

DOI:10.19650/j.cnki.cjsi.J2412902

热膨胀效应修正流量偏差促进时序神经网络精准侦测溢流研究*

梁海波¹, 杨梓为¹, 耿捷², 刘名杨¹

(1. 西南石油大学机电工程学院 成都 610000; 2. 中国石油乍得公司 恩贾梅纳 999052)

摘要:随着油气钻井日益向深部地层以及复杂地层发展,传统的溢流钻井事故监测凸显滞后性和多解性,复杂的地层情况和井下高温高压,导致流量计量产生偏差,这是造成溢流识别精度的主要问题之一,针对计量偏差问题,利用泥浆热膨胀效应,构建了一种流量修正模型,攻克非溢流影响因素,修正计量偏差。其次在修正流量数据的基础上,建立了多元数据融合与时序神经网络相结合的溢流识别预警模型,该模型的溢流漏报次数为0,溢流及时率相较于常规监测手段得到了较大的提升,可提前约5 min发出预警,在钻井作业工程中,具有较大的应用价值和前景。

关键词:热膨胀效应;溢流识别;修正流量;时序神经网络

中图分类号: TH71 **文献标识码:** A **国家标准学科分类代码:** 460.40

Flow deviation correction through the thermal expansion effect enhances the precise detection of overflow in time-series neural networks

Liang Haibo¹, Yang Ziwei¹, Geng Jie², Liu Mingyang¹

(1. College of Mechanical and Electrical Engineering, Southwest Petroleum University, Chengdu 610000, China;

2. China Petroleum Chad Company, N'Djamena 999052, Chad)

Abstract: As oil and gas drilling advances into deeper and more complex formations, traditional methods for monitoring overflow accidents show delays and offer multiple potential solutions. The challenging formation conditions, along with high temperature and pressure underground, result in flow measurement deviations, which significantly affect the accuracy of overflow detection. To address this issue, a flow correction model was developed, accounting for the thermal expansion of mud to correct these deviations by mitigating non-overflow influencing factors. Furthermore, based on the corrected flow data, an overflow identification and warning model was established using multivariate data fusion and a temporal neural network. This model eliminates missed overflow reports and significantly improves the timely detection rate compared to conventional methods. It can provide warnings up to 5 minutes in advance, offering substantial application value and potential in drilling operations.

Keywords: thermal expansion effect; overflow identification; corrected flow; temporal neural network

0 引言

石油作为当今工业系统的命脉,油气资源的开发不可忽视^[1],钻井作为石油勘探的重要手段,在钻进过程中,复杂的地质情况使钻进风险层出不穷,尤其是因为井底压力过大所引起的溢流事故^[2]。溢流作为井喷的前兆^[3-4],如何完成早期溢流风险识别和预测,并为现场提

供指挥级决策,进而安全有效的对溢流风险进行早期控制,降低事故发生的频率以及减少事故带来的风险和损失^[5],为钻进的安全和效率提供一份可靠的保障,这对石油勘探,钻井安全都有十分重要的意义^[6]。

传统的溢流风险监测通常不能及时发现,使溢流等风险存在滞后性和多解性^[7-8],为解决这一问题,国内外钻井专家在早期溢流监测方面做了大量的技术研究,现已取得了一定的成果^[9-15]。目前,国外主要依赖于井下

设备的实时监测来达到早期溢流监测的目的,其参数精准,效果直观,如 APS 公司推出的井下仪器配套的 Sureshot 地面系统和 SSCC 软件可以显示并导出井下随钻测量工具的实时数据,结合钻进工况通过各参数的变化趋势判断井下是否出现溢流现象。

随着人工智能发展,国内也逐步尝试将机器学习和多源数据融合技术与溢流预警技术相结合^[16],2012 年,崔猛等^[17]对 BP 神经网络算法进行修正,构建了基于人工智能 BP 神经网络算法的钻井事故诊断模型,相比传统神经网络模型,在适应度和误差等方面更为可靠,提高了事故诊断精度。2013 年,张正辉等^[18]通过神经网络的反复训练调整小波系数以达到对非线性函数的最佳逼近,选取井涌和井漏等事故样本,经过最小二乘法对参数训练后,取得良好的实验效果。2022 年,张冉等^[19]采用模糊 C 均值聚类的方法,通过并行特征分布式重组,差分进化和遍历寻找,提高海洋石油设备预警准确率,具有一定应用价值。

上述方法在一定程度上提升了溢流判识性,但是井下随钻仪器成本高且仪器的传输能力会因井下的高温高压环境而受到影响,且国内也缺乏成熟的井下随钻设备。而复杂的地层环境导致目前的地面传感器计量存在偏差,致使基于机器学习与多元数据结合的方法存在数据质量的困扰,预测的准确性十分有限。无法大规模现场应用。

综上所述,本文针对现有对溢流风险评价方法存在的问题提出了一种依托于地面的监测方法,通过排除非溢流影响因素提升计量精度,从而提高数据质量,并基于机器学习和多元数据结合的方式建立溢流智能监测模型,提高溢流识别模型精度和响应速度。

1 早期溢流特征

1.1 溢流发生机理及监测方式

溢流是指当井内流体层压力大于钻井液柱力时,流体层中流体会侵入到井筒^[20],地层压力 p_b 指地下岩石孔隙内流体的压力,也叫地层流体压力或地层孔隙压力,井底压力 p_d 等于钻井液静液柱压力和环空循环压降的总和,如图 1 所示,正常钻井作业情况下,地层压力应与井底压力保持平衡^[21],当 $p_b > p_d$ 时,即地层压力大于井底压力,地层流体就会大量侵入井筒导致钻井液污染引起溢流,引发井下复杂情况。

在地面录井相关参数中,出入口流量作为溢流特征的重要参数^[22],而由于复杂的地层原因导致该参数的计量存在偏差,如何对流量进行修正是提高溢流识别模型准确率的关键问题。相较于其他流量计,科里奥利力质量计可直接测量质量流量,测量精度较高,并且质量流量计测量范围较广。因此本文依托于质量流量计的计量数




图 1 压力平衡示意图

Fig. 1 Schematic diagram of pressure balance

据,构建流量修正模型,用以排除非溢流影响因素,为后续溢流识别模型提供数据支持和保障。

1.2 流量修正模型

由于井下高温高压的影响,钻井液密度会因此受到影响,流体体积会随温度的升高而发生膨胀,随压力的增大而发生压缩。

在井底循环的过程中,常规钻井的井底压强大约在 0.1~50 MPa,温度通常在 200℃ 以内,将温度和压强控制在此区间内,研究其密度的变化趋势,以地面流体密度为 1.3 的水基钻井液为例,其流体密度受高温高压影响的变化如图 2 所示。

由图 2 可以看出,钻井液随温度的升高密度会逐渐下降,且下降趋势趋近于指数函数,随着压力增加,密度成线性增加,但影响程度不如温度,因此为保证质量流量计监测精度,需将因高温高压导致钻井液膨胀而影响出口流量的因素排除。

设流体体积受到压强和温度影响而变化的函数为 $V = V(P, T)$,设温度的变化量为 ΔT ,压力的变化量为 ΔP ,流量变化量为 ΔV ,则有:

$$V + \frac{\partial V}{\partial T} \Delta T + \frac{\partial V}{\partial P} \Delta P = V(1 + \alpha \Delta T - \beta \Delta P) \quad (1)$$

$$\alpha = \frac{1}{V} \frac{\partial V}{\partial T} \quad (2)$$

$$\beta = -\frac{1}{V} \frac{\partial V}{\partial P} \quad (3)$$

式中: V' 为变化后的流量体积; α 为等压热膨胀系数; β 为等温压缩系数。分析可知,在 0.1~50 MPa 的压强下,流体的密度变化很小,由此可以判断,流体的体积受此区间的压强影响几乎可以忽略不计,因此可以将式(1)简写为:

$$V' = V + \frac{\partial V}{\partial T} \Delta T = V(1 + \alpha \Delta T) \quad (4)$$

钻井液循环温度的变化与井下温度场和热传导息息相关,设井筒内径为 R_1 ,外径为 R_2 ,热传导面积为与井筒体积相关的一个常数,为 $2\pi r l$, l 为井段常数, Δt 为钻井液温度与井壁温度之差,结合热传导傅里叶定律,热传




图2 高温高压钻井液密度变化曲线

Fig. 2 Density change curve of high temperature and high pressure drilling fluid

导速率 ϕ 的定义为:

$$\phi = \lambda (2\pi r l) \frac{\Delta t}{r_2 - r_1} \tag{5}$$

$$r = \frac{r_2 - r_1}{\ln(r_2/r_1)} \tag{6}$$

式中: λ 为物质的导热系数; r 为井筒对数平均半径。将式(6)代入式(5)可得:

$$\phi = \frac{\lambda (2\pi r l)}{\ln(r_2/r_1)} \Delta t \tag{7}$$

在单位时间内泥浆吸收的热量为地层传递的热量,通过热量计算公式可得:

$$Q = \Phi = cm(t_1 - t_0) = cm\Delta T \tag{8}$$

$$\Delta T = \frac{t_2 - t_0}{1 + \frac{cm \ln(r_2/r_1)}{2\lambda \pi l}} \tag{9}$$

式中: ΔT 为泥浆温度变化量; c 为泥浆比热容; m 为流量质量,通过质量流量计测得; t_2 为地层温度; t_0 为地面温度,可由质量流量计中温度传感器测得。地层温度可以通过地面温度以及地层温度梯度求出:

$$t_2 = t_0 + G\Delta h \tag{10}$$

式中: Δh 为井深变化; G 为地层温度梯度,该数据可以从现在地质资料中查得,以四川盆地为例,该地的地质温度梯度约为 2.8~3.0 (°C/100 m)。由于受井下高温高压影响导致流体膨胀所带来得出口流量变化的大小为:

$$\Delta V = \alpha V \Delta T = \alpha V \frac{t_2 - t_0}{1 + \frac{cm \ln(r_2/r_1)}{2\lambda \pi l}} \tag{11}$$

综上所述,该模型可结合井热膨胀数据,地层温度梯度,质量流量计等数据,减弱甚至排除由于井下高温高压所引起的热膨胀效应对出口流量的影响。

2 理论模型

钻井过程中由于复杂的地层情况会导致对钻井数据的识别不够精确,溢流识别的核心在于对异常数据的提取,而这些数据与是否发生溢流并非是一个线性的关系,因此出口流量进行修正模型的基础上,采用机器学习构建溢流识别模型^[23],以修正出口流量和钻井数据以时间序列排列进行输入,溢流判别结果为输出,实现早期溢流识别预警。

2.1 注意力-门控循环单元(Attention-GRU)模型

门控循环单元(gated recurrent unit, GRU)是一种循环神经网络(RNN)^[24-25],在解决时间序列的问题上有着巨大优势。将修正质量流量计出口流量数据和录井数据作为时间序列,构建循环神经网络模型是一个最优选择。而 GRU 网络便是在长短期记忆(LSTM)的基础上改进而来,将系统中的遗忘门和输入门改为更新门和重置门来提高运算速度,使其输出结果更容易收敛^[26-28]。GRU 的系统机构如图 3 所示。




图 3 GRU 结构

Fig. 3 GRU structure diagram

GRU 结构包含重置门控制矩阵和更新门控制矩阵。更新门控制上一个时刻的输出隐层对当前隐层的影响程度,值越大,上一个时刻的状态信息保留越多;而重置门控制上一个时刻的隐层信息被忽略的程度,值越小忽略越多^[29]。GRU 单元的更新公式如下:

$$z_{<t>} = \sigma(W_z \cdot [h^{<t-1>}, x^{<t>}]) \quad (12)$$

$$r_{<t>} = \sigma(W_r \cdot [h^{<t-1>}, x^{<t>}]) \quad (13)$$

$$\tilde{h}^{<t>} = \tanh(W \cdot [r_t \times h^{<t-1>}, x^{<t>}]) \quad (14)$$

$$h^{<t>} = (1 - z_t) \times h^{<t-1>} + z_t \tilde{h}^{<t>} \quad (15)$$

$$y^{<t>} = W_y \cdot h^{<t>} + b_y \quad (16)$$

式中: \$\sigma\$ 表示 sigmoid 激活函数,目的是将函数映射到 \$[0, 1]\$ 之间; \$\mathbf{h}^{<t>}\$ 代表当前时刻的隐藏层矩阵; \$\mathbf{W}_z\$ 表示更新门参数矩阵; \$\mathbf{W}_r\$ 表示重置门矩阵; \$\mathbf{x}^{<t>}\$ 表示当前时刻的输入; \$\tilde{\mathbf{h}}^{<t>}\$ 表示当前记忆内容; \$\times\$ 代表对应原始相乘; \$\cdot\$ 表示矩阵相乘; \$\mathbf{y}^{<t>}\$ 表示当前时刻输出; \$\mathbf{W}_y\$ 代表输出权重; \$\mathbf{b}_y\$ 表示输出偏置; \$[\cdot]\$ 表示矩阵的串联。

Attention 机制是跟据人类的注意力机制所提出的一种信息处理方式^[30],在编码解码网络中,注意力机制直接作用于编码器的输出结果(非隐藏层矩阵),并将处理后的结果传递到解码器的输入端,达到获取有用信息,抑制无用信息的目的^[31]。

注意力机制是一个加权过程,其核心在于计算注意力权重向量。注意力权重向量计算方式如图 4 所示。




图 4 注意力机制权重向量

Fig. 4 Attention mechanism weight vector graph

为了清晰地描述注意力向量的计算流程,这里使用 \$t'\$ 表示编码器的第 \$t\$ 时刻; \$t\$ 表示解码器的第 \$t\$ 时刻; \$s^{t-1}\$ 表示解码器 \$t-1\$ 时刻的隐藏层矩阵; \$e^{<t,t'>}\$ 表示编码器第 \$t\$ 时刻输出对解码器第 \$t\$ 时刻输出的贡献,也就是权重

值^[32]。权重值的范围为 \$[0, 1]\$, 因此,需要对权重值进行归一化,可以用式(18)所示。

$$\alpha^{t,t'} = \frac{\exp(e^{t,t'})}{\sum_{t'=1}^N \exp(e^{t,t'})} \quad (17)$$

$$c^t = \sum_{t'} \alpha^{t,t'} \tilde{y}^{<t>} \quad (18)$$

式中: \$e^{<t,t'>}\$ 表示编码器第 \$t\$ 时刻输出对解码器第 \$t\$ 时刻输出的贡献度; 为解码网络在 \$t\$ 时刻的输入。按式(18)计算整个网络的注意力机制权重向量,完成 Attention-GRU 编码解码网络模型的搭建。

2.2 PCA 数据预处理

溢流识别作为一种非线性问题,现场相关数据及其驳杂,但并非所有数据都有明显的溢流特征因此本文采用主成分分析法(principal component analysis, PCA)来对特征数据进行选取^[33],设原始数据集整体为 \$X\$, \$x\$ 中包含有 \$N\$ 个种类的样本 \$\{x_1, x_2, x_3, x_4, \dots, x_n\}\$, 设每个样本的维度设为 \$m\$, 则可以构建一个维度为 \$m \times n\$ 的矩阵表达式,矩阵相关系数为:

$$r_{mn} = \frac{\sum_{k=1}^n (x_{km} - \bar{x}_i)(x_{kn} - \bar{x}_n)}{\sqrt{\sum_{k=1}^n (x_{km} - \bar{x}_i)^2 \sum_{k=1}^n (x_{kn} - \bar{x}_n)^2}} \quad (19)$$

根据现场经验,通常对溢流通常对溢流判断所选用得数据为出口流量 \$\lambda_1\$, 入口流量 \$\lambda_2\$, 立管压力 \$\lambda_3\$, 泥浆池体积 \$\lambda_4\$, 钻压 \$\lambda_5\$, 气测值 \$\lambda_6\$, 输出结果如表 1 所示 \$\lambda_1 \sim \lambda_4\$ 数据贡献率可达 89%, 足以作为模型输入。

表 1 PCA 结果数据

Table 1 PCA results data

	\$\lambda_1\$	\$\lambda_2\$	\$\lambda_3\$	\$\lambda_4\$	\$\lambda_5\$	\$\lambda_6\$
特征值	2.58	1.08	0.98	0.66	0.47	0.16
贡献率	0.43	0.18	0.16	0.11	0.078	0.026

2.3 模型搭建

本文所构建的 Attention-GRU 早期溢流监测模型由输入层、输出层、隐藏层和网络训练 4 部分组成,模型将地面多元融合数据中作为模型的输入,并通过流量修正模型排除非溢流影响因素,提升数据质量,利用重置门和激活函数将通过输入层进入网络的参数进行加权变换,注意力机制可以突出各类数据对溢流结果的影响,避免神经网络对所有数据同等对待,从而得到更准确的预测值^[34]。输出结果为当前溢流风险的概率值,模型中通过步长来选择一段时间的数据进行处理,并在模型中添加一个 sigmoid 激活函数将模型中的输出值映射在 \$[0, 1]\$。模型如图 5 所示。

此外,合适的训练算法可以将模型的输出趋近于理想结果通过对权重的不断调节,最小化损失函数曲线,不同的优化算法对模型最终的训练效果不同的影响,Adam




图 5 Attention-GRU 算法模型框架图

Fig. 5 Framework diagram of the Attention-GRU algorithm

优化算法化算法结合 Momentum 和 RMSprop 两种算法^[35-36],其充分利用了一阶动量和二阶动量,为不同的参数设计独立的自适应学习率,相较于 SGD 算法,Adam 优化算法在优化能力和计算速度等性能上都有较大的提升,其优化过程如下:

$$S_{dw} = \beta S_{dw} + (1 - \beta) (dw)^2 \tag{20}$$

$$S_{db} = \beta S_{db} + (1 - \beta) (db)^2 \tag{21}$$

$$W = W - \frac{\alpha v_{dw}^{corrected}}{\sqrt{S_{dw}^{corrected}} + \epsilon} \tag{22}$$

式中: W 表示溢流预警模型的权重矩阵; v 表示指数加权计算后的梯度; β 为一阶矩估计的指数衰减率; s 是梯度平方的平滑处理结果; α 是学习率; ϵ 是避免分母出现 0。以上算法在 MATLAB 框架中得到了很好的封装,可以直接调用进行溢流预警模型的训练。训练结果采用 RMSE 作为评价指标对模型的精度经行验证 Adam 优化算法的伪代码如表 2 所示,算法流程如图 6 所示。

表 2 Adam 训练伪代码
Table 2 Adam trains pseudocode

输入:
溢流数据集,最大迭代次数 Eopch
1) 初始化溢流预警模型权重 ω_0 ,初始化注意力权重 ω_1 ,计算每轮更新批次 N_0 ,批次溢流样本集 $D(i = 1, 2, 3, \dots, N_0)$
2) for each $j = 1, 2, 3, \dots, epoch$:
3) for each $i = 1, 2, 3, \dots, N_0$:
4) 对应溢流样本 D
5) for each $\{X Y\}$ in D
6) 记录迭代次数
7) 获取该批次输入和输出
8) X 作为溢流预警模型输入
9) 得到溢流预警模型实际输出 y
10) 计算模型损失 $Loss = y - Y $
11) 计算该批次损失 Loss
12) 根据 Loss 获取更新梯度




图 6 模型训练流程

Fig. 6 Model training flowchart

3 实验结果与分析

3.1 模型输入

通过主成分分析法所测的结果来看,将非溢流影响出口流量的因素排除后所得到的修正流量数据,结合综合录井系统所监测到的泥浆池体积,立管压力以及入口流量 3 个参数作为模型输入,当前的溢流风险概率作为模型输出,二者之间存在映射关系,根据特征的变化来对当前是否存在溢流风险做出一个判断。

从数据集中提取某段真实样本数据,经过现场工作人员结合现场实际情况和自身经验做出判断,该数据集可以判断发生了溢流,因此该样本对应的输出值为 1,样本进入模型后,最终得出预测的溢流曲线。通常将溢流概率大于 0.6 时模型发出警报。

在进行特征提取时,模型中设置的步长过长可能会导致对特征数据的敏感度降低,从而引发溢流发生而预测模型无法优先监测预警的可能,而如果步长设置过小,算法模型对这段时间的特征数据敏感性加强,但可能会导致模型学习不到特征,对是否发生溢流进行误判,因此最优时间间隔的选择对模型的输出结果的准确率异常关键。输入示例如表 3 所示。

表 3 输入数据示例

Table 3 Example of input data

输入参数	出口流量/ (L·s ⁻¹)	入口流量/ (L·s ⁻¹)	泥浆池体积/ m ³	立管压力/ MPa
1	52.63	52.24	106.01	18.35
2	53.66	52.23	106.01	18.34
3	53.67	52.23	106.02	18.35
⋮	⋮	⋮	⋮	⋮
30	66.35	52.35	110.12	19.36
输出结果	1.0			

3.2 最优步长选取

改变网络参数来调整步长,达到最优时间间隔选取的目的,通过大量对神经网络预测溢流的文献的研究,时间间隔取值为 30 左右达到最优解,但由于不同的算法和优化方法会导致特征提取的方式和敏感度都不同,从而最优时间间隔也会因此发生改变,本文采取 10、20、30、40,这 4 个步长比较溢流模型的准确度,以误判报警、漏判预警以及是否能早发现预警作为评价标准。4 种步长对比结果如图 7 所示。




图 7 步长 10、20、30 和 40 对比结果

Fig. 7 Comparison of step sizes 10, 20, 30 and 40

当时间间隔为 10(图 7(a))时,步长较短,此时对该段数据进行特征提取时敏感性较强,在 10:27~10:36 时间段出现了 5 次溢流误警的情况,且几乎没有早于溢流真实发生的时间做出预警,说明对于该数据集,该步长选择并非最优解,需要在网络模型中对步长做出修改,改变特征提取灵敏度,加强模型对整个序列特征的学习,减少误报频率。

当步长选择为 20(图 7(b)),时间序列增强,算法模型对一段时间的特征敏感性降低,误判情况减少,预警时间提前。但仍需加强整体特征学习。数据选取间隔为 30(图 7(c)),在该步长下的溢流模型预测曲线与实际溢流情况基本符合,在当前数据段内仅出现一次对溢流误判的情况,预警模型提早发出预警,说明模型有一定预警能力实现早期溢流预警的功能。图 7(d)敏感度明显降低,但预测模型发出警报的时间几乎没有提前,且在溢流

发生后尚未结束时,溢流概率出现了漏报的情况,预警精确度要低于时间间隔选取为 30 的溢流模型。而在现场实际情况中很多微小溢流的数据序列长度并不满足过大的时间间隔,因此在该数据集中,基于 Attention-GRU 算法所搭建的早期溢流识别预警模型的最优时间间隔为 30。

3.3 模型对比及误差评价

步长对比结果如图 8 所示,可以看出在同样的特征提取参数之下,基于 Attention-GRU 搭建的溢流预警模型取得了更好的测量效果。Attention-GRU 的预测曲线与实际情况基本符合,几乎没有误判和漏报的情况,且能提前发出预警,同样具有时序特征处理的算法 GRU 的预测结果也较为接近真实数据但有 3 次误报及两次漏报,LSTM 模型虽然误报次数多于 GRU,但漏报次数少于 GRU,RNN 的预测值曲线有明显偏差,错误预警的情况较多,预警精度较差。




图 8 步长对比结果

Fig. 8 Comparison of models

从漏报次数和误报次数作为评价指标来看 Attention-GRU 预警模型的效果无疑是 4 种模型中最优选择,为使得预警精度更为直观,从数据化的角度来展示模型的预测精度,采用均方根误差(RMSE)评价作为预测指标,对 4 种模型的预测精度做出比较,误差值越小的模型其对于溢流预警的预测精度越高,4 种模型的预测精度如表 4 所示。结合现场实际情况,漏报的风险远远高于误报带来的风险,对于溢流预警模型来说,精确预测溢流风险数据的重要程度要高于预测非溢流风险数据,因此本文为进一步评价溢流预警模型的效果,选取数据集中溢流风险为 1 的数据,提取 4 种模型的预测值,采用相对误差评价指标,来判定 4 种模型对于溢流数据的预测精度。

表 4 模型误差精度表

Table 4 Model error accuracy

模型	Attention-GRU	GRU	LSTM	RNN
RMSE	0.195	0.25	0.296	0.275
相对误差	0.12	0.31	0.35	0.43

4 种模型相对误差对比如图 9 所示,对于数据集中溢流数据的预测情况,Attention-GRU 的相对误差值整体趋势最小,所有数据的相对误差都在 0.35 以下,整体样本中国的相对误差为 0.12 远低于 GRU 的 0.31,LSTM 的 0.35 以及 RNN 的 0.43,因此从该角度也可以说明 Attention-GRU 对于溢流的预测更为精准。




图 9 模型相对误差对比

Fig. 9 Comparison of the relative error of the model

3.4 现场实验

地面常规录井采用泥浆池液面判定溢流,但由于钻井液循环时间过长,该方法存在严重的滞后性,因此本文实验对比采用设定溢流敏感值方法,该方法针对累计出入口流量差值进行溢流判定,具体模式为设定流量敏感值和时间敏感值,当出入口流量差值超过溢流敏感值时发出流量预警,累计出入口流量差值超过时间敏感值后发出溢流预警,方法如图 10 所示。现场测试数据来源及装置如图 11 所示,最后通过 Vs 及 MATLAB 等平台工具对模型进行封装,形成早期溢流监测系统,对两个模型进行对比分析等具体方法和对比结果如图 12 所示。




图 10 溢流敏感值监测方法

Fig. 10 Monitoring method of overflow sensitive value




图 11 现场实验

Fig. 11 Field experiment


由如图 11 可以看到,质量流量计数据通过无线通信模块完成数据采集,并基于 Modbus 通信协议上传至上位机,综合录井数据则基于 TCP/IP 协议完成数据传输。

图 12 中,左侧为溢流识别模型,右侧为敏感值监测模型,其中溢流识别模型分为三级预警,区域①代表一级预警,区域②代表二级预警,区域③代表三级预警,映射溢流

概率分别为 0.6、0.8、1.0;右侧敏感值监测模型中区域①代表流量异常预警,区域②代表溢流预警。从图 12(a)的 3 个对比区域可以看出,区域(1)内溢流监测系统发出流量预警时,出入口流量明显异常,算法模型发出一级预警,两个模型预警情况较为吻合且算法模型溢流敏感度更高。区域(2)内,13:30 后溢流系统频繁发出流量异常信号后



(a) 模型对比试验I组
(a) Model control trial group 1



(b) 模型对比试验2组
(b) Model control trial group 2

图 12 模型对比实验

Fig. 12 Model comparison experiment

发出溢流预警,算法模型与溢流监测系统重合度较高,且提前约 5 min 发出预警。区域(3)内溢流监测系统发出了几次流量预警,但由于出入口流量明显异常,算法模型发出一级预警,敏感度更好,杜绝漏报情况。

从图 12(b)可以看出,区域(1)内,11:38 后溢流监测系统频繁发出流量异常预警后,到达流量预警状态,算法模型重合度很好,且依然提前发出溢流预警。区域(2)内溢流系统发出几次流量预警,但由于出入口流量明显异常,算法模型发出一级预警作为提醒。区域(3)内溢流系统频繁发出流量异常预警,但流量异常出入值较小没有发出溢流预警,算法模型发出预警后等级逐渐升高,表明模型对溢流敏感度更高,对小流量溢流有一定侦测能力。

综上所述,溢流识别模型的溢流敏感度更高,右侧模型还处于流量异常预警时便已经发出溢流预警,时间约提前了约 5 min,对于微小流量的增加也有一定的预警作用,溢流发现的及时性和准确率得到了显著提升,且没有漏报发生,对于现场的工作人员足以提供辅助级决策。

4 结 论

本文针对现有的溢流技术的不足,提出了对现有计量数据修正的方法,针对质量流量计数据建立了流量修正模型,并基于流量修正流量数据结合综合录井数据,确立了以 Attention-GRU 为基础建立溢流预警算法模型,搭建了算法框架以及优化流程,对模型的输入数据进行了预处理后,对最优时间间隔的大小进行了研究,以误报漏报次数作为评价确立了模型数据的最优时间间隔,随后为验证模型的优越性,在相同特征提取参数的前提下,进行模型对比分析。并通过 RMSE 以及对溢流数据段的相对误差作为评价指标,验证了 Attention-GRU 算法性能表现要优于部分经典算法,实验结果表明 ATT-GRU 模型仅有 2 次虚报,漏报次数为 0,溢流发现及时率可达 100% ,且相较于其他溢流监测方式,可提约 5 min 发出预警,传统监测的滞后性得到了较为可观的改善,具有一定的使用价值和现场应用前景。

参考文献

- [1] 石天峰. 精细控压钻井地面控制系统研究[D]. 成都:西南石油大学, 2017.
- SHI T F. Research on ground control system of finely controlled pressure drilling [D]. Chengdu: Southwest Petroleum University, 2017.
- [2] 孙宝江,王春生,辛桂振,等. 复杂压力体系地层钻探溢流压井技术研究[J]. 钻采工艺, 2024, 47(4): 42-50.
- SUN B J, WANG CH SH, XIN G ZH. Research on drilling overflow kill technology in complex pressure system formations[J]. Drilling Process, 2024, 47(4): 42-50.
- [3] 葛亮,黄凯强,田贵云,等. 基于电磁检测机理的井下环空流量测量方法研究[J]. 仪器仪表学报, 2019, 40(12): 161-174.
- GE L, HUANG K Q, TIAN G Y, et al. Research on downhole annular flow measurement method based on electromagnetic detection mechanism [J]. Chinese Journal of Scientific Instrument, 2019, 40(12): 161-174.
- [4] JU G SH, YAN T, SUN X F, et al. Evolution of gas kick and overflow in wellbore and formation pressure inversion method under the condition of failure in well shut-in during a blowout[J]. Petroleum Science, 2022, 19(2): 678-687.
- [5] 付加胜,刘伟,韩霄松,等. 基于 CNN-LSTM 融合网络的溢流早期预测深度学习[J]. 石油机械, 2021, 49(6): 16-22.
- FU J SH, LIU W, HAN X S, et al. A deep learning method for early prediction of overflow based on CNN-LSTM fusion network[J]. Petroleum Machinery, 2021, 49(6): 16-22.
- [6] 张飞宇. 钻井低效实时监测系统开发与应用[D]. 成都:西南石油大学, 2019.
- ZHANG F Y. Development and application of drilling low-efficiency real-time monitoring system[D]. Chengdu: Southwest Petroleum University, 2019.
- [7] 邹佳玲. 钻井漏失风险预测与控制系统设计[D]. 成都:西南石油大学, 2018.
- ZHOU J L. Drilling wellbore leakage risk prediction and control system design [D]. Chengdu: Southwest Petroleum University, 2018.
- [8] BENNY B, HIDAYAT A M, KARNUGROHO A, et al. Combining pressurised mud cap drilling (PMCD) and early kick detection (EKD) techniques for fractured formations overlying a high pressure reservoir in offshore kalimantan [C]. SPE Asia Pacific Oil and Gas Conference and Exhibition, 2013: SPE-165893-MS.
- [9] CHOE J, SCHUBERT J J, JUVKAM-WORLD H C. Analyses and procedures for kick detection in subsea mudlift drilling[J]. SPE Drilling & Completion, 2007, 22(4): 296-303.
- [10] WANG X R, HASAN A R, ZHANG B, et al. Study on the hydrate formation region in a wellbore during subsea mudlift drilling[J]. Journal of the Society for Computer, 2021, 97(2): 69-82.
- [11] SUN W T, WEI N, ZHAO J ZH, et al. Wellbore temperature and pressure field in deep-water drilling and the applications in prediction of hydrate formation region[J]. Frontiers in Energy Research, 2021, 9: 696392.
- [12] ZHOU Q, ZHAO H, ZHAN H Q, et al. The application of ultrasonic based on Doppler effect used in early kick detection for deep water drilling [C]. International Conference on Communications, Circuits and Systems (ICCCAS), 2013: 488-491.
- [13] KAMYAB M, SHADIZDEH S R, JAZAYERI-RED H, et al. Early kick detection using real time data analysis with dynamic neural network: A case study in iranian oil fields[C]. Nigeria Annual International Conference and Exhibition, 2010: 1-10.
- [14] YIN B T, LIU G, LI X F. Multiphase transient flow model in wellbore annuli during gas kick in deepwater drilling based on oil-based mud[J]. Applied Mathematical Modelling, 2017, 51(1): 159-198.
- [15] 张禾,池紫欣. 基于 BSMOTE-SVM 算法的溢流风险评价[J]. 控制工程, 2023, 30(12): 2173-2178.
- ZHANG H, CHI Z X. Evaluation of over-flow risk of BSMOTE-SVM algorithm [J]. Control Engineering, 2023, 30(12): 2173-2178.
- [16] 韦龙贵,张伟国,罗黎敏,等. 数字化井控技术研究现状及发展趋势[J]. 钻采工艺, 2024, 47(4): 86-93.
- WEI L G, ZHANG W G, LUO L M, et al. Research on digital well control technology: Current status and future

- trends[J]. *Drilling and Production Technology*, 2024, 47(4): 86-93.
- [17] 崔猛,汪海阁,李洪,等. 基于 BP 神经网络的钻井复杂情况和事故诊断[J]. *信息技术*, 2012, 36(10): 62-65.
- CUI M, WANG H G, LI H, et al. A BP neural network-based diagnosis of drilling complex situations and accidents[J]. *Information Technology*, 2012, 36(10): 62-65.
- [18] 张正辉. 小波神经网络在钻井事故诊断中的应用[J]. *油气田地面工程*, 2013, 32(11): 6-7.
- ZHANG ZH H. Application of wavelet neural network in drilling accident diagnosis [J]. *Oil and Gas Ground Engineering*, 2013, 32(11): 6-7.
- [19] 张冉,侯林,陈峰,等. 基于聚类算法的海洋石油固井设备红外监测大数据预警模型[J]. *激光杂志*, 2022, 43(11): 190-193.
- ZHANG R, HOU L, CHEN F, et al. A big data early warning model for ocean oil cementing equipment based on clustering algorithm and infrared monitoring[J]. *Laser Journal*, 2022, 43(11): 190-193.
- [20] 单兴鹏,王树山,佟国志. 自升式钻井平台泥浆系统的设计与研究[J]. *船舶标准化与质量*, 2019(3): 37-42, 61.
- SHAN X P, WANG SH SH, TONG G ZH. Design and research of mud system for self-elevating drilling platforms [J]. *Ship Standardization and Quality*, 2019(3): 37-42, 61.
- [21] 徐宝昌,孟卓然,陈贻祺,等. 控压钻井井下气侵工况的自适应参数及状态估计[J]. *控制与决策*, 2024, 39(2): 551-558.
- XU B CH, MENG ZH R, CHENG Y Q, et al. Adaptive parameters and state estimation of gas invasion in underground drilling with controlled pressure[J]. *Control and Decision*, 2024, 39(2): 551-558.
- [22] 周英操,郭庆丰,蔡骁,等. 精细控压钻井技术及装备研究进展[J]. *钻采工艺*, 2024, 47(4): 94-104.
- ZHOU Y C, GUO Q F, CAI X, et al. Research progress on fine pressure control drilling technology and equipment[J]. *Drilling and Production Technology*, 2024, 47(4): 94-104.
- [23] 徐楷,苏堪华,李猛,等. 机器学习在油气钻井工程中的应用[J]. *非常规油气*, 2023, 10(5): 8-17.
- XU K, SU K H, LI M, et al. Application of machine learning in oil and gas drilling engineering [J]. *Unconventional Oil and Gas*, 2023, 10(5): 8-17.
- [24] VERMAAK J, BOTH A E C, et al. Recurrent neural networks for short-term load forecasting [J]. *IEEE Transactions on Power Systems*, 1998, 13(1), 126-132.
- [25] MA P, LI G F, ZHANG H L, et al. Prediction of remaining useful life of rolling bearings based on multiscale efficient channel attention CNN and bidirectional GRU[J]. *IEEE Transactions on Instrumentation and Measurement*, 2024, 73: 1-13.
- [26] 凌华靖. 基于竞争深度强化学习的建筑能耗预测研究[D]. 苏州科技大学, 2021.
- LING H J. Research on building energy consumption prediction based on competitive deep reinforcement learning [D]. *Suzhou University of Science and Technology*, 2021.
- [27] DONAHUE J, HENDRICKS L A, ROHRBACH M, et al. Long-term recurrent convolutional networks for visual recognition and description [J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2017, 39(4): 677-691.
- [28] LI D D, LI W L, ZHAO Y M, et al. The analysis of deep learning recurrent neural network in English grading under the Internet of Things [J]. *IEEE Access*, 2024, 12: 44640-44647.
- [29] 赵杰,解则晓,刘世萱. 基于能量熵 VMD 最优分解与 GRU 循环神经网络的潮汐预测精度提升方法研究[J]. *仪器仪表学报*, 2023, 44(12): 79-87.
- ZHAO J, XIE Z X, LIU SH X. Tide prediction accuracy improvement method research based on VMD optimal decomposition of energy entropy and GRU recurrent neural network [J]. *Chinese Journal of Scientific Instrument*, 2023, 44(12): 79-87.
- [30] 鄢明辉,周喜,王轶. 基于残差注意力的新槽值抽取研究[J]. *计算机应用与软件*, 2024, 41(6): 208-214.
- YAN M H, ZHOU X, WANG Y. Research on new slot value extraction based on residual attention [J]. *Computer Applications and Software*, 2024, 41(6): 208-214.
- [31] ZHANG B, XIONG D Y, XIE J. Neural machine

translation with GRU-gated attention model [J]. IEEE Transactions on Neural Networks and Learning Systems, 2020, 31(11):4688-4698.

[32] 兰汐. 基于深度学习的答案选择算法研究 [D]. 北京:北京邮电大学, 2019.

LAN X. Research on answer selection algorithm based on deep learning [D]. Beijing: Beijing University of Posts and Telecommunications, 2019.

[33] 王佳佳,熊飞龙. 基于改进的 MFCC 与 CNN 心音信号识别方法的研究 [J/OL]. 计算机测量与控制, 1-10 [2024-10-23].

WANG J J, XIONG F L. Research on heart sound recognition based on improved MFCC and CNN methods [J]. Computer Measurement and Control, 1-10 [2024-10-23].

[34] 周超,丛鑫,訾玲玲,等. 基于 DNN 与注意力机制的推荐算法模型 [J]. 计算机与现代化, 2024 (6): 1-8.

ZHOU CH, CONG X, ZI L L, et al. A recommendation algorithm model based on DNN and attention mechanism [J]. Computer and Modernization, 2024 (6): 1-8.

[35] 高斌斌. 深度学习下标记受限的视觉识别研究 [D]. 南京:南京大学, 2018.

GAO B B. Research on visual recognition with limited labels under deep learning [D]. Nanjing: Nanjing University, 2018.

[36] BHAKTA S, NANDI U, SI T, et al. DiffMoment: An adaptive optimization technique for convolutional neural network [J]. Applied Intelligence, 2023, 53 (13): 16844-16858.

作者简介



梁海波 (通信作者), 2008 年于西南石油大学获得博士学位, 现为西南石油大学教授, 博士生导师, 主要研究方向为油气测控技术、人工智能与专家系统研究。
E-mail: secondbo@swpu.edu.cn

Liang Haibo (Corresponding author) received his Ph. D. degree from Southwest Petroleum University in 2008. He is currently a professor and Ph. D. supervisor at Southwest Petroleum University. His main research interests include oil and gas measurement and control technology, artificial intelligence, and expert system research.



耿捷, 1998 年在西南石油大学获得硕士学位, 现为中国石油集团乍得公司采油厂厂长, 主要研究方向为采油工程油气计量。
E-mail: gengjie@cnpct.com

Geng Jie received his M. Sc. degree from Southwest Petroleum University in 1998. He is currently the factory director of the oil production plant at PetroChina Chad Company. His main research interest is oil and gas measurement in oil extraction engineering.