

# 基于多录井参数特征同步的溢流事故监测研究\*

陈青<sup>1,2</sup>, 黄志强<sup>1,2</sup>, 孔祥伟<sup>1,2</sup>,  
何弦桀<sup>3</sup>, 徐洲<sup>1,2</sup>, 安果涛<sup>1,2</sup>

- (1. 长江大学 石油工程学院, 武汉 430100;  
2. 长江大学 油气钻完井技术国家工程研究中心, 武汉 430100;  
3. 中国石油集团川庆钻探工程有限公司 钻采工程技术研究院, 四川 德阳 618399)

**摘要:** 依据录井参数进行溢流事故的判断十分依赖坐岗人员的经验,且现场采集的综合录井参数信噪严重,参数变化特征不明显,溢流监测准确率较低。通过低通滤波处理和局部加权线性回归,去除现场综合录井参数曲线的高频信号和低频信噪,经归一化处理,得到了多参数同步的溢流识别方法,并结合 GCN 图形匹配和 BRNN 双向传递的特点,建立了 GCN-BRNN 相融合的模型,提高了溢流事故监测的准确率。结果表明,通过局部加权线性回归处理后能够使曲线变化特征更加明显,且归一化后的多参数同步监测比单一参数监测的准确率更高;以川西某井的综合录井数据为例进行溢流识别测试,与原先模型相比,结合后的模型溢流识别准确率更高,可达到 85%;储层特征会影响录井参数的采集精度,储层分布结构越均匀、性质越稳定,溢流监测的准确率越高。经 JT 井现场应用,溢流事故识别准确率 $\geq 89\%$ ,实际溢流风险与模型识别结果一致。该方法能有效处理多源信息间的冲突,提高溢流监测的识别精度,对现场结合录井参数的溢流事故监测方法具有指导意义。

**关键词:** 钻井溢流监测; 参数特征; 滤波去噪; 局部加权线性回归; 神经网络  
**中图分类号:** O368; O29 **文献标志码:** A **DOI:** 10.21656/1000-0887.450125

## Study on Overflow Accident Monitoring Based on Synchronous Features of Multiple Well Logging Parameters

CHEN Qing<sup>1,2</sup>, HUANG Zhiqiang<sup>1,2</sup>, KONG Xiangwei<sup>1,2</sup>,  
HE Xianjie<sup>3</sup>, XU Zhou<sup>1,2</sup>, AN Guotao<sup>1,2</sup>

- (1. *Petroleum Engineering College, Yangtze University, Wuhan 430100, P.R.China;*  
2. *National Engineering Research Center for Oil & Gas Drilling and Completion Technology, Yangtze University, Wuhan 430100, P.R.China;*  
3. *Research Institute of Drilling and Production Engineering Technology, CNPC Chuangqing Drilling Engineering Co., Ltd., Deyang, Sichuan 618399, P.R.China*)

**Abstract:** Judging overflow accidents based on well logging parameters relies heavily on the experience of on-duty personnel, and the comprehensive well logging parameters collected in-situ have severe noises and unclear

\* 收稿日期: 2024-05-07; 修订日期: 2024-06-13

基金项目: 国家自然科学基金(51904261)

作者简介: 陈青(1997—),男,博士生(E-mail: chenq.st@yangtzeu.edu.cn);

孔祥伟(1982—),男,教授,博士生导师(通讯作者, E-mail: 501074@yangtzeu.edu.cn).

引用格式: 陈青,黄志强,孔祥伟,何弦桀,徐洲,安果涛. 基于多录井参数特征同步的溢流事故监测研究[J]. 应用数学和力学, 2025, 46(2): 241-253.

parameter change characteristics, resulting in low accuracy of overflow monitoring. A multi-parameter synchronous overflow identification method was obtained through low-pass filtering and locally weighted linear regression to remove the high-frequency signals and low-frequency noises of the in-situ comprehensive well logging parameter curves, and after normalization processing. Combined with the characteristics of the GCN graph matching and the BRNN bidirectional transmission, the GCN-BRNN fusion model was established to improve the accuracy of overflow accident monitoring. The results show that, the local weighted linear regression can make the curve change characteristics more obvious, and the accuracy of the multi-parameter synchronous monitoring after normalization is higher than that of the single-parameter monitoring. With the comprehensive well logging data of a well in western Sichuan as an example, compared with the original model, the combined model has a higher accuracy reaching 85% in overflow identification. The characteristics of the reservoir affect the accuracy of logging parameter collection; the more uniform the reservoir distribution structure is and the more stable the properties are, the higher the accuracy of overflow monitoring will be. After in-situ application in the JT well, the identification accuracy of overflow accidents is  $\geq 89\%$ , and the actual overflow risk is consistent with the model identification results. This method can effectively handle conflicts between multiple sources of information, improve the accuracy of overflow monitoring, and provide guidance for in-situ overflow accident monitoring methods combined with well logging parameters.

**Key words:** drilling overflow monitoring; parameter characteristic; filtering denoising; locally weighted linear regression; neural network

## 0 引 言

随着油气开发逐渐向超深层发展,井下情况复杂、环境严峻,钻井过程中极易发生溢流,造成钻井危害<sup>[1]</sup>。从以往钻井经验来看,从发生溢流到形成井喷的时间很快,往来不及采取措施,造成井控险情甚至威胁钻井人员安全,虽然根据出入口流量差、总池体积能够直接、明确诊断溢流,但需要等侵入井筒的流体上返到井口时才能测量,有效性强但预警性不高<sup>[2-4]</sup>。因此,及时监测溢流的发生,能够争取足够的处理时间,以便迅速采取井控措施,减小溢流的危害<sup>[5]</sup>。

现场采集的综合录井参数获取时间严重滞后,并且十分依赖监测人员的经验。近年来,随着人工智能的发展,许多学者把神经网络等人工智能理论引入到解决科学难题和工程核心技术的领域<sup>[6-10]</sup>。基于此,目前发展出许多溢流事故监测安全算法<sup>[11-14]</sup>,例如袁俊亮等<sup>[15]</sup>创建了基于朴素 Bayes 算法(NB)和钻井大数据的溢流实时预警方法;岳炜杰<sup>[16]</sup>改进传统 Bayes 模型,提出了基于分级 Bayes 判别模型的溢流事故判别方法;徐振华<sup>[17]</sup>将云计算应用于溢流监测,提出了基于立压套压的控压钻井溢流监测方法;张倩<sup>[18]</sup>基于 RBF 神经网络构建了钻井事故识别模型;肖宏亮<sup>[19]</sup>分别采用 Bayes 分类、logistic 回归和神经网络训练钻井数据进行溢流监测;李玉飞等<sup>[20]</sup>提出了一种基于 SVM 和 D-S 证据理论的早期溢流监测方法;GA-BP 神经网络在溢流井涌监测预警方面得到了应用<sup>[21]</sup>;张旭等<sup>[21]</sup>指出了结合大数据进行实时溢流预警的重要性;肖阳等<sup>[22]</sup>运用 Pearson 和 Spearman 大数据的相关性分析方法,完成了区块产量差异性研究;沈旭东等<sup>[23]</sup>利用机器学习提取高耗水层的基本特征,实现了储层耗水能力的初步评价;Sabah 等<sup>[24]</sup>利用自适应模糊神经网络(AN-FIS)、遗传算法优化的多层感知机(GA-MLP)、决策树(DT)等方法开展了钻井漏失监测,并在伊朗马伦油田进行了现场应用;Khodnenko 等<sup>[25]</sup>将最近邻分类算法(KNN)、SVM、随机森林(RF)、逻辑回归(LR)、朴素 Bayes 5 种预测模型进行对比分析,优选出了逻辑回归算法对钻井漏失事故监测的优势性。

这些安全算法的应用表明神经网络在溢流监测领域具有积极作用,但目前大多数溢流监测手段无法在连续长时间的工作中有效识别参数变化的复杂特征,很难进行准确的早期预测。因此,有必要对现场采集的录井数据进行深入研究,通过分析曲线特征来探究溢流初期录井参数的变化规律,从而实现溢流的实时监测,而不是利用历史数据进行后验训练分析是否发生溢流<sup>[26]</sup>。考虑到现场采集的录井数据因设备、环境等因素存在质量问题,本文首先对录井数据进行了低通滤波处理,以去除数据高频信号,再通过局部加权线性回归(LOESS)去除低频信噪,这一方法已在相关文献中得到了广泛应用<sup>[27-28]</sup>,通过该方法获得了平滑的录井

数据曲线,更清晰地展现了录井参数的变化规律.同时对数据进行归一化处理,以便实现多参数的同步溢流监测.为了进一步提高溢流识别的准确性,本文结合图形神经网络(GNN)和循环神经网络(RNN)的特点,建立了图卷积网络-双向循环神经网络(GCN-BRNN)相融模型,同时匹配录井参数的图形特征和数据特征,从而更有效地识别溢流.通过指标评估,与原先的GCN、BRNN方法相比,GCN-BRNN方法识别准确率更高,对溢流监测更有参考价值.

## 1 GNN-BRNN 相融模型构建

### 1.1 GNN 算法

GNN 通过在图中的节点和边上制定一定的策略,将图结构数据转化为规范而标准的表示,并输入到多种不同的神经网络中进行训练,在节点分类、边信息传播和图聚类任务上取得优良的效果<sup>[29]</sup>.

其中,图卷积网络(GCN)通过卷积操作,将节点的特征聚合起来,达到信息传播的目的.假设一批图数据中有  $N$  个节点,每个节点都有自己的特征,设这些节点的特征组成一个  $N \times D$  维的矩阵  $\mathbf{X}$ ,然后各个节点之间的关系也会形成一个  $N \times N$  维的矩阵  $\mathbf{A}$ ,也称为邻接矩阵, $\mathbf{X}$  和  $\mathbf{A}$  就是模型的输入.它的层与层之间的传播方式为

$$\mathbf{H}^{(l+1)} = \sigma \left( \tilde{\mathbf{D}} - \frac{1}{2} \tilde{\mathbf{A}} \tilde{\mathbf{D}} - \frac{1}{2} \mathbf{H}^{(l)} \mathbf{W}^{(l)} \right), \quad (1)$$

其中,  $\tilde{\mathbf{A}} = \mathbf{A} + \mathbf{I}$ ,  $\mathbf{I}$  为单位矩阵;  $\tilde{\mathbf{D}}$  为  $\tilde{\mathbf{A}}$  的度矩阵;  $\mathbf{H}$  为每一层的特征,对于输出层,  $\mathbf{H}$  就是  $\mathbf{X}$ ;  $\sigma$  为非线性激活函数;  $\mathbf{W}^{(l)}$  为权重矩阵.

GCN 通过交替生成节点和边,或者大量训练生成完整图形,具有模拟学习图结构和属性的能力,但对图形噪声十分敏感,并且需要精确的图例信息.上述已针对图形噪声进行了滤波处理.如图 1 所示,  $\mathbf{X}$  表示输入数据,  $\mathbf{Z}$  表示输入数据的特征曲线.在钻井溢流事故中,针对立压、总烃、出入口流量差和总池体积这些参数的曲线特征,首先进行 GNN 的特征匹配来监测录井参数曲线变化,识别是否发生溢流.

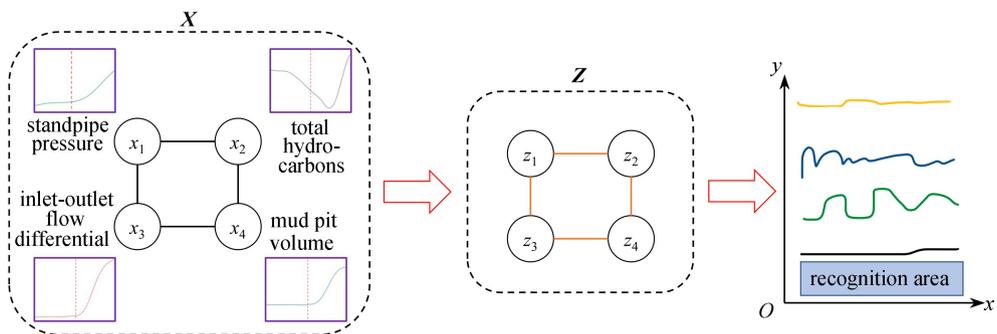


图 1 GNN 结构

Fig. 1 The graph neural network architecture

首先计算两个视图嵌入表示的相似度矩阵<sup>[30]</sup>:

$$Z_{ij} = \frac{(\mathbf{X}_i^{v_1}) (\mathbf{X}_j^{v_2})^T}{\|\mathbf{X}_i^{v_1}\|_2 \|\mathbf{X}_j^{v_2}\|_2}, \quad (2)$$

式中,  $\mathbf{X}_i^{v_1}$  为识别视图 1 中的第  $i$  行像素;  $\mathbf{X}_j^{v_2}$  为识别视图 2 中的第  $j$  行像素;  $Z_{ij}$  为两个视图中  $\mathbf{X}_i^{v_1}$  和  $\mathbf{X}_j^{v_2}$  的余弦相似度.基于此,通过最小化相似度矩阵的冗余信息来强制相似度矩阵  $\mathbf{Z}$  对齐特征规律的单位矩阵  $\mathbf{I}$ .

### 1.2 BRNN 算法

BRNN 由两个 RNN 叠加而成,它们共同连接一个输出层.这个结构提供给输出层输入序列中每一个点完整的过去和未来的上下文信息,比如预测数据不仅需要根据前面的数据来判断,还需要考虑未来的内容.如图 2 所示,  $x$  表示输入的数据(立压、总烃、出入口流量差和总池体积).其中六个独特的权值( $w_1 \sim w_6$ )在每一个时序被重复使用,六个权值分别对应:输入层到向前和向后隐含层( $w_1, w_3$ )、隐含层之间的传递( $w_2, w_5$ )、隐含层到输出层( $w_4, w_6$ ).向前和向后隐含层之间无数据传递,确保展开图是非循环的.同时,提供给输

出层的数据包含了两个相反方向获得的结果,提高了输出的准确性.在钻井溢流事故的监测中,不仅需要时刻接收井下录井参数的变化特征,同时也要考虑未来各参数的变化情况,以便提前预测溢流事故的发生.因此,在基于 GNN 曲线特征匹配的基础上,进行 BRNN 数据特征分析,以提高溢流事故监测的准确性.相应的特征函数表示如下:

$$\begin{cases} p = A_1 \varepsilon^2 + A_2 \varepsilon + A_3, \\ h = B_1 \varepsilon^2 + B_2 \varepsilon + B_3, \\ q = C_1 \varepsilon^2 + C_2 \varepsilon + C_3, \\ V = D_1 \varepsilon^2 + D_2 \varepsilon + D_3, \end{cases} \quad (3)$$

其中,  $\mathbf{A}, \mathbf{B}, \mathbf{C}, \mathbf{D}$  分别为立压、总烃、出入口流量差和总池体积的相关系数矩阵;  $\mathbf{A} = [a_{ij}]$ ,  $\mathbf{B} = [b_{ij}]$ ,  $\mathbf{C} = [c_{ij}]$ ,  $\mathbf{D} = [d_{ij}]$ ,  $i = 1, 2, 3$ ,  $j = 1, 2, 3$ ;  $p$  为立压, MPa;  $h$  为总烃 ( $\times 10^{-6}$ );  $q$  为出入口流量差, L/s;  $V$  为总池体积,  $\text{m}^3$ ;  $\varepsilon$  为曲线横坐标指代参数.

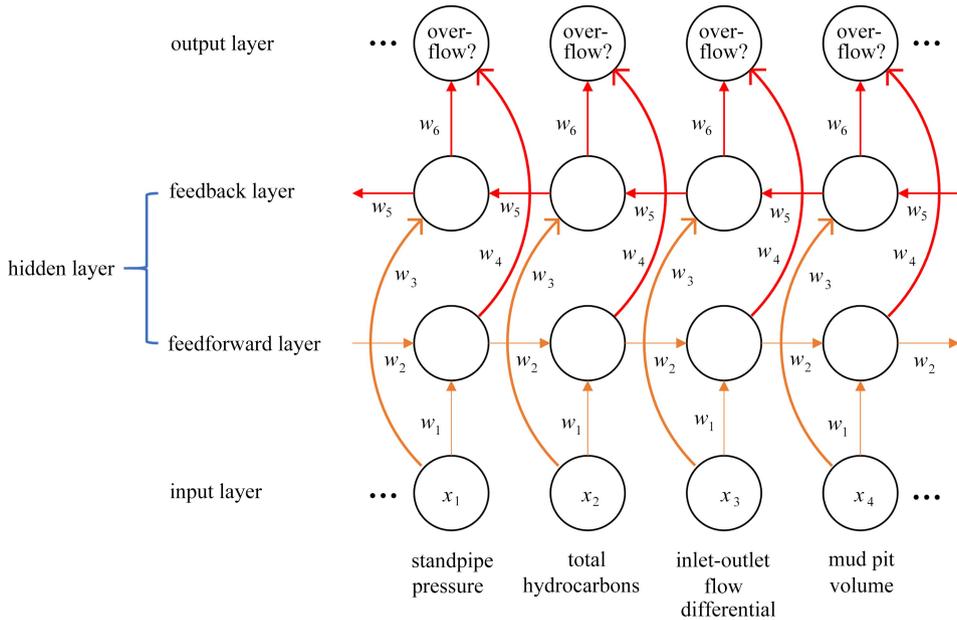


图2 BRNN 结构

Fig. 2 The bidirectional recurrent neural network architecture

### 1.3 信噪处理模型

#### 1) 归一化处理模型

每个录井参数的尺度与量纲均不同,神经网络模型对参数特征敏感性很高<sup>[31]</sup>.通过将录井参数归一化处理,将参数值归一化到区间  $[0, 1]$ ,实现多录井参数同轴效果,归一化公式如下:

$$X'_{ij} = \frac{X_{ij} - X_{\min}}{X_{\max} - X_{\min}}, \quad (4)$$

式中,  $X'_{ij}$  为数据样本矩阵;  $X_{ij}$  为矩阵第  $i$  行第  $j$  列的元素;  $X_{\max}, X_{\min}$  分别为数据中的最大值和最小值.

#### 2) 滤波处理模型

现场采集的录井参数往往会因设备、环境等因素影响带数据的采集质量,通常含有大量噪声,这些噪声会影响模型的泛化能力<sup>[32]</sup>,需要对录井参数进行滤波处理和数据去噪.针对录井参数的高频白噪声信号,采用低通滤波算法,用于抑制高频信号中的异常值或噪声,从而实现数据曲线的平滑和去除高频异常值的效果,一阶低通滤波算法模型如下:

$$Y(n) = \alpha X(n) + (1 - \alpha) Y(n - 1), \quad (5)$$

式中,  $\alpha$  为滤波系数,在  $(0, 1)$  上;  $X(n)$  为本次采样值;  $Y(n - 1)$  为上次滤波输出值;  $Y(n)$  为本次滤波输出值.一阶滤波相当于将新的采样值与上次的滤波结果计算一个加权平均值.

滑动中值与均值滤波模型如下:

$$U_1(i) = \frac{1}{F_1 - 2} \sum_{j=0}^{N_1-1} (U_{i-1} - U_{\max} - U_{\min}), \quad (6)$$

式中,  $U_1(i)$  为数据预处理完成后的滤波输出值;  $F_1$  为连续采样值的频次;  $U_{i-1}$  为滤波后  $i-j$  的采样值;  $U_{\max}$ ,  $U_{\min}$  分别为  $i-j$  采样序列的最大值和最小值。

### 3) LOESS 处理模型

在经过低通滤波处理后的数据, 高频信息部分明显消失, 但曲线低频部分仍旧分布不同信噪, 影响模型的识别效率和准确性. 因此在上述数据归一化和低通滤波处理后, 曲线数据需要进行局部回归分析, 以去除低频部分信噪, 使曲线平滑. 将数据划分成多个区间, 并对每个区间进行拟合, 不断重复这一过程得到不同区间上的加权回归曲线, 最终连接每个曲线中心点整合为一条回归曲线. 样本集的特征矩阵表达为

$$\mathbf{X} = \begin{bmatrix} x_{11} & x_{21} & \cdots & x_{i1} \\ x_{12} & x_{22} & \cdots & x_{i2} \\ \vdots & \vdots & & \vdots \\ x_{1j} & x_{2j} & \cdots & x_{ij} \end{bmatrix}. \quad (7)$$

样本数据对应的输出向量表达为

$$\mathbf{Y} = \begin{bmatrix} y_1 \\ y_2 \\ \vdots \\ y_i \end{bmatrix}. \quad (8)$$

权函数  $w(i)$  以 Gauss 核函数形式表示:

$$w(i) = \exp\left(-\frac{(\mathbf{x}_i - \mathbf{x})^2}{2k^2}\right), \quad (9)$$

式中,  $\mathbf{x}_i$  为样本矩阵第  $i$  个行向量;  $\mathbf{x}$  为待测样本点;  $k$  为加权带宽参数.

对于给定的待测样本点  $\mathbf{x}$ , 计算每个历史样本点  $\mathbf{x}_j$  到该点的距离  $D_j$ :

$$D_j = \sum_{j=1}^n (\mathbf{x} - \mathbf{x}_j)^2, \quad (10)$$

式中,  $\mathbf{x}_j$  为样本矩阵第  $j$  个列向量.

计算加权系数  $W_j$ , 并获得加权系数对角矩阵  $\mathbf{W}$ , 分别如下:

$$W_j = e^{-D_j/(2k^2)}, \quad \mathbf{W} = \begin{bmatrix} W_1 & 0 & \cdots & 0 \\ 0 & W_2 & \cdots & 0 \\ \vdots & \vdots & & \vdots \\ 0 & 0 & \cdots & W_m \end{bmatrix}. \quad (11)$$

回归系数  $\boldsymbol{\theta}$  通过拟合样本集得到:

$$\boldsymbol{\theta} = (\mathbf{X}^T \mathbf{W} \mathbf{X})^{-1} \mathbf{X}^T \mathbf{W} \mathbf{Y}. \quad (12)$$

加权带宽参数  $k$  影响 Gauss 核的特征, 加权带宽参数越大, 表示有较多的样本点权重较高; 反之, 只有离待测样本点较近的样本点具有较高权重, 用于数据拟合.

## 1.4 相融模型求解

模型求解流程如图 3 所示, 具体求解流程如下:

1) 数据预处理. ① 归一化处理: 通过对现场采集原始录井参数进行归一化处理, 使立压、总烃、进出口流量差和总池体积数据实现同轴处理, 确保特征同步. ② 低通滤波处理: 消除录井参数中振幅过大的高频奇异点信噪, 保留低频数据. ③ LOESS 处理: 消除低频数据中的奇异点数据, 保留数据变化的特征规律.

2) 模型判别. ① 图像识别: 采用 GNN 提取各录井数据变化的特征规律, 进行图形特征的对比判别. 具体过程如下:

$$R = \frac{1}{N^2} \sum (S - I)^2 = \frac{1}{N^2} \sum_{i=1}^N (S_{ii} - T)^2 + \frac{1}{N^2 - N} \sum_{i=1}^N \sum_{i \neq j} (S_{ij})^2, \quad (13)$$

式中,  $R$  为对比损失。通过对比不同视图中相似度矩阵  $S$  的对角线元素与非对角线元素, 分析不同视图的余弦相似度, 保持视图间相同样本的不变特征, 保证视图嵌入特征的一致性, 从而达到模型判别的效果, 以此通过录井参数变化特征识别溢流是否发生。② 数据识别: 比对历史井溢流数据库, 判别当前立压、总烃、进出口流量差和总池体积参数的变化是否符合溢流发生。③ 识别结果: 不符合, 继续监测更新数据; 符合, 标记并更新记录的溢流次数, 继续监测更新数据。

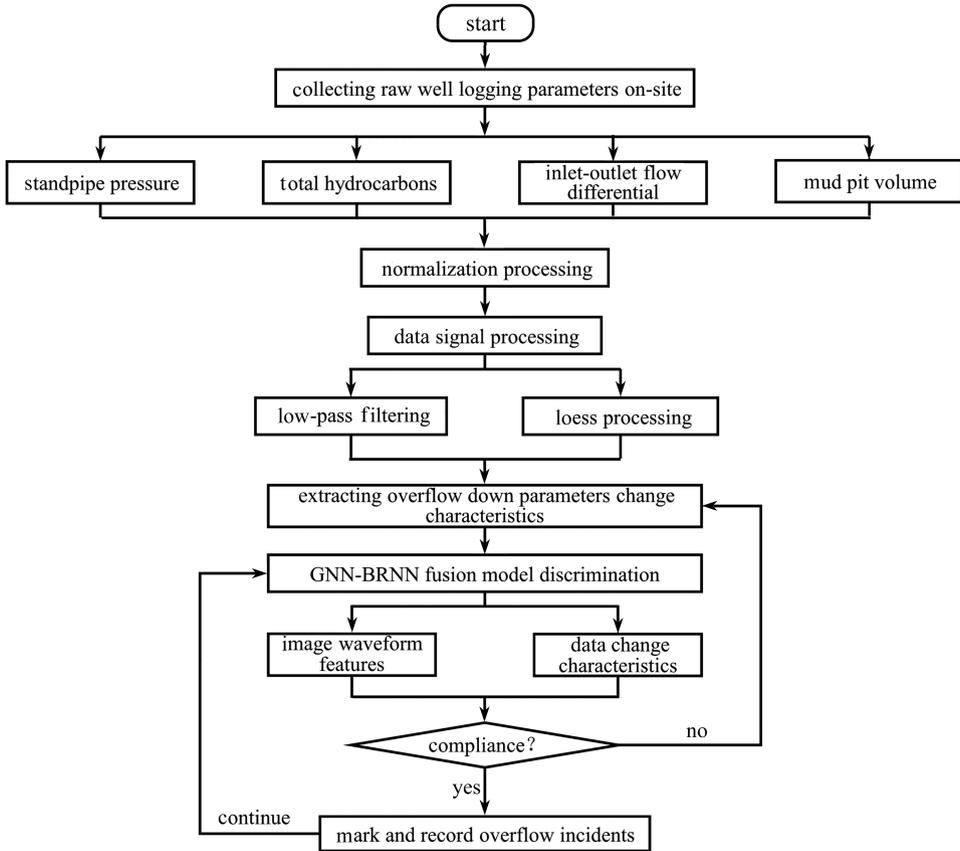


图3 求解流程

Fig. 3 The solving flowchart

## 2 实例分析

### 2.1 数据测试集

为证实本文提出模型的实用性, 本文采用川西 X1 井的历史综合录井数据进行测试, 该井每 20 s 记录一次数据, 井深 5 301 m 处发生溢流事故, 该井采集的立压、总烃、进出口流量差和总池体积四项原始录井数据部分见表 1。

### 2.2 数据测试结果

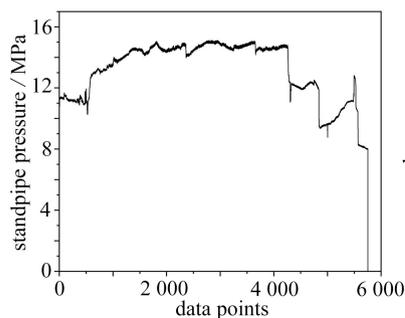
录井参数预处理结果见图 4, 首先通过归一化处理使多个参数实现同轴显示, 确保特征同步, 便于分析溢流事故发生时立压、总烃、进出口流量差和总池体积数据的变化情况, 接着提取溢流特征明显的波段数据, 进行溢流段局部特征的低通滤波处理, 对各参数中存在峰值突变严重、回峰异常、整体偏移严重等问题的异常数据进行消除。由图可知, 立压、总烃和总池体积的波形特异点振幅不大, 选择滤波频率阈值为 0.125 kHz, 而进出口流量差数据在第 300~450 个数据点波段位置的波动较为复杂, 选择滤波频率阈值为 0.5 kHz, 并用滑动中值与均值滤波去除信号中的高频噪声。

表 1 多井历史综合录井数据

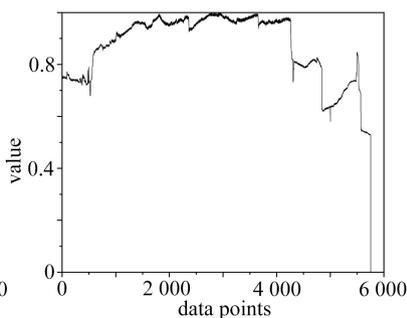
Table 1 Multi-well historical composite well logging data

time /s	standpipe pressure /MPa	total hydrocarbons ( $\times 10^{-6}$ )	mud pit volume /m <sup>3</sup>	inlet-outlet flow differential /( $L \cdot s^{-1}$ )
0	10.09	0.62	100.54	0.6
20	10.41	0.64	100.56	0.66
40	10.57	0.75	100.52	0.66
60	10.99	1.08	100.29	0.51
80	11.11	1.36	100.29	0.74
100	11.21	1.55	100.21	0.78
120	11.3	1.59	100.11	0.86
140	11.35	1.58	100.02	0.9
160	11.39	1.46	100.08	0.85
180	11.27	1.35	100.05	0.9
200	11.4	1.35	100.08	0.88
220	11.32	1.42	100.06	0.85
240	11.4	1.39	100.03	0.85
260	11.36	1.33	100.06	0.86
280	11.34	1.27	100.15	0.81
300	11.34	1.23	100.05	0.8
⋮	⋮	⋮	⋮	⋮

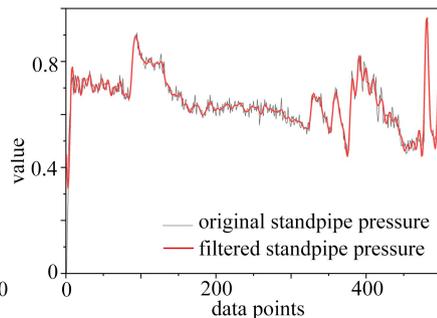
对比图 4(c)、4(i)和 4(l)的原始立压、流量差、总池体积数据和低通滤波处理结果,可以发现远离曲线中心的数据高频信息被过滤,曲线明显去噪.图 4(f)中的原始总烃数据较为稳定,信噪很少,滤波处理的效果不明显;图 4(l)中的总池体积数据处理较为理想,上升沿变化清晰;图 4(c)和图 4(i)的滤波效果最优,数据信号出现明显的上升沿变化和下降沿变化,均没有被算法所滤除.



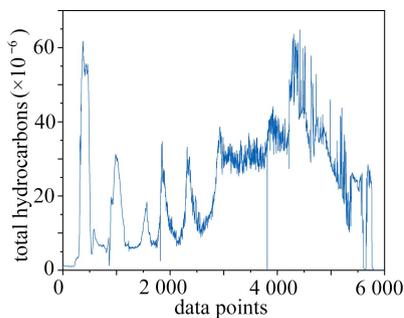
(a) 原始立压数据  
(a) Raw standpipe pressure



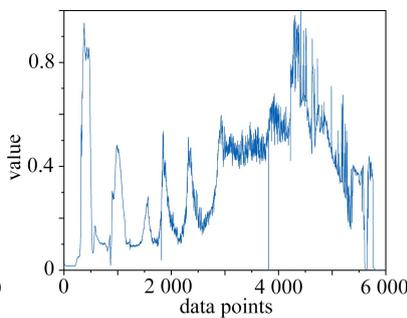
(b) 立压归一化  
(b) Standpipe pressure normalization



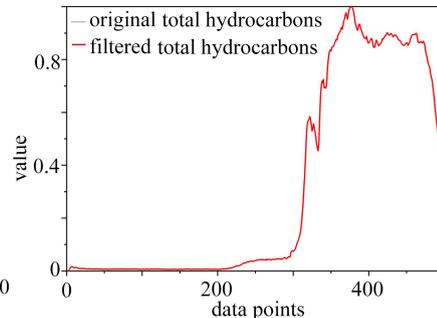
(c) 立压溢流段低通滤波  
(c) Standpipe pressure overflow segment low-pass filtering



(d) 原始总烃数据  
(d) Raw total hydrocarbons



(e) 总烃归一化  
(e) Total hydrocarbons normalization



(f) 总烃溢流段低通滤波  
(f) Total hydrocarbons overflow segment low-pass filtering

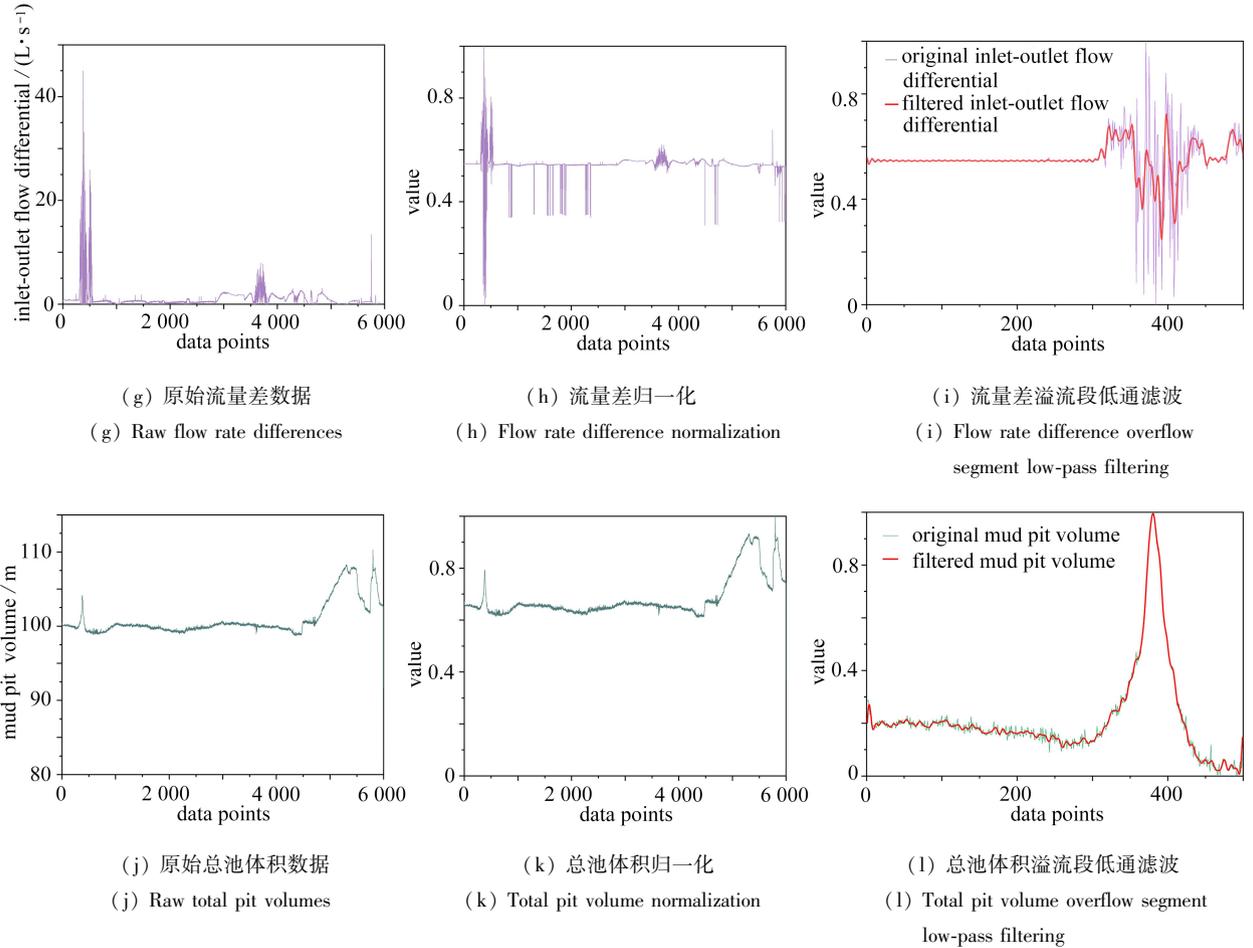


图4 溢流段录井数据滤波处理

Fig. 4 Filtered logging data for the overflow section

注 为了解释图中的颜色,读者可以参考本文的电子网页版本,后同。

从图4可以看出,尽管采用低通滤波处理了高频数据点,但由于信噪与实际真实录井数据信号在时域和频域上存在耦合,导致滤波处理后的总池体积数据仍分布有密集复杂的小波信号,立压和进出口流量差数据更是明显显示出大量的不稳定波形,因此,仅通过低通滤波处理难以直接去除这种干扰信噪,需要采用平滑算法对耦合信号做进一步处理,但常规平滑算法容易消除数据真实波动,难以凸显数据信号的局部特征。

将图4中进行了低通滤波处理后的数据进行局部加权回归处理,在此 $k$ 取值0.1,使保留的低频数据点具备较高权重,用于回归拟合。处理结果如图5所示,可以看出曲线低频信号明显去噪,相比图4滤波结果,各参数曲线的波形变得更加平滑,变化规律更为显著。立压和进出口流量差数据不稳定波形大大减少,曲线波形更为稳定;总池体积数据的低频信号基本消除,小波信号减少,LOESS处理后的曲线表现更为平滑,变化趋势更明显;总烃数据消除了滤波后低频奇异信号的干扰波动,保留了明显的上升波形变化规律。

### 2.3 数据特征分析

表2为溢流发生后立压、总烃、进出口流量差和总池体积特征参数的变化情况<sup>[33]</sup>。溢流表征规律是地层流体在进入井筒过程中录井参数的变化规律,由于溢流现象复杂,且井下状况模糊,选取合适的监测参数是实现快速、准确监测溢流的关键,且单一参数的变化不能明确表示溢流的发生,需要同时监测多个参数进行识别。

结合川西X1井溢流发生点的情况,将图5中各参数曲线进行局部特征分析,溢流段录井参数局部特征曲线如图6所示。在发生溢流时,地层中流体侵入环空,套压升高,静液柱压力随之减小,立压降低;地层气体中含碳氢化合物,溢流发生时常伴随全烃含量以及各烃类气体组分异常增加,导致总烃含量增加;地层中气

体侵入环空后随钻井液上返至地面,在到达井口的过程中,物性发生变化,体积迅速膨胀,顶出大量钻井液,增大出口流量,使出入口流量差升高,泥浆总池体积也会逐渐升高.因此,溢流最直观的表现是钻井液返出量和总池体积的增加,通过这两个参数监测溢流具有较高的可靠性,在此基础上结合立压和总烃的变化规律,进一步提高监测准确性.

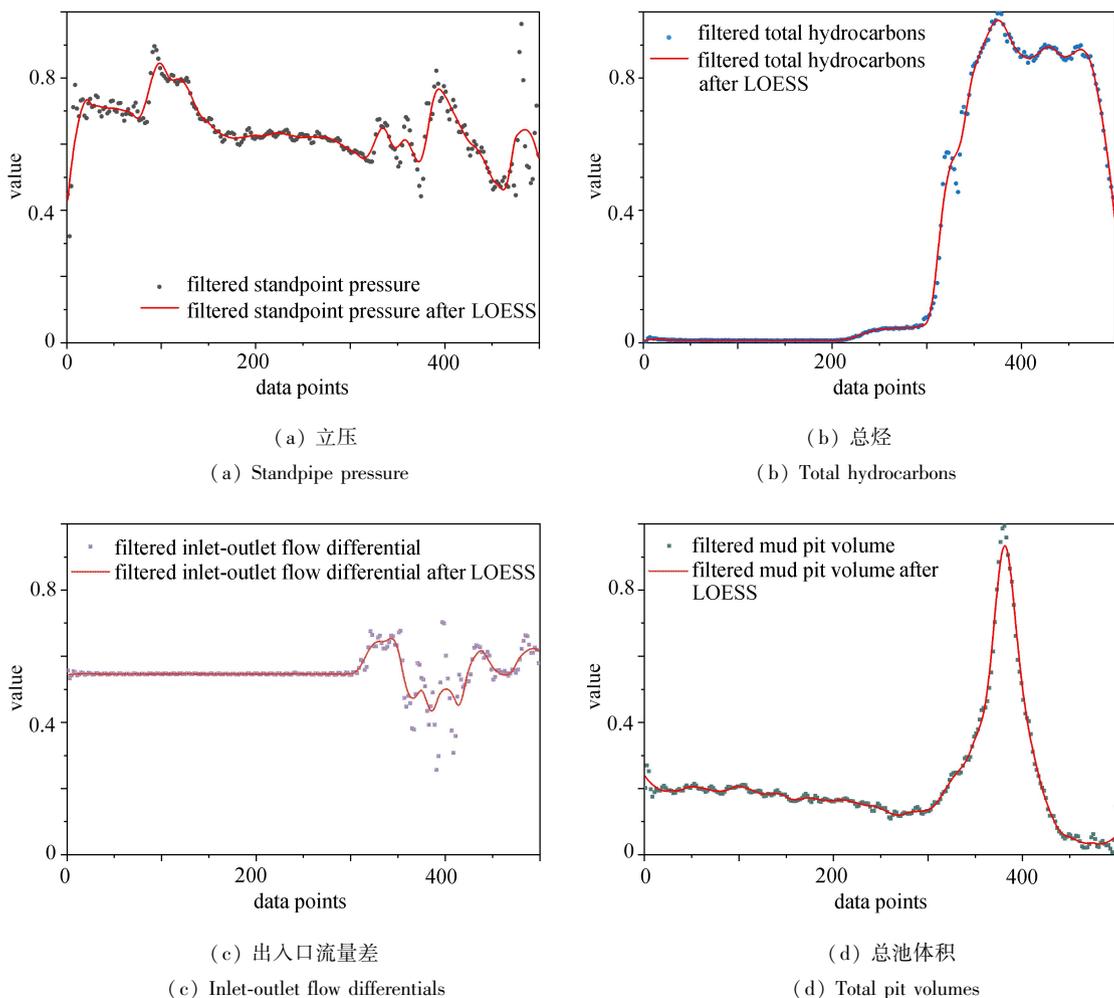


图 5 溢流段录井数据 LOESS 处理

Fig. 5 LOESS processing of overflow section logging data

表 2 溢流发生后特征参数变化分析

Table 2 Analysis of feature parameter changes after overflow occurrence

feature parameter	change characteristics after overflow occurrence	reason
standpipe pressure	decrease	overflow intrusion reduces static fluid column pressure
total hydrocarbons	increase	overflow is often accompanied by abnormal increases in total hydrocarbons content and gas composition of various hydrocarbon classes
inlet-outlet flow differential	increase	overflow intrusion into annulus causes gas volume expansion, displacing drilling fluid
total pit volume	increase	formation fluids intrude into annulus, increasing return volume

## 2.4 模型测试

本文使用 GNN、BRNN 以及两者结合评估的方法进行测试,采用的指标有精确率  $P$ 、召回率  $R$ 、 $F_1$  值以及准确率  $\delta_{Acc}$  值.其中  $P$  指模型对识别为溢流的数据中正确的比例, $R$  指实际类别为溢流的数据中被识别正确的比率, $F_1$  值是一个综合度量指标,是  $P$  和  $R$  的调和平均值, $\delta_{Acc}$  是所有数据中预测正确的比率. $F_1$  和  $\delta_{Acc}$  值越高,模型识别溢流准确程度越好.以  $P, R, F_1, \delta_{Acc}$  为评估标准得到的最终模型十折交叉<sup>[34-35]</sup>平均评估结果

见表3,可以看出 GCN-BRNN 的精确率  $P$ 、召回率  $R$ 、 $F_1$  值以及准确率  $\delta_{Acc}$  值都最大,对溢流事故监测的效果更好。

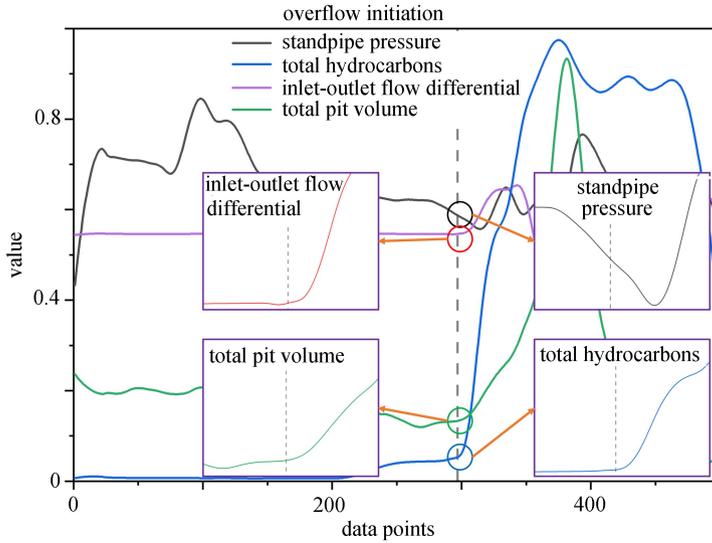


图6 溢流段录井参数局部特征曲线

Fig. 6 Local feature curves of logging parameters in the overflow section

为了确保模型的广泛适用性和可靠性,在不同地质条件下进行了模型测试,以砂岩、页岩及碳酸盐岩为例,对不同储层类型的录井数据使用模型分别进行了溢流监测,对应测试结果见表4, GCN-BRNN 模型在不同地质条件下均表现出较高的识别准确率。在砂岩储层中,由于其孔隙度和渗透率较大,流体流动均匀,溢流监测的灵敏度更好,识别准确率最高;在页岩储层中,由于其致密性,溢流识别的准确率较低,约为91%;而在碳酸盐岩储层中,由于其复杂的孔隙结构和高溶蚀性,溢流监测的效果略低于砂岩储层,通过录井数据预处理,依然取得了较为满意的结果,识别准确率约为94%。这些结果表明,不同储层类型的溢流特征对溢流识别的准确性有影响,储层渗透性越大,溢流识别精度越高,针对不同地层特征,进行数据分类处理对于提高溢流监测的准确性具有积极意义。

表3 模型最终预测结果对比

Table 3 Comparison of final predicted results from models

model	$P$	$R$	$F_1$	$\delta_{Acc}$
GCN	0.63	0.62	0.62	0.64
BRNN	0.75	0.77	0.76	0.77
GCN-BRNN	0.8	0.85	0.83	0.85

表4 部分井历史数据识别结果

Table 4 Identification results of partial well historical data

well ID	reservoir type	overflow frequency	identified overflow frequency	accuracy /%
PZ1-X	shale	11	10	91
GS1-Y	carbonate rock	16	15	94
YT2-X	sandstone	6	6	100

### 3 现场应用

JT 井位于四川省简阳市青龙镇水井村7组,构造位置在四川盆地简阳地区茅口组顶界斜坡带,设计垂深5520 m,完钻层位在栖霞组,其中嘉二段~茅口组发育高压盐水层、气层,易漏失,安全密度窗口窄,为避免或减少漏喷复杂的发生,提高作业的安全性,2023年6月在JT井茅二段开展了预警模型应用工作,应用情况见表5,总计风险识别23次溢流事故,实际发生气测异常22次,试验结果表明:溢流事故识别准确率 $\geq 89\%$ ,实际溢流风险与识别结果一致,验证了模型对于现场溢流识别的可行性,但高压盐水层具有高压、高盐

度的特性,导致所采集的数据漂移率高、漂移程度大,会影响局部监测准确性。

表 5 JT 井模型应用情况

Table 5 The application status of the JT well model

depth /m	time	abnormal type	occurrences /s	warnings	early warning	accuracy /%
5 275.88~5 282.20	2023-06-28	overflow	2	2	78( yes)	100
5 284.33~5 303.40	2023-06-30	overflow	3	3	42( yes)	100
5 305.75~5 318.19	2023-07-09	overflow	4	4	83( yes)	100
5 319.11~5 324.92	2023-07-11	overflow	8	9	60( yes)	89
5 326.36~5 413.26	2023-07-12	overflow	5	5	80( yes)	100

## 4 结 论

1) 现场采集的录井参数容易受到外界因素影响,低通滤波处理和 LOESS 处理能使现场采集的录井参数变化特征更明显,提高录井参数对溢流识别的表征性。

2) 单一录井参数的变化不能明确识别溢流的发生,误判性高,归一化处理的多参数同步溢流监测方法弥补了原先单一参数溢流识别缺乏时效性、一致性的缺点,提高了溢流识别的精度。

3) 基于 GCN 和 BRNN 神经网络建立的相融识别模型,兼具了数据特征和图形特征的变化识别能力,提高了溢流识别的准确性,与原模型对比测试,GCN-BRNN 的溢流识别效果更好。经现场验证,识别准确率  $\geq 89\%$ ,模型可用于现场溢流的识别。

4) 储层特征会影响录井参数的采集精度,储层分布结构越均匀、性质越稳定,溢流监测的准确率越高。针对高温高压、孔缝复杂、矿物质丰富等地层采集录井数据的特殊干扰问题,建议现场配备适配的录井装置及抗干扰措施,以确保数据采集的准确性和实时监测的有效性。

## 参考文献(References):

- [1] 孔祥伟,刘祚才,靳彦欣.川渝裂缝性地层自动压井环空多相压力波速特性研究[J].应用数学和力学,2022,43(12):1370-1379.(KONG Xiangwei, LIU Zuocai, JIN Yanxin. Study on multiphase pressure wave velocity characteristics of automatic kill annulus in Chuanyu fractured formation[J]. *Applied Mathematics and Mechanics*, 2022, 43(12): 1370-1379.(in Chinese))
- [2] SCHAFER D M, LOEPPKE G E, GLOWKA D A, et al. An evaluation of flowmeters for the detection of kicks and lost circulation during drilling[C]//IADC/SPE Drilling Conference. New Orleans, Louisiana: SPE, 1992: SPE-23935-MS.
- [3] 刘书杰,杨向前,郭华,等.井控溢流快速判断方法研究[J].煤炭技术,2017,36(5):296-298.(LIU Shujie, YANG Xiangqian, GUO Hua, et al. Research for judgment method of well control overflow[J]. *Coal Technology*, 2017, 36(5): 296-298.(in Chinese))
- [4] 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 Jiasheng, LIU Wei, HAN Xiaosong, et al. CNN-LSTM fusion network based deep learning method for early prediction of overflow[J]. *China Petroleum Machinery*, 2021, 49(6): 16-22.(in Chinese))
- [5] 常杨,郭修成,李永钊,等.基于随钻工程参数测量数据的钻井风险识别试验[J].钻采工艺,2022,45(5):150-153.(CHANG Yang, GUO Xiucheng, LI Yongzhao, et al. Drilling risk analysis test based on engineering parameter measurement while drilling[J]. *Drilling & Production Technology*, 2022, 45(5): 150-153.(in Chinese))
- [6] 姚浩,夏桂然,刘泽佳,等.基于机器学习的黏钢构件黏接层缺陷识别方法研究[J].应用数学和力学,2024,45(4):429-442.(YAO Hao, XIA Guiran, LIU Zejia, et al. A defect identification method for bonding layers of adhesive steel members based on machine learning[J]. *Applied Mathematics and Mechanics*, 2024, 45(4): 429-442.(in Chinese))
- [7] 姚明辉,王兴志,吴启亮,等.基于 RBF 神经网络的压气机叶片面压力场预测研究[J].应用数学和力学,2023,44(10):1187-1199.(YAO Minghui, WANG Xingzhi, WU Qiliang, et al. RBF neural network based prediction

- on blade surface pressure fields in compressors[J]. *Applied Mathematics and Mechanics*, 2023, **44**(10): 1187-1199. (in Chinese))
- [8] 李杨, 闫冬梅, 刘磊. 基于输出层具有噪声的DQN的无人车路径规划[J]. *应用数学和力学*, 2023, **44**(4): 450-460. (LI Yang, YAN Dongmei, LIU Lei. UGV path programming based on the DQN with noise in the output layer[J]. *Applied Mathematics and Mechanics*, 2023, **44**(4): 450-460. (in Chinese))
- [9] 王沐晨, 李立州, 张珺, 等. 基于卷积神经网络气动降阶模型的翼型优化方法[J]. *应用数学和力学*, 2022, **43**(1): 77-83. (WANG Muchen, LI Lizhou, ZHANG Jun, et al. An airfoil optimization method based on the convolutional neural network aerodynamic reduced order model[J]. *Applied Mathematics and Mechanics*, 2022, **43**(1): 77-83. (in Chinese))
- [10] 周济民, 张海晨, 王沫然. 基于物理经验模型约束的机器学习方法在页岩油产量预测中的应用[J]. *应用数学和力学*, 2021, **42**(9): 881-890. (ZHOU Jimin, ZHANG Haichen, WANG Moran. Machine learning with physical empirical model constraints for prediction of shale oil production[J]. *Applied Mathematics and Mechanics*, 2021, **42**(9): 881-890. (in Chinese))
- [11] KAMYAB M, SHADIZADEH S R, JAZAYERI-RAD 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*. Tinapa-Calabar, Nigeria: SPE, 2010: SPE-136995-MS.
- [12] HARGREAVES D, JARDINE S, JEFFRYES B. Early kick detection for deepwater drilling: new probabilistic methods applied in the field[C]//*SPE Annual Technical Conference and Exhibition*. New Orleans, Louisiana: SPE, 2001: SPE-71369-MS.
- [13] NHAT D M, VENKATESAN R, KHAN F. Data-driven Bayesian network model for early kick detection in industrial drilling process[J]. *Process Safety and Environmental Protection*, 2020, **138**: 130-138.
- [14] ALOUHALI R, ALJUBRAN M, GHARBI S, et al. Drilling through data: automated kick detection using data mining[C]//*SPE International Heavy Oil Conference and Exhibition*. Kuwait City, Kuwait: SPE, 2018: SPE-193687-MS.
- [15] 袁俊亮, 范白涛, 幸雪松, 等. 基于朴素贝叶斯算法的钻井溢流实时预警研究[J]. *石油钻采工艺*, 2021, **43**(4): 455-460. (YUAN Junliang, FAN Baitao, XING Xuesong, et al. Real-time early warning of drilling overflow based on naive Bayes algorithm[J]. *Oil Drilling & Production Technology*, 2021, **43**(4): 455-460. (in Chinese))
- [16] 岳炜杰. “三高”油气井溢流先兆在线监测与预警系统设计与开发[D]. 东营: 中国石油大学(华东), 2014. (YUE Weijie. The design and development of online monitoring and warning system for kick foreboding on “three high” wells[D]. Dongying: China University of Petroleum (Huadong), 2014. (in Chinese))
- [17] 徐振华. 基于云计算的控压钻井溢流监测诊断系统研究与设计[D]. 成都: 西南石油大学, 2019. (XU Zhenhua. Research and design of control pressure drilling overflow monitoring and diagnosis system based on cloud computing[D]. Chengdu: Southwest Petroleum University, 2019. (in Chinese))
- [18] 张倩. 基于机器学习的钻井事故识别系统研究与实现[D]. 西安: 西安石油大学, 2021. (ZHANG Qian. Research and implementation of drilling accident recognition system based on machine learning[D]. Xi'an: Xi'an Shiyou University, 2021. (in Chinese))
- [19] 肖宏亮. 基于机器学习的石油钻井溢流监测研究与应用[D]. 北京: 北京邮电大学, 2020. (XIAO Hongliang. Research and application of oil well overflow monitoring based on machine learning[D]. Beijing: Beijing University of Posts and Telecommunications, 2020. (in Chinese))
- [20] 李玉飞, 张博, 孙伟峰. 基于SVM和D-S证据理论的早期溢流智能识别方法[J]. *钻采工艺*, 2020, **43**(5): 27-30. (LI Yufei, ZHANG Bo, SUN Weifeng. Research on intelligent early kick identification method based on SVM and D-S evidence theory[J]. *Drilling & Production Technology*, 2020, **43**(5): 27-30. (in Chinese))
- [21] 张旭, 王芷桁, 李鑫, 等. 大数据驱动下的溢流监测预警发展现状[J]. *中国石油和化工标准与质量*, 2022, **42**(1): 124-125. (ZHANG Xu, WANG Zhiheng, LI Xin, et al. Development status of overflow monitoring and early warning under the driving of big data[J]. *China Petroleum and Chemical Standard and Quality*, 2022, **42**(1): 124-125. (in Chinese))
- [22] 肖阳, 王家豪, 李志刚, 等. 基于大数据的页岩油区块产量差异分析方法研究[J]. *钻采工艺*, 2022, **45**(3): 73-

- 78.(XIAO Yang, WANG Jiahao, LI Zhigang, et al. Study on production difference analysis method of shale oil play based on big data[J]. *Drilling & Production Technology*, 2022, **45**(3): 73-78.(in Chinese))
- [23] 沈旭东, 刘慧卿, 张郁哲, 等. 基于机器学习的二次采油高耗水层识别方法研究[J]. 钻采工艺, 2022, **45**(4): 74-80.(SHEN Xudong, LIU Huiqing, ZHANG Yuzhe, et al. Identification method for high water consumption layer in second oil recovery based on machine learning[J]. *Drilling & Production Technology*, 2022, **45**(4): 74-80.(in Chinese))
- [24] SABAH M, TALEBKEIKHAH M, AGIN F, et al. Application of decision tree, artificial neural networks, and adaptive neuro-fuzzy inference system on predicting lost circulation: a case study from Marun oil field[J]. *Journal of Petroleum Science and Engineering*, 2019, **177**: 236-249.
- [25] KHODNENKO I, IVANOV S, PERETS D, et al. Detection of lost circulation in drilling wells employing sensor data using machine learning technique[J]. *Procedia Computer Science*, 2019, **156**: 300-307.
- [26] 盛茂, 李根生, 田守增, 等. 人工智能在油气压裂增产中的研究现状与展望[J]. 钻采工艺, 2022, **45**(4): 1-8.(SHENG Mao, LI Gensheng, TIAN Shouceng, et al. Research status and prospect of artificial intelligence in reservoir fracturing stimulation[J]. *Drilling & Production Technology*, 2022, **45**(4): 1-8.(in Chinese))
- [27] 任明仑, 宋月丽, 褚伟. 灰铸铁抗拉强度预测的局部加权线性回归建模[J]. 电子测量与仪器学报, 2019, **33**(3): 65-71.(REN Minglun, SONG Yueli, CHU Wei. Locally weighted linear regression modeling for tensile strength prediction of gray cast iron[J]. *Journal of Electronic Measurement and Instrumentation*, 2019, **33**(3): 65-71.(in Chinese))
- [28] 杨鹏史, 丁卉, 陈同, 等. 基于局部加权线性回归的城市公交车排放能耗预测[J]. 中山大学学报(自然科学版), 2019, **58**(6): 111-118.(YANG Pengshi, DING Hui, CHEN Tong, et al. Estimation of emissions or electricity consumptions of urban buses based on locally weighted linear regression[J]. *Acta Scientiarum Naturalium Universitatis Sunyatseni*, 2019, **58**(6): 111-118.(in Chinese))
- [29] 吴博, 梁循, 张树森, 等. 图神经网络前沿进展与应用[J]. 计算机学报, 2022, **45**(1): 35-68.(WU Bo, LIANG Xun, ZHANG Shusen, et al. Advances and applications in graph neural network[J]. *Chinese Journal of Computers*, 2022, **45**(1): 35-68.(in Chinese))
- [30] 杨希洪, 郑群, 章佳欣, 等. 基于特征插值的深度图对比聚类算法[J]. 计算机科学, 2024, **51**(11): 157-165.(YANG Xihong, ZHENG Qun, ZHANG Jiaxin, et al. Feature interpolation based deep graph contrastive clustering algorithm[J]. *Computer Science*, 2024, **51**(11): 157-165.(in Chinese))
- [31] 王岩, 吴晓富. 深度神经网络训练中适用于小批次的归一化算法[J]. 计算机科学, 2019, **46**(11A): 273-276.(WANG Yan, WU Xiaofu. Novel normalization algorithm for training of deep neural networks with small batch sizes[J]. *Computer Science*, 2019, **46**(11A): 273-276.(in Chinese))
- [32] 王赞, 闫明, 刘爽, 等. 深度神经网络测试研究综述[J]. 软件学报, 2020, **31**(5): 1255-1275.(WANG Zan, YAN Ming, LIU Shuang, et al. Survey on testing of deep neural networks[J]. *Journal of Software*, 2020, **31**(5): 1255-1275.(in Chinese))
- [33] 王钰豪, 郝家胜, 张帆, 等. 钻井溢流风险的自适应 LSTM 预警方法[J]. 控制理论与应用, 2022, **39**(3): 441-448.(WANG Yuhao, HAO Jiasheng, ZHANG Fan, et al. Adaptive LSTM early warning method for kick detection in drilling[J]. *Control Theory & Applications*, 2022, **39**(3): 441-448.(in Chinese))
- [34] 郭立力, 赵春江. 十折交叉检验的支持向量机参数优化算法[J]. 计算机工程与应用, 2009, **45**(8): 55-57.(GUO Lili, ZHAO Chunjiang. Optimizing parameters of support vector machine's model based on genetic algorithm[J]. *Computer Engineering and Applications*, 2009, **45**(8): 55-57.(in Chinese))
- [35] LIU Y H, MAHMMASSANI H S. Global maximum likelihood estimation procedure for multinomial probit (MNP) model parameters[J]. *Transportation Research (Part B): Methodological*, 2000, **34**(5): 419-449.