测量动态过程下气液两相CO₂质量流量时的误差。利用实验采集到的数据集对GRU及LS-SVM模型进行训练和优化,对优化后的模型使用典型工况下的测试集进行了测量准确性和模型泛化性能的对比分析。实验结果表明:GRU模型输出结果能够跟随动态过程下气液两相CO₂质量流量变化,在动态波动结束后的稳定阶段相对误差在±5%以内。

参考文献

- [1] SVENSSON R, ODENBERGER M, JOHNSON F, et al. Transportation systems for CO₂—application to carbon capture and storage[J]. *Energy Conversion and Management*, 2004, 45(15-16): 2342-2353.
- [2] NOOTHOUT P, WIERSMA F, HURTADO O, et al. CO₂ pipeline infrastructure—lessons learnt[J]. *Energy Procedia*, 2014, 63: 2481-2492.
- [3] GALE J, DAVISON J. Transmission of CO₂—safety and economic considerations[J]. *Energy*, 2004, 29(9-10): 1319-1328.
- [4] COLLIE G J, NAZERI M, JAHANBAKHSI A, et al. Review of flowmeters for carbon dioxide transport in CCS applications[J]. *Greenhouse Gases Science and Technology*, 2017, 7(1): 10-28.
- [5] 张建国,徐科军,方正余,等. 气液两相流下微弯型科氏质量流量计信号建模[J]. *仪器仪表学报*, 2017, 38(4): 870-877.
- [6] ZHANG J G, XU K J, FANG ZH Y, et al. Signal modeling for micro-bend type Coriolis mass flowmeter under gas-liquid two-phase flow[J]. *Chinese Journal of Scientific Instrument*, 2017, 38(4): 870-877.
- [7] YAN Y, WANG L J, WANG T, et al. Application of soft computing techniques to multiphase flow measurement: A review[J]. *Flow Measurement and Instrumentation*, 2018, 60: 30-43.
- [8] 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*, 2017, 66(5): 852-868.
- [9] 陶波波,侯其立,石岩,等. 科氏质量流量计测量含气液体流量的方法与实现[J]. *仪器仪表学报*, 2014, 35(8): 1796-1802.
- [10] TAO B B, HOU Q L, SHI Y, et al. Method and implementation of measuring liquid flow mixed with gas for Coriolis mass flowmeter[J]. *Chinese Journal of Scientific Instrument*, 2014, 35(8): 1796-1802.
- [11] WANG L J, YAN Y, WANG X, et al. Mass flow measurement of gas-liquid two-phase CO₂ in CCS transportation pipelines using Coriolis flowmeters[J]. *International Journal of Greenhouse Gas Control*, 2018, 68: 269-275.
- [12] ZHANG W B, SHAO D, YAN Y, et al. Experimental investigations into the transient behaviours of CO₂ in a horizontal pipeline during flexible CCS operations[J]. *International Journal of Greenhouse Gas Control*, 2018, 79: 193-199.
- [13] ZHANG Y J, LIU Y J, LIU Z D, et al. Developing a long short-term memory-based signal processing method for Coriolis mass flowmeter[J]. *Measurement*, 2019, 148: 106896.
- [14] 尹诗,侯国莲,胡晓东,等. 风力发电机组发电机前轴承故障预警及辨识[J]. *仪器仪表学报*, 2020, 41(5): 242-251.
- [15] YIN SH, HOU G L, HU X D, et al. Fault warning and identification of front bearing of wind turbine generator[J]. *Chinese Journal of Scientific Instrument*, 2020, 41(5): 242-251.
- [16] 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: 99-123.

- [14] HEMP J, KUTIN J. Theory of errors in Coriolis flowmeter readings due to compressibility of the fluid being metered [J]. Flow Measurement and Instrumentation, 2006, 17(6): 359-369.
- [15] CHUNG J, GULCEHRE C, CHO K H, et al. Empirical evaluation of gated recurrent neural networks on sequence modeling[J]. Eprint Arxiv, 2014, 12: 1-9.
- [16] LIU R P, FUENT M J, HENRY M P, et al. A neural network to correct mass flow errors caused by two-phase flow in a digital Coriolis mass flowmeter [J]. Flow Measurement and Instrumentation, 2001, 12 (1): 53-63.
- [17] BORRA S, CIACCIO A D. Measuring the prediction error. A comparison of cross-validation, bootstrap and covariance penalty methods[J]. Computational Statistics and Data Analysis, 2010, 54: 2976-2989.
- [18] 罗小燕, 陈慧明, 卢小江, 等. 基于网格搜索与交叉验证的 SVM 磨粉负荷预测[J]. 中国测试, 2017, 43(1): 132-135, 144.
LUO X Y, CHEN H M, LU X J, et al. Forecast of SVM mill load based on grid search and cross validation[J]. China Measurement and Test, 2017, 43(1): 132-135, 144.
- [19] SHAO D, YAN Y, ZHANG W B, et al. Dynamic measurement of gas volume fraction in a CO₂ pipeline through capacitive sensing and data driven modelling[J]. International Journal of Greenhouse Gas Control, 2020, 94: 102950.
- [20] 秦建强, 孔祥玉, 孙喜荣. 数据标准化对 Sevcik 分形维数算法的性能影响[J]. 仪器仪表学报, 2016, 37(7): 1485-1491.
QIN J Q, KONG X Y, SUN X R. Influence of different data normalizing methods on the performance of Sevcik fractal dimension algorithm [J]. Chinese Journal of Scientific Instrument, 2016, 37(7): 1485-1491.
- [21] KINGMA D P, BA J. Adam: A method for stochastic optimization [C]. Proceedings of the International Conference on Learning Representations, 2015: 1-13.

作者简介



丁宁, 2018 年于东北大学获得学士学位, 现为华北电力大学硕士研究生, 主要研究方向为多相流检测技术。

E-mail: 15690585861@163.com



Ding Ning received his B. Sc. degree from Northeastern University in 2018. He is currently a master student at North China Electric Power University. His main research interests include multi-phase flow measurement techniques.

闫勇, 1985 年和 1988 年于清华大学分别获得学士学位和硕士学位, 1992 年于英国提赛德大学获得博士学位, 现任英国肯特大学工程学院教授、创新主管。2011 年当选为 IEEE Fellow, 2020 年当选为英国皇家工程院院士。主要研究方向为多相流和燃烧过程检测技术。

E-mail: y. yan@kent.ac.uk

Yan Yong received his B. Sc. degree and M. Sc. degree both from Tsinghua University in 1985 and 1988, and received his Ph. D. degree from University of Teesside in 1992. He is currently a professor and Director of Innovation in the School of Engineering at University of Kent, UK. He was elected as an IEEE Fellow in 2011 and a Fellow of the Royal Academy of Engineering in 2020. His main research interests include multi-phase flow metering and combustion process monitoring.



张文彪(通信作者), 2008 年、2010 年、2014 年于天津大学分别获得学士、硕士、博士学位, 现为华北电力大学控制与计算机工程学院副教授, 主要研究方向为多相流检测技术与智能仪器仪表。

E-mail: wbzhang@ncepu.edu.cn

Zhang Wenbiao (Corresponding author) received his B. Sc. degree, M. Sc. degree and Ph. D. degree all from Tianjin University in 2008, 2010 and 2014, respectively. He is currently an associate professor in the School of Control and Computer Engineering at North China Electric Power University. His main research interests include multi-phase flow measurement techniques and intelligent instrumentation.