【环境与能源／Environment and Energy】

基于深度学习的海上压裂砂堵风险实时预警方法

郭布民[1,2]，徐延涛[1,2]，王晓鹏[3]，王新根[1]，宫红亮[1]，巴广东[1]，赵明泽[4]

1）中海油田服务股份有限公司，天津300459；2）天津市海洋石油难动用储量开采企业重点实验室，天津300459；3）中海石油(中国)有限公司天津分公司，天津300459；4）中国石油大学(华东)石油工程学院，山东青岛266580

摘　要：为有效解决压裂过程砂堵事故识别方法费时费力、精度低且无法实时预警的问题，基于施工压力、排量和砂比等多参数数据分析和深度学习算法，提出了海上压裂井砂堵风险自动识别与智能预警方法．利用具有注意力机制的长短期记忆(attention long short-term memory，Att-LSTM)神经网络，构建了施工压力实时预测模型，可提前40 s预测压力变化，精度高于92%；改进具有注意力机制的卷积—长短期记忆(attention-based convolutional neural network-LSTM，Att-CNN-LSTM)神经网络，建立了压裂砂堵识别模型，时间误差少于1 min．耦合两种模型并嵌入迁移学习技术，构建了具有可继续学习功能的压裂砂堵风险实时预警方法．结果表明，压裂砂堵风险实时预警模型通过压力预测值驱动砂堵识别，输出当前及未来40 s砂堵概率（取最高5个概率值均值），现场验证显示可提前38～42 s触发预警．同时，该模型中迁移学习模块使正式训练迭代次数从2 000次降至300次，计算效率提升5.7倍．研究表明，机器学习方法可以提高压裂砂堵识别精度和效率，有效加快压裂决策智能化进程．

关键词：石油与天然气工程；深度学习；压裂砂堵自动识别；压力智能预测；砂堵风险实时预警；迁移学习；数据特征增强

中图分类号：TE377；TP181　　**文献标志码：**A　　**DOI：**10.3724/SP.J.1249.2026.01065

Real-time risk early-warning method for sand plugging during offshore hydraulic fracturing based on deep learning

GUO Bumin[1,2], XU Yantao[1,2], WANG Xiaopeng[3], WANG Xingen[1], GONG Hongliang[1], BA Guangdong[1], and ZHAO Mingze[4]

1) China Oilfield Services Limited, Tianjin 300459, P. R. China

2) Tianjin Key Enterprises Laboratory of Offshore Oil Reserves Exploitation, Tianjin 300459, P. R. China

3) Tianjin Branch, CNOOC China Limited, Tianjin 300459, P. R. China

4) School of Petroleum Engineering, China University of Petroleum (East China), Qingdao 266580, Shandong Province, P. R. China

Abstract: To overcome the limitations of conventional sand-plug identification methods during hydraulic fracturing operation, such as low efficiency, high labor-intensity, limited accuracy, and inability to provide real-time early warning, we develop an automated sand-plugging risk identification and intelligent early-warning model for offshore fracturing wells based on multi-parameter operational data—including operational pressure, pumping rate and sand

Received: 2024-10-14; **Revised:** 2025-04-11; **Accepted:** 2025-06-05; **Online** (CNKI)**:** 2025-06-30

Foundation: Sub-Course of the National Key Research and Development Program (2023YFB4104203); China National Offshore Oil Corporation (CNOOC) "14th Five-Year Plan" Major Science and Technology Project (G2415B-1120C032)

Corresponding author: Senior engineer XU Yantao (Xuyt4@cosl.com.cn)

Citation: GUO Bumin, XU Yantao, WANG Xiaopeng, et al. Real-time risk early-warning method for sand plugging during offshore hydraulic fracturing based on deep learning [J]. Journal of Shenzhen University Science and Engineering, 2026, 43(1): 65-73. (in Chinese)

Open access: This article is licensed under the CC BY 4.0 License (https://creativecommons.org/licenses/by/4.0/).

http://journal.szu.edu.cn

concentration—and deep learning algorithms. Firstly, an attention-based long short-term memory neural network (Att-LSTM) is employed to establish a real-time wellhead pressure prediction model, which could forecast pressure evolution 40 s in advance with an accuracy exceeding 92%. Secondly, an improved attention-based convolutional neural network−LSTM (Att-CNN-LSTM) model is proposed to identify sand-plug, achieving a temporal identification error of less than 1 min. By integrating these two models and incorporating a transfer learning module, a real-time sand-plugging risk early-warning system with continuous transfer learning capability is established. The results indicate that the proposed warning model, driven by the predicted pressure values, can identify sand-plugging events and outputs the sand-plugging probabilities for both the current moment and the subsequent 40 s, calculated as the average of the top five probability values. Field validation shows that the system can trigger warnings 38−42 s prior to actual sand-plugging events. In addition, the embedded transfer learning module helps reduce the number of training iterations required for formal model convergence from 2 000 to 300, improving computational efficiency by a factor of 5.7. This study demonstrates that the proposed deep learning approach can significantly enhance the accuracy and efficiency of sand-plug identification and early-warning, thereby accelerating the intelligent decision-making process in hydraulic fracturing operations.

Key words: petroleum and natural gas engineering; deep learning; automatic sand plugging identification in hydraulic fracturing; intelligent pressure prediction; real-time sand-plug risk early warning; transfer learning; feature augmentation

压裂技术是实现非常规油气藏效益开发的核心技术之一[1-4]. 由于地层非均质性和复杂地质条件，压裂施工过程中砂堵事故可能导致严重的经济损失、环境污染、储层伤害及井筒完整性破坏等工程问题[5-7]. 因此，砂堵风险的高效准确预警成为压裂作业的必要工作，其主要依赖专家经验分析施工曲线异常波动. 然而，原始压裂数据具有体量大、动态波动复杂及噪声显著等特征，导致数据信息提取不充分，砂堵风险识别准确性受限.

目前，砂堵事故识别方法主要包括微地震监测[8-9]、人工判断、双对数曲线法和反斜率法等. 其中，微地震监测通过监测压裂微地震事件分析裂缝状况和判断是否发生砂堵，具有高风险评估效率和高精度，但是设备要求高，技术服务费用昂贵. 人工判断方法利用实时数据绘制压裂施工曲线，由现场工作人员基于经验判断砂堵，虽然成本低且应用广泛，但预警效率和精度受限于个人经验和精力. 双对数曲线法通过将井口压力转换为井底净压力并绘制双对数曲线，通过压力变化进行砂堵识别，数据采集方便且技术成熟，但井底净压力计算需要假设摩擦恒定影响了计算结果. 反斜率法基于压力斜率变化判断砂堵，通常在加砂阶段井口压力先下降后上升，斜率差异反映砂堵风险. 然而，现场数据噪音大，导致斜率计算误差大，预警精度不足. 因此，亟需建立有效的智能预警方法.

人工智能技术为石油工业智能化提供了新机遇[10-14]，井场传感器数据通过物联网环境与数据挖掘技术，可以有效预测压裂风险[15-18]. 虽然人工智能方法能通过学习样本数据特征判断砂堵，但现有技术依赖压力变化斜率计算，缺乏全面智能化的预警能力和继续学习功能. 本研究基于大数据分析和深度学习方法，通过改进现有神经网络结构，利用海上压裂井历史压裂数据与压裂曲线分析总结，建立新压裂井中砂堵风险自动识别与智能预警方法，实现压裂砂堵风险实时预警.

1 数据增强

压裂过程中砂堵事件发生时，施工压力通常会有具体响应(如陡然上升). 本研究以36口海上压裂井为例进行压裂砂堵风险研究，旨在实现压裂过程中砂堵风险提前预警，提高压裂决策效率. 36口压裂井中，砂堵井10口，共有59段压裂施工数据，将3口砂堵井和3口正常井的压裂施工数据作为测试数据，其余作为训练数据.

砂堵的发生受砂比和排量的直接影响，在施工曲线上表现为明显的异常变化. 数采系统以1次/s为采样频率实时获取原始压裂施工数据，这一采样频率能够较为细致地捕捉压裂施工参数随时间的动态变化，为后续模型的构建和分析提供了较为密集且具有时效性的基础数据. 本研究以采集到的施工压力p(单位：MPa)、排出排量q(单位：m^3/s)和砂比($s = V$(下砂)$/V$(防砂泵排出))为主要参数，典型海上压裂井的完整数据实例如图1. 由于离散

http://journal.szu.edu.cn

数据通常具有较强的非线性特征，不同数据在不同时刻往往隐藏着重要的特征信息，这是常规数学建模无法直观体现和发现的．本研究通过计算数据不同时刻的变化率、均值、离差和离差绝对值，作为神经网络模型的补充输入参数，增强不同数据的隐藏特征信息．

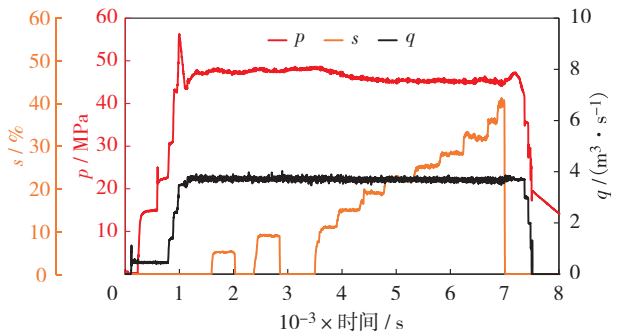


图 1　海上某压裂井的压裂施工数据

Fig. 1　Fracturing operation data curves of an offshore fracturing well. The red line represents the pressure, the black line represents the slurry rate, and the orange line represents the proppant concentration.

根据式(1)和式(2)利用滑动窗口构建神经网络模型的输入参数，新获取的参数可以更好的反应离散数据不同时刻之间的非线性关系，这使得神经网络模型可以更快的捕捉数据之间隐藏的特征信息．

$$\frac{\Delta f}{\Delta t}=\begin{cases}0, & i=0\\ \dfrac{f(t_i)-f(t_0)}{t_i-t_0}, & 0<i\leqslant j\\ \dfrac{f(t_i)-f(t_{i-j+1})}{t_i-t_{i-j+1}}, & j<i\leqslant N\end{cases}\tag{1}$$

$$d(t_i)=\begin{cases}0, & i=0\\ f(t_i)-\overline{f(t_i)}, & 0<i\leqslant N\end{cases}\tag{2}$$

其中，j为计算步长；t_i为压裂作业第i个时刻，i为时刻序号；$d(t_i)$为离差，即t_i时刻参数数据与前i个时间点参数平均值之差；t_0为压裂作业初始时刻；$f(t_0)$为初始时刻的参数数据；$f(t_i)$为t_i时刻的参数数据；$\overline{f(t_i)}$为前i个时间点参数的平均值；$\dfrac{\Delta f}{\Delta t}$为一定时间段内参数的平均变化率；$N$为压裂施工数据中数据点个数．

2　压力实时预测模型

压裂施工压力波动趋势是判断压裂作业中砂堵事故的关键参数．现场作业条件、储层发育情况和压裂设备等因素与压力异常变化密切相关．此外，压力变化的同时往往与施工排量和砂比等其他参数的波动同时发生．因此，实现砂堵风险实时预警的首要任务是精准预测施工压力波动趋势．

压裂施工过程中的多参数时序数据(压力、排量和砂比等)具有典型的非平稳时间序列特征．虽然长短期记忆(long short-term memory，LSTM)网络凭借其门控机制能够有效捕捉时序依赖关系，但在处理受多重地质-工程因素耦合影响的压力信号时存在局限性．这些压力信号不仅包含砂堵的潜在特征，还混杂着强烈的噪声干扰，且表现出显著的非线性和非均匀分布特性．为此，本研究引入了注意力机制，通过建立动态权重分配函数实现关键特征的自适应聚焦，从而提升模型在复杂地质工程条件下的特征提取能力和预测鲁棒性．

本研究利用具有注意力机制的长短期记忆(attention long short-term memory，Att-LSTM)神经网络建立施工压力实时预测模型，基于数采系统前 1 min 获取的数据自动预测后 40 s 施工压力数据，预判施工压力波动．

为验证 Att-LSTM 模型中注意力机制的有效性，基于压裂作业实时压力预测模型输入数据，用大小为 60 的滑动窗口采样构建数据集．设置模型训练迭代次数为 400 次，选择均方误差(mean-square error，MSE)作损失函数．通过监测训练过程中 MSE 动态变化曲线，对比 Att-LSTM 与传统 LSTM 模型(图2)．结果显示，Att-LSTM 模型损失下降更快．

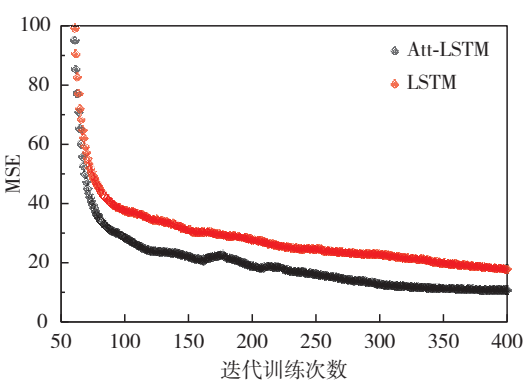


图 2　Att-LSTM 和 LSTM 训练过程中 MSE 变化

Fig. 2　MSES of Att-LSTM and LSTM during the training processes.

2.1　输入数据

基于数采系统获取的时刻、施工压力、排出排量和砂比 4 类数据．采用步长为 5 的均值滤波器降

http://journal.szu.edu.cn

噪处理，并计算20和30时间步下的压力、砂比和排量的变化率、均值、离差及其绝对值作为扩展特征．同时计算累计砂比以增强特征表征能力．最终构建包含17个特征的输入参数集(表1)，时间窗口为60，即压力预测模型的输入为当前时刻之前60 s对应的这17种参数．

表1 压力实时预测模型输入参数

Table 1 Input parameters for the real-time pressure prediction model

类别	名称	符号	单位
原始参数	施工时间	t	s
	施工压力	p	MPa
	排出排量	q	m^3/s
	砂比	s	%
扩展参数	t时刻累计砂比	s_t	%
	压力均值	$\bar{p}$	MPa
	砂比均值	$\bar{s}$	%
	压力离差	p_d	MPa
	砂比离差	s_d	%
	压力离差绝对值	$\lvert p_d \rvert$	MPa
	砂比离差绝对值	$\lvert s_d \rvert$	%
	$j=20$时压力平均变化率	$\left.\frac{\Delta f}{\Delta t}\right\rvert_{p,20}$	MPa/s
	$j=20$时排出排量平均变化率	$\left.\frac{\Delta f}{\Delta t}\right\rvert_{q,20}$	m^3/s^2
	$j=20$时砂比平均变化率	$\left.\frac{\Delta f}{\Delta t}\right\rvert_{s,20}$	$kg/(m^3\cdot s)$
	$j=30$时压力平均变化率	$\left.\frac{\Delta f}{\Delta t}\right\rvert_{p,30}$	MPa/s
	$j=30$时排出排量平均变化率	$\left.\frac{\Delta f}{\Delta t}\right\rvert_{q,30}$	m^3/s^2
	$j=30$时砂比平均变化率	$\left.\frac{\Delta f}{\Delta t}\right\rvert_{s,30}$	%

2.2 模型训练及评价

基于施工压力实时预测模型输入数据，利用大小为60的滑动采样窗口进行输入数据采样，其中，滑动采样窗口移动方向以作业时间为基准．考虑压裂数据以秒为单位被获取，数据量较大，本研究在神经网络模型训练过程中嵌入迁移学习模块，利用两步式模型训练方法训练模型(图3)，有效加速网络训练效率，并在添加新井压裂施工数据时无需从头训练．① 预训练：随机选择一部分数据进行压力实时预测模型预训练，获取部分数据所得到的最佳压力实时预测模型权重，形成基础模型；② 正式训练：基于全部训练数据训练压裂施工压力实时预测模型，利用迁移学习模块，将预训练模型权重作为Att-LSTM网络模型初始权重．

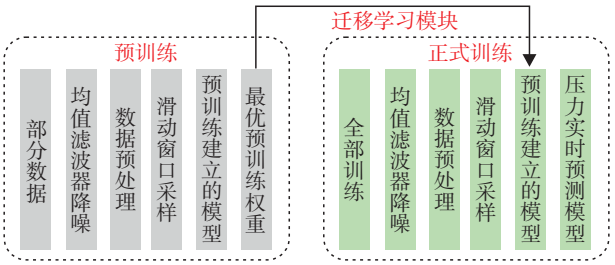


图3 压裂过程压力实时预测模型训练方法示意图

Fig. 3 Schematic diagram of the training method for the real-time pressure prediction model in fracturing process.

对于均值滤波器降噪，通过对相邻数据点求平均平滑数据曲线，降低因设备测量误差和环境干扰等引起的高频噪点．通过信噪比(signal-noise ratio，SNR)计算与特征点保留分析，量化验证均值滤波器降噪效果，本次施工压力、排量及砂比对应的SNR分别为40.5、34.8和33.4 dB，数据波动显著降低且数据特征完整保留．

Att-LSTM神经网络的输入数据维度为60 × 17，利用20口井的数据进行预训练且迭代次数为2 000次，正式训练迭代次数为300次，计算效率提升5.7倍；1次训练所抓取的数据样本数为2 950，优化器为Adam优化器，利用MSE函数，最大学习率为1×10^{-4}，最小学习率为1×10^{-6}，学习率变化方式为cos函数取值方式．

采用皮尔逊相关系数(r)分析参数相关性结果见图4．由图4可知，相关参数均符合压裂施工物理规律．例如，施工压力与排量相关系数达0.97，实际施工中排量变化确实显著影响压力，二者共同为模型提供关键信息．压力均值与压力的相关系数为0.49，表明二者虽相关但反映不同特征：实时压力值体现瞬时变化，压力均值反映趋势水平，二者互补有助于模型更全面捕捉压力规律，提升预测精度．

本研究采用NVIDIA GeForce RTX 3 090 GPU、AMD EPYC 7 642 CPU和512 GB内存进行模型训练与推理．基于Python和Pytorch框架建立并训练神经网络模型．如图5所示，预训练后Att-LSTM模型的MSE损失最小为0.24．将该模型权重作为正式训练初始权重，经300次迭代后，训练集和测试集

http://journal.szu.edu.cn

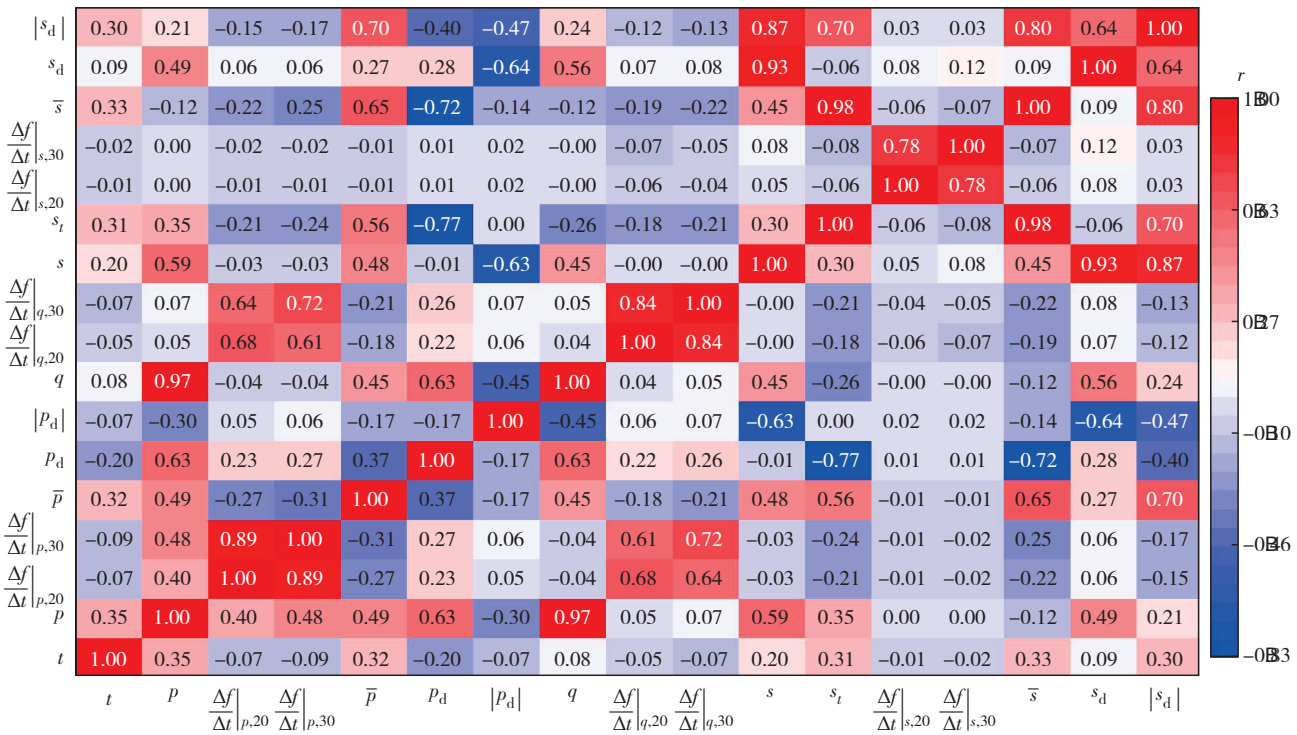
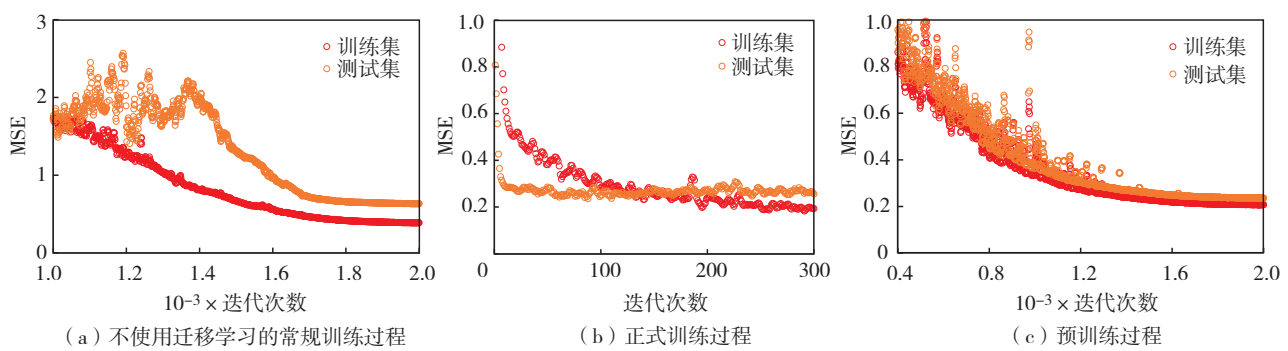


图 4　17 种输入参数相关性分析热力图

Fig. 4　Heat map of correlation analysis of 17 input parameters.



（a）不使用迁移学习的常规训练过程　（b）正式训练过程　（c）预训练过程

图 5　压力实时预测模型迭代训练的 MSE 变化

Fig. 5　Iterative training MSE loss for the real-time pressure prediction model. (a) MSE during conventional training. (b) MSE during formal training. (c) MSE during pre-training. The red circles represent the training loss on the training set, while the orange circles represent the training loss on the testing set.

MSE 分别降至 0. 20 和 0. 24 以下，显著提升了训练效率. 新数据输入时，可直接基于已有权重继续训练，大幅减少迭代次数.

对比实验显示，不使用迁移学习时模型收敛缓慢(图 5(a))；而采用迁移学习后，仅需 300 次迭代(图 5(b))即可达到与预训练(图 5(c))相当的性能，训练时间显著缩短. 这表明迁移学习通过复用预训练特征和权重，有效提升了模型的收敛速度. 这一优势对于需要实时处理新增数据的压裂作业尤为重要，可快速适应区块性质变化，及时提供砂堵预警.

2. 3　预测效果

利用训练好的压力实时预测模型进行压力实时预测，如图 6，可见预测压力与真实压力数据拟合度较高，预测准确度达 92% 以上.

3　砂堵事故自动识别模型

为了实现压裂砂堵事故高效准确地识别，本研究通过搭建具有注意力机制的卷积—长短期记忆(attention-based convolutional neural network−LSTM，

http://journal.szu.edu.cn

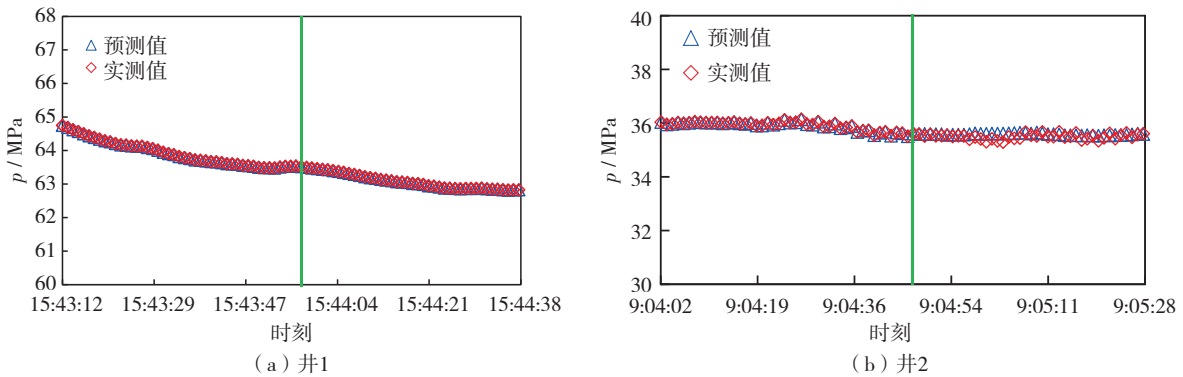


图6 不同压裂井压裂过程中压力预测示例(绿线为当前施工时刻,左侧为历史施工时间,右侧为未来40 s的预测时段)

Fig. 6 Example of pressure prediction during the fracturing process for (a) fracture well 1 and (b) fracture well 2. The red diamond represents the actual pressure data, while the blue triangle represents the predicted pressure data. The green vertical line marking the "current moment", with the historical operation period on its left and the 40 s prediction period on its right.

Att-CNN-LSTM)神经网络结构，构建压裂过程砂堵事故自动识别模型，利用数采系统获取的压裂施工数据，实现压裂砂堵事故的自动识别，提高砂堵事故识别效率，降低砂堵事故判断对施工人员专业知识要求.

压裂过程砂堵事故自动识别模型训练数据集同样基于数采系统获取的时间、压力、排量和砂比数据进行构建. 在建立砂堵事故自动识别数据集过程中，将每口井的压裂施工时间戳数据进行人工标签处理. 将未发生砂堵的压裂时间戳数据标记为0，发生砂堵时刻的时间戳数据标记为1，即压裂砂堵事故自动识别模型通过分析压裂施工数据并将时间戳数据自动识别为0或1进行砂堵事故判断，如图7.

1) 输入数据. 砂堵识别模型从表1中选取10项作为输入(原始参数及当前时刻累计砂比、压力均值、压力离差、压力离差绝对值、$j = 20$和$j = 30$时压力平均变化率)，以作业时间为基准，以大小为60滑动采样窗口的实现输入采样，即利用数采系统前60 s实时数据，判断最后时刻的数据是否为砂堵. 滑动窗口沿压裂作业时间递增方向滑动，步长为1. 窗口内的数据被自动整理为样本矩阵$\boldsymbol{x}_i$，并将矩阵最后1行对应的标签y_i作为当前时刻是否发生砂堵的判断标准. 每个滑动窗口都会生成1个样本点$(\boldsymbol{x}_i, y_i)$，其中，$\boldsymbol{x}_i$是用于模型输入的数据矩阵；y_i则是判断该样本矩阵是否为砂堵的真实类别；k代表长度为N的压裂段中样本点总数，$k = N - j + 1$.

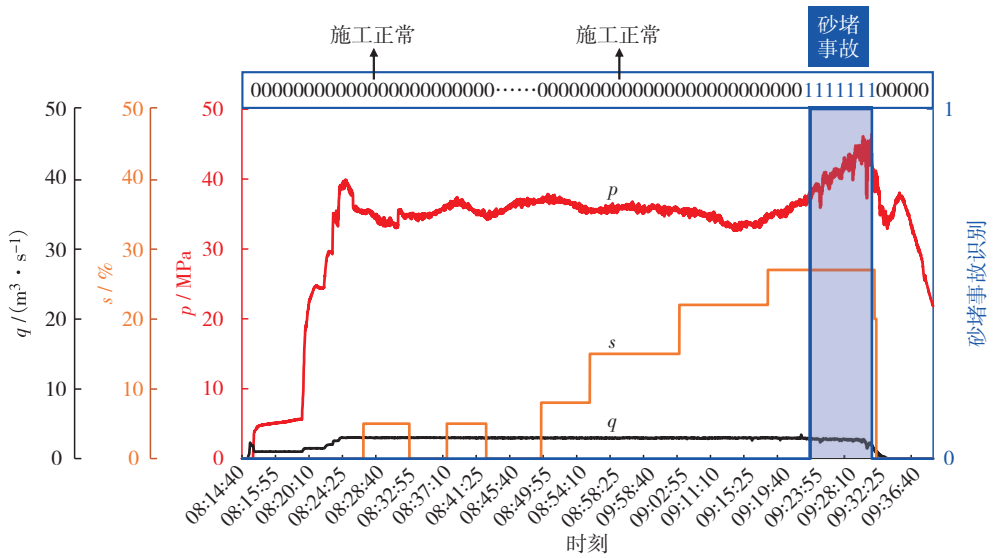


图7 压裂施工时间戳数据分类标记示意图

Fig. 7 Schematic diagram of classification and marking of fracturing operation timestamp data.

http://journal.szu.edu.cn

2）模型训练及评价．模型训练与压力预测模型类似，同样采用两步式训练方法，并嵌入迁移学习模块，加速网络训练效率．Att-CNN-LSTM 神经网络的输入数据维度为 60 × 10．该模型在预训练阶段进行 500 次迭代，正式训练阶段进行 200 次迭代，每次训练处理的数据样本数为 50．

3）识别效果．正式训练后，砂堵事故自动识别模型的预测精度可达到 0.95，MSE 损失误差小于 0.01．砂堵事故识别效果如图 8，其中，绿色区域代表真实砂堵时压力变化，蓝色区域代表砂堵识别模型识别砂堵效果，砂堵事故识别耗时的误差范围远小于 1 min．

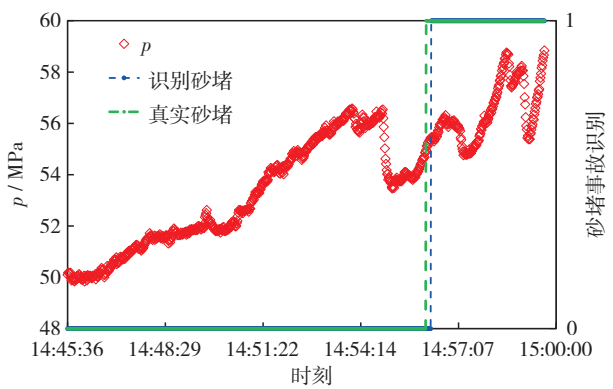


图 8　压裂砂堵井砂堵事故自动识别示例

Fig. 8　Example of automatic identification of sand screenout accidents in fracturing sand screenout well. The red curve represents the pressure data, the blue dashed line indicates the model′s sand screenout warning time, and the green dashed line marks the actual sand screenout occurrence time.

4　砂堵风险实时预警方法

基于已建立的施工压力实时预警模型和砂堵事故自动识别模型，提出了砂堵风险实时预警方法．首先，压裂过程施工压力实时预测模型用于提前 40 s 预测压力变化趋势．然后，压裂过程砂堵事故自动识别模型用于自动识别砂堵事件．该方法将施工压力实时预测模型得到的压力预测数据作为砂堵事故自动识别模型的输入，从而实现砂堵风险自动预警．若预测数据具有砂堵特征，该方法将给出砂堵警示和砂堵概率．

由于压力实时预测模型仅对当前压力进行预测，而砂堵事故自动识别模型还需要排量和砂比数据．所以，砂堵风险实施预测模型在预测过程中利用当前时刻前 40 s 的排量和砂比数据作为预测压力的对应参数数据．

将上述方法应用于海上压裂井进行砂堵风险预警，在输出砂堵风险预警的同时输出砂堵风险的概率，包括当前时刻和未来 40 s 内砂堵风险概率．在输出未来 40 s 的砂堵风险概率时，通过取砂堵概率值最高的 5 个值并求其平均值来进行计算．

预警效果如图 9，黄色区域代表预测的 40 s 压力变化，绿色箭头代表当前压裂时刻，蓝色箭头代表砂堵预警，在黄色区域以外的蓝色线条代表之前压裂时间中进行的砂堵识别，红色箭头代表真实砂堵时刻．砂堵风险实时预警模型通过在当前压裂时刻对预测的压力区域内进行砂堵识别，进而实现砂堵提前预警．从图 9 的预警效果可知，利用砂堵风险实时预警模型可以提前明确砂堵事故的发生，并了解到砂堵发生概率，表明该模型对砂堵事故的发生具有较好的预警作用．

5　结　论

综合海上压裂井压裂施工数据与报告总结，根据压裂砂堵事故发生时压裂数据变化特征，利用深度学习方法，提出了海上压裂井的压裂过程砂堵风险智能实时预警方法．通过以上研究可得：

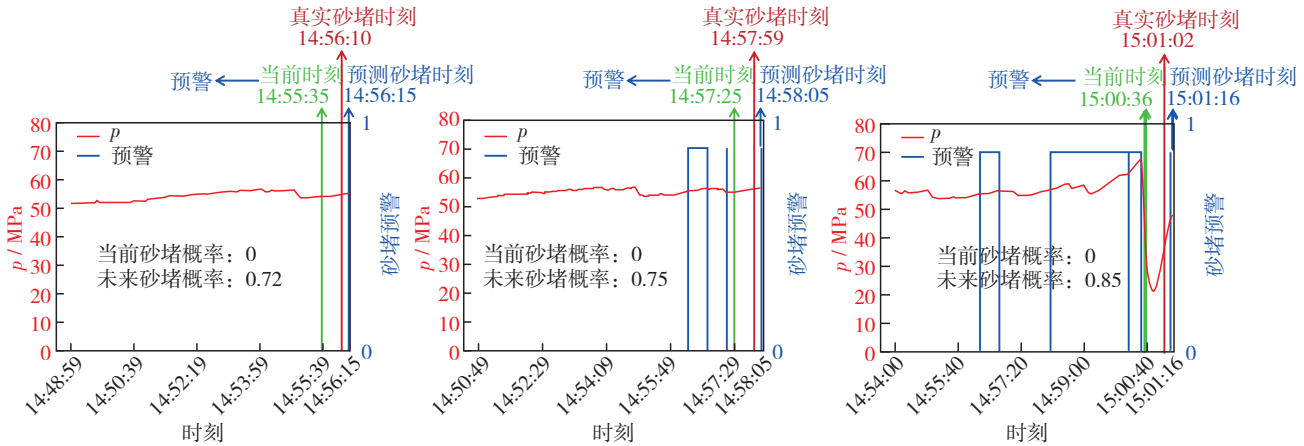
1）通过搭建 Att-LSTM 神经网络结构，建立了压裂过程施工压力实时预测模型，可以实现施工压力的高效精准预测，提前预测未来 40 s 的压力数据，预测精度高于 92%．

2）通过搭建 Att-CNN-LSTM 神经网络结构，建立了压裂过程砂堵事故识别模型，可以实现压裂砂堵事故的高效精准识别，砂堵事故识别时间误差少于 1 min．

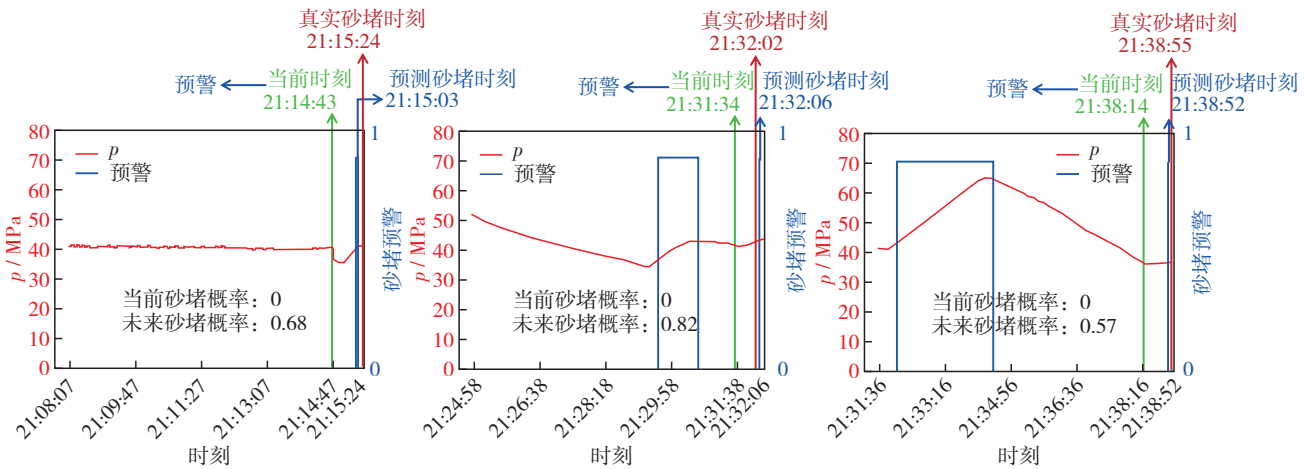
3）通过耦合 Att-LSTM 神经网络和 Att-CNN-LSTM 神经网络，提出了压裂砂堵风险实时预警方法，可以实现压裂砂堵风险实时预警．在预警模型中嵌入迁移学习技术，可以使得压裂砂堵风险实时预警方法具有继续学习功能．

4）通过采用大数据分析和深度学习方法可以实现砂堵风险智能预警，并给出相应的砂堵风险概率．该方法极大提升了压裂施工过程中实时数据的分类效率，提高了砂堵事故自动识别的准确性，实现了压裂砂堵风险的有效预警．

http://journal.szu.edu.cn



（a）砂堵井X1压裂过程砂堵实时预警



（b）砂堵井X2压裂过程砂堵实时预警

图9 两口砂堵井的砂堵风险实时预警效果

Fig. 9 Real-time warning effectiveness of sand screenout risk for two sand screenout wells. (a) Real-time sand screenout warning during fracturing in Well X1; (b) Real-time sand screenout warning during fracturing in Well X2. The red curve represents the measured pressure, blue lines and arrows indicate model-predicted screenout warnings, green arrows mark the current fracturing time, and dark red arrows denote the actual screenout occurrences.

基金项目： 国家重点研发计划子课资助项目（2023YFB4104203）；中国海洋石油集团有限公司“十四五”科技重大专项资助项目（G2415B-1120C032）

作者简介： 郭布民(guobm@cosl.com.cn)，中海油田服务股份有限公司高级工程师. 研究方向：低渗油气藏储层改造技术研究与应用.

引　　文： 郭布民，徐延涛，王晓鹏，等. 基于深度学习的海上压裂砂堵风险实时预警方法[J]. 深圳大学学报理工版，2026，43(1)：65-73.

参考文献 / References：

[1] 李宾. 水平井分段压裂工艺技术研究[J]. 石化技术，2021，28(12)：206-207.
LI Bin. Research on staged fracturing technology of horizontal wells [J]. Petrochemical Industry Technology, 2021, 28(12): 206-207. (in Chinese)

[2] 蒋廷学，卞晓冰. 深层油气藏多级迂回暂堵压裂技术研究[J]. 深圳大学学报理工版，2021，38(6)：590-597.
JIANG Tingxue, BIAN Xiaobing. Multistage circuitous-temporary plugging fracturing technology for deep oil-gas reservoirs [J]. Journal of Shenzhen University Science and Engineering, 2021, 38(6): 590-597. (in Chinese)

[3] 郭建春，路千里，何佑伟. 页岩气压裂的几个关键问题与探索[J]. 天然气工业，2022，42(8)：148-161.
GUO Jianchun, LU Qianli, HE Youwei. Key issues and explorations in shale gas fracturing [J]. Natural Gas Industry, 2022, 42(8): 148-161. (in Chinese)

[4] 雷群，胥云，才博，等. 页岩油气水平井压裂技术进展与展望[J]. 石油勘探与开发，2022，49(1)：166-172，182.
LEI Qun, XU Yun, CAI Bo, et al. Progress and prospects of horizontal well fracturing technology for shale oil and

http://journal.szu.edu.cn

gas reservoirs [J]. Petroleum Exploration and Development, 2022, 49(1): 166-172,182. (in Chinese)

[5] 伊坤. 压裂井砂堵原因分析及对策[J]. 化学工程与装备，2022(2)：80，70.
YI Kun. Analysis of the causes and countermeasures of sand blockage in fractured wells [J]. Chemical Engineering & Equipment, 2022(2): 80,70. (in Chinese)

[6] 祁生金，贺海龙，光辉，等. 致密砂岩气藏压裂砂堵原因分析及对策[J]. 石油化工应用，2023，42(10)：14-19.
QI Shengjin, HE Hailong, GUANG Hui, et al. Cause analysis and countermeasures of fracturing sand plugging in tight sandstone gas reservoir [J]. Petrochemical Industry Application, 2023, 42(10): 14-19. (in Chinese)

[7] 冯尧. 松辽盆地北部常规油储层压裂砂堵原因及对策分析[J]. 化工管理，2023(31)：54-56.
FENG Yao. Analysis of causes and countermeasures of sand blockage caused by conventional oil reservoir fracturing in the northern part of Songliao Basin [J]. Chemical Enterprise Management, 2023, (31): 54-56. (in Chinese)

[8] HUANG Qijun, GUO Delong, SUI Guojie, et al. Application of microseismic monitoring in fracturing process evaluation [J]. Journal of Physics: Conference Series, 2024, 2834(1): 012049-012049.

[9] JIN Qihu, YU Xuemeng, LIANG Xueli, et al. Determination of Fracturing Risk-Units base on seismic and microseismic [J]. Journal of Physics: Conference Series, 2024, 2834(1): 012164-012164.

[10] 郭建春，张宇，曾凡辉，等. 非常规油气储层智能压裂技术研究进展与展望[J]. 天然气工业，2024，44(9)：13-26.
GUO Jianchun, ZHANG Yu, Zeng Fanhui, et al. Research progress and prospects of intelligent fracturing technology for unconventional reservoirs [J]. Natural Gas Industry, 2024, 44(9): 13-26. (in Chinese)

[11] 李根生，田守嶒，盛茂，等. 智能压裂技术研究进展与前景展望 [J]. 钻采工艺，2025，48(1)：1-9.
LI Gensheng, TIAN Shouceng, SHEN Mao, et al. Research progress and prospect of intelligent hydraulic fracturing technologies [J]. Drilling & Production Technology, 2025, 48(01): 1-9. (in Chinese)

[12] 王文东，石梦翩，庄新宇，等. 基于机器学习的井位及注采参数联合优化方法[J]. 深圳大学学报理工版，2022，39(2)：126-133.
WANG Wendong, SHI Menghe, ZHUANG Xinyu, et al. Joint optimization method of well location and injection-production parameters based on machine learning [J]. Journal of Shenzhen University Science and Engineering, 2022, 39(2): 126-133. (in Chinese)

[13] 陆吉，林伯韬，史璨，等. 克拉玛依油田七区砂砾岩油藏智能岩性识别[J]. 深圳大学学报理工版，2023，40(3)：361-369.
LU Ji, LIN Botao, SHI Can, et al. Intelligent lithologic identification of sandy conglomerate reservoirs in District No. 7 of Karamay Oilfield [J]. Journal of Shenzhen University Science and Engineering, 2023, 40(3): 361-369. (in Chinese)

[14] 蒋廷学，周珺，廖璐璐. 国内外智能压裂技术现状及发展趋势[J]. 石油钻探技术，2022，50(3)：1-9.
JIANG Tingxue, ZHOU Jun, LIAO Lulu. Development status and future trends of intelligent fracturing technologies [J]. Petroleum Drilling Techniques, 2022, 50(3): 1-9. (in Chinese)

[15] 何玉荣，宋志超，张燕明，等. 机器学习在水力压裂作业中的应用综述[J]. 中国石油大学学报自然科学版，2021，45(6)：127-135.
HE Yurong, SONG Zhichao, ZHANG Yanming, et al. Review on application of machine learning in hydraulic fracturing [J]. Journal of China University of Petroleum Edition of Natural Science, 2021, 45(6): 127-135. (in Chinese)

[16] 袁彬，赵明泽，孟思炜，等. 水平井压裂多类型复杂事件智能识别与预警方法[J]. 石油勘探与开发，2023，50(6)：1298-1306.
YUAN Bin, ZHAO Mingze, MENG Siwei, et al. Intelligent identification and real-time warning method of diverse complex events in horizontal well fracturing [J]. Petroleum Exploration and Development, 2023, 50(6): 1298-1306. (in Chinese)

[17] WANG F, TANG H, LI L, et al. An early warning method for fracturing accidents using joint CNN and LSTM modeling [C]// International Conference on Wireless Artificial Intelligent Computing Systems and Applications. Cham, Swiss: Springer Nature Switzerland, 2024: 428-439.

[18] SUN Yanwei, LIU Qingyou, FENG Zhu, et al. Sand screenout early warning models based on combinatorial neural network and physical models [J]. Processes, 2025, 13(4): 1018.

【中文责编：晨兮；英文责编：天澜】

http://journal.szu.edu.cn