

基于 LSTM-WGAN 模型的柱塞-泡排复合排采系统 预测控制方法^{*}

赖 欣¹ 钱中程¹ 杨 肖¹ 刘永辉² 叶长青³ 王 强³

(1. 西南石油大学机电工程学院 成都 610500; 2. 西南石油大学石油与天然气工程学院 成都 610500;
3. 中国石油西南油气田分公司工程技术研究院 成都 610017)

摘要:高效的生产过程和智能化管理是天然气井可持续发展的关键,目前实际生产中页岩气开采仍然面临着井底积液造成气井产能下降的问题。为提高天然气井的产能和排水效率,充分利用泡沫排水采气和柱塞气举的优点,设计了一套“双元合一”的柱塞-泡排复合排采装置,提出了一种新颖的基于长短期记忆网络(LSTM)和Wasserstein生成对抗网络(WGAN)的复合排采LSTM-WGAN预测控制方法。利用基于密度的抗噪聚类算法(DBSCAN)对数据进行预处理,避免异常数据对模型预测的影响。通过生成器和判别器相互对抗并更新各自梯度方向的权重,不断优化使油套压差、水气比预测值逼近真值,从而准确预测下一时刻的油套压差和水气比。通过柱塞-泡排复合排采智能管理系统,实施预测的柱塞泡排投放策略。实验结果表明,LSTM-WGAN模型的误差最小,与LSTM模型相比,LSTM-WGAN模型的油套压差和水气比预测结果的均方根误差、均方误差、平均绝对误差分别降低了2.64%、5.13%、11.75%和8.81%、8.07%、6.60%。LSTM-WGAN预测模型可以准确地预测油套压差和水气比,指导柱塞-泡排复合排采系统发出正确的投放泡球和柱塞指令,实现了泡排-柱塞的全智能化投放。

关键词:复合排采;预测控制;LSTM-WGAN;油套压差;水气比;井底积液

中图分类号: TH86; TN06 文献标识码: A 国家标准学科分类代码: 460.40

LSTM-WGAN-based model predictive control method of plunger-foam compound drainage system

Lai Xin¹ Qian Zhongcheng¹ Yang Xiao¹ Liu Yonghui² Ye Changqing³ Wang Qiang³

(1. School of Mechanical Engineering, Southwest Petroleum University, Chengdu 610500, China;

2. Petroleum Engineering School, Southwest Petroleum University, Chengdu 610500, China;

3. Engineering and Technology Research Institute, PetroChina Southwest Oil & Gas Field Company, Chengdu 610017, China)

Abstract: Efficient production process and smart management are key to the sustainable development of natural gas wells. At present, shale gas mining in actual production still faces the problem of liquid loading in wellbores causing the gas well production capacity to decrease. In this paper, a “dual-element integration” plunger-foam compound drainage device is designed to improve the productivity and drainage efficiency of gas wells, taking full advantages of both shale gas foam drainage and plunger drainage gas recovery systems. A novel LSTM-WGAN predictive control method based on Long short-term memory networks (LSTM) and Wasserstein generative adversarial networks (WGAN) is proposed. Density-based spatial clustering of applications with noise (DBSCAN) is used to preprocess the data to avoid the impact of abnormal data on model prediction. The generator and the discriminator compete with each other and update the weights of their respective gradient directions, and the predicted values of oil-casing pressure difference and water-gas ratio are continuously optimized to approach the true value. This enables the model to accurately predict the oil-casing pressure difference and water-gas ratio at the next moment. The predicted plunger-foam drainage strategy is implemented through the plunger-foam drainage composite drainage intelligent management system. Compared with LSTM models, the LSTM-WGAN model reduces the root mean square error (RMSE), mean square error (MSE), and mean absolute error (MAE) of the predicted oil-casing pressure difference and water-gas ratio by 2.64%, 5.13%, 11.75% and 8.81%, 8.07%, 6.60%, respectively. The experimental results demonstrate that the

prediction model can accurately predict the oil-casing pressure difference and water-gas ratio data, guide the plunger-foam compound drainage system to issue correct instructions to deploy foam and plungers, and the intelligent delivery of plunger-foam is realized.

Keywords: compound drainage; predictive control; LSTM-WGAN; oil-casing pressure difference; water-gas ratio; liquid loading

0 引言

在气井的整个开采周期中,随着气体流速降低,气体不足以携带液体出井,液体在井下聚集产生井底积液,导致气井的产量和产能下降。对于大多数气井来说,延长生命周期的主要挑战来自于排除气井中的井底积液^[1]。气井产能会因为井底积液而大幅下降,因此需及时准确判断当前井底积液量,并实施有效的排水采气措施,以确保稳产增效^[2]。改善积液问题可以从硬件排液技术和软件预测方法两方面入手。

为了解决井底积液问题,工业界采用了多种排液技术。柱塞气举技术因其高效性和经济性而成为一种广泛采用的方法。柱塞排水采气工艺以其使用寿命长、维修成本低、具有较高的排水效率和稳定性特点被广泛应用,但存在需要定期维护和清洗,操作过程中可能出现柱塞卡阻,且在高温高压环境下可能存在耐受性差等问题。段进贤^[3]根据大牛地不同管柱结构设计了不同规格的分体式柱塞,提高了气井的日产液量。周宇驰^[4]对排水采气工艺进行了模拟改进,分析总结了差分数值求解方法,并基于质量守恒原理建立了柱塞排水采气工艺过程中柱塞运动的数学模型,提高了排水采气效率。黄伟明等^[5]对分体式排水采气柱塞进行了结构优化,提高了气井的排水效率,还能有效延长设备的使用寿命,减少维护成本。泡沫排水采气工艺具有排水效率高、排水速度快、可以有效降低井底压力等优点,但传统泡沫排水采气采用车载人工加注方式,工作量大,施工成本高,气井不易实现智能化管理^[6]。液体泡排剂^[7]因其操作简便且在较低浓度下可以快速形成泡沫的特点,在工业界被广泛应用,但液体泡排剂可能因井下温度和压强变化而失效。固体泡排剂^[7]相较于液体泡排剂能保持更长时间的稳定性,尤其在高温高压下的表现更佳。然而,固体泡排棒在下落时受上升气液两相流影响严重,且在通过倾斜段时与井筒摩擦阻力较大,最后导致下落位置较浅,难以与积液充分反应。

实施排采工艺前,利用预测模型对天然气井关键状态参数进行准确预测,合理制定泡排球和柱塞的投放策略,实现快速有效排除井底积液,提高气井产能。随着油气田自动化的快速发展,深度学习方法在石油工程领域得到广泛应用。李萍等^[8]在煤层气井产量上使用前馈神经网络(back propagation, BP)补偿算法进行预测,并得到了良好的预测结果,为煤层气井产量预测提供了一种神

经网络新方法。Calvette 等^[9]讨论了长短期记忆神经网络(long short-term memory networks, LSTM)模型预测油气产量时比油藏数值模拟的预测精度更高。Lee 等^[10]分别使用 LSTM 模型和递减曲线分析对页岩气井的月产量进行预测,论证了 LSTM 模型的预测精度更高。由于 LSTM 预测准确性高,并且预测所需的数据量小,更加适用于页岩气井生产数据预测,因而被广泛应用于油气井现场的生产预测^[11]。学者们对 LSTM 模型不断进行优化,如 Zhan 等^[12]通过集成学习方法,组合了两种不同特性的 LSTM 模型,使模型预测精度显著提高。Kocoglu 等^[13]利用 Bi-LSTM 模型对美国 Pennsylvania 地区页岩层多口井产量进行预测,预测精度相较于门控循环单元(gated recurrent unit, GRU)和 LSTM 模型均有所提高。Song 等^[14]利用粒子群优化算法对 LSTM 模型的超参数进行处理,提高了模型预测的准确性。通过 LSTM 进行时间序列分析、捕捉气井状态整体变化趋势,其已成为石油工程领域预测的重要工具,但 LSTM 存在处理长序列时的全局建模和多维向量间复杂交互关系不足的问题,在处理需要长时间跨度依赖的预测任务时,可能导致模型无法有效捕捉长距离依赖关系,从而使预测精度降低。

综上所述,针对页岩气泡排和柱塞排水采气两种系统的单一局限性,为各自发挥优势并扬长避短,设计了一套“双元合一”的柱塞-泡排复合排采系统,该系统综合利用了柱塞排水和泡沫排水的优点,并采用了一种新型球状固体泡排剂(泡排球),球状结构可降低泡排剂下行阻力,泡排球先于柱塞投放,可在柱塞的推动下到达井下更深的位置,与积液反应更加充分,提高排液效率。为解决柱塞-泡排复合举升系统泡排球和柱塞投放频率问题,提出了一种适合气井生产工艺特征的 LSTM-WGAN 柱塞-泡排预测控制方法,充分利用 LSTM 可以捕捉气井数据在时间上的长期依赖关系和 Wasserstein 生成对抗网络(wasserstein generative adversarial networks, WGAN)可以生成更稳定数据的优势,并在特征输入中加入了“关井时间”变量,进一步提高了模型的预测精度,实现了在柱塞-泡排复合排采系统中对气井产液情况的准确预测,能够确保泡排球和柱塞的准确投放,提高了排水采气系统的稳定性和排采效能。

1 柱塞-泡排复合排采系统

“双元合一”柱塞-泡排复合排采系统采用智能化和模块化设计理念,由上位机管理系统模块、电源模块、柱

塞排采模块、泡排球排采模块以及控制模块组成。系统整体设计如图1所示。

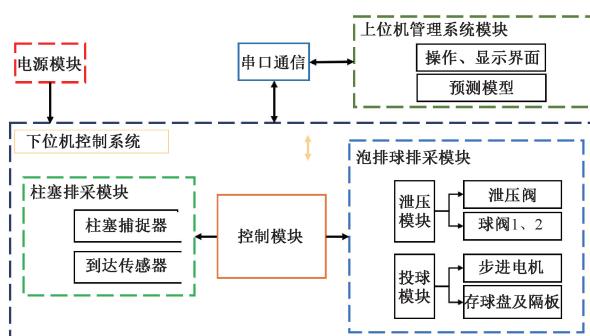


图1 柱塞-泡排复合排采装置设计

Fig. 1 Design of plunger-foam combination liquid removal device

采用嵌入式芯片作为控制模块,搭建泡排球和柱塞控制电路。柱塞排采模块由电磁柱塞卡定器、柱塞到达传感器等组成。泡排球排采模块由投球装置、泄压装置构成。其中,泄压装置由一个泄压阀以及两个电动法兰球阀组成,泄压装置位于泡排球投放装置和油管之间,以防止投球装置在投放泡排球时井口压力对其产生冲击,造成设备损坏等问题。通过反转电路控制电磁阀和泄压阀实现系统压力平衡,完成嵌入式控制模块驱动电机实现投球功能;由继电器电路控制柱塞投放,柱塞根据其自身重力下落到油管中,采用电压转换模块将光电传感器的输出转换并反馈到柱塞控制模块,完成对柱塞到达状态的检测。

开发了柱塞-泡排复合排采智能管理系统作为上位机管理模块,其中由基于LSTM-WGAN网络的预测模型根据实时更新的现场数据(油套压差、水气比)做出预测结果,柱塞-泡排复合排采智能管理系统根据预测结果发出投放泡排球和柱塞的信号,控制模块根据所接收到投放信号的不同而判断投球数量和投柱塞频率(控制流程如图2所示),实现按需投放的智能工作模式。

柱塞-泡排复合排采模拟装置如图3所示,系统结构简图如图4所示。该装置模拟了柱塞-泡排复合排采系统在实际气井中的运行情况,其中柱塞排采模块和泡排球排采模块相互配合,以实现气井井底积液的高效排除。通过这些模块的协同作用,可以模拟气井排采过程,为气井生产运行提供参考依据。

2 LSTM-WGAN模型构建

基于LSTM-WGAN井底积液预测控制模型整体框架如图5所示。首先,通过基于密度的抗噪聚类算法(density-based spatial clustering of application with noise, DBSCAN)对长宁气田现场的油套压差和水气比数

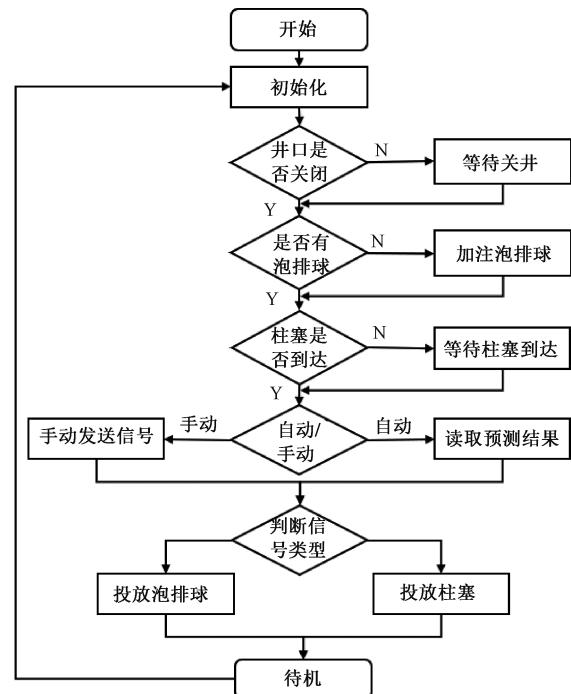


图2 控制流程

Fig. 2 Control flow diagram

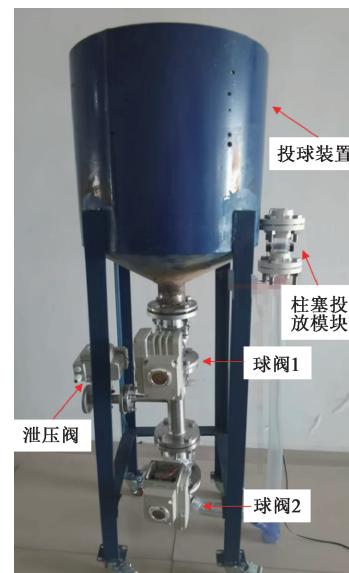


图3 柱塞-泡排复合排采系统

Fig. 3 Plunger-foam combination liquid removal system

据进行数据预处理,避免异常数据对预测结果的影响。然后将优化后的数据输入到LSTM-WGAN网络中,LSTM提取时间步中的数据作为输入,并在序列的下一步预测特征。将预测值输送到WGAN网络中和真实数据一起进行鉴别。通过不断相互对抗训练,使生成数据分布更加接近真实数据分布。该方法利用LSTM和WGAN二者

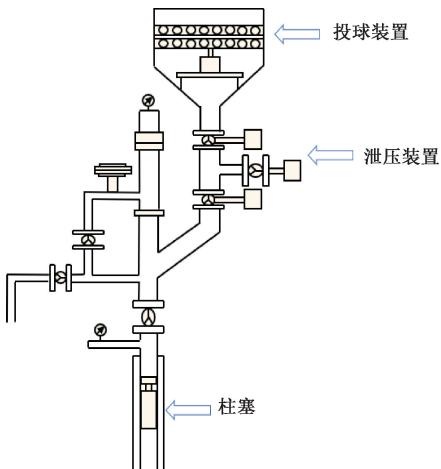


图 4 结构简图

Fig. 4 Structural schematic

的优势,不仅提升了模型对数据的处理能力,也增强了预测结果的可靠性。

2.1 异常值检测单元

采用 DBSCAN 聚类算法作为异常值检测单元。DBSCAN 原理图如图 6 所示。DBSCAN 聚类算法是一种基于密度的聚类算法,它将密度相连点的最大集合定义为一个簇,并可在空间数据库中发现任意形状的噪声聚类。算法开始首先随机选择一个点,标记所有与该点距离在半径 r 内的点,如果标记点的数量大于最小数(MinPts),则当前点为核心点(Eps)并与其标记点形成一个簇。以相同的方法处理所有改为被标记点,如果找出点的数量小于最小包含点数,则该点被标记为噪声点^[15]。

油套压差、气水比记为 V_{data} , 经过 DBSCAN 聚类算法处理后的结果记为 D_{data} 。数据处理流程图如图 7 所示。

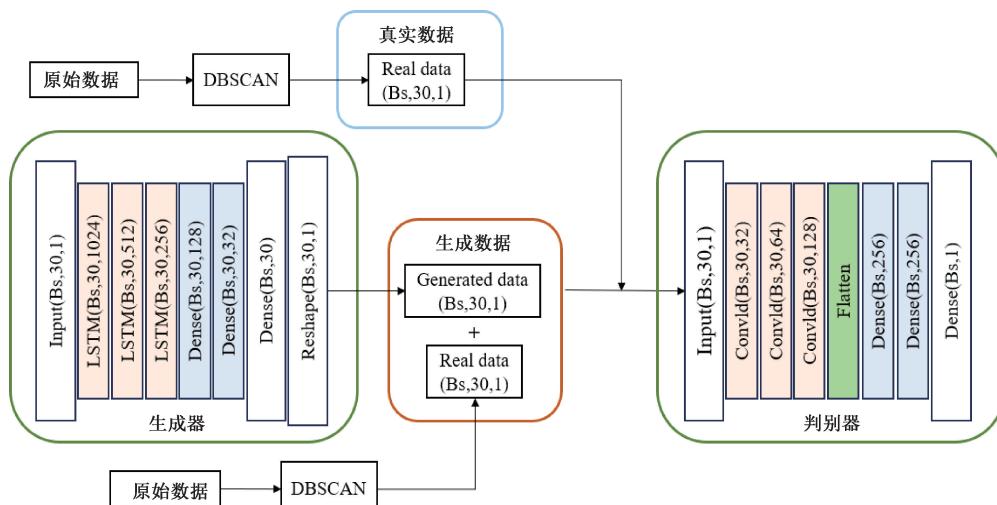


图 5 LSTM-WGAN 模型框架

Fig. 5 LSTM-WGAN model framework

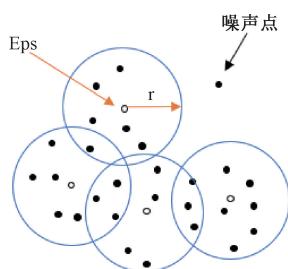


图 6 DBSCAN 原理

Fig. 6 DBSCAN principle diagram

2.2 长短期记忆网络

LSTM 属于一种递归神经网络,是循环神经网络(recurrent neural network, RNN)的变体^[16]。LSTM 利

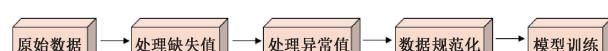


图 7 数据处理流程

Fig. 7 Data processing flowchart

用在网络中加入门结构和记忆细胞的方法,解决了普通 RNN 在训练过程中引起的梯度爆炸与梯度消失的问题,从而能在较长序列中表现良好^[17]。模型使用 LSTM 捕捉气井历史数据与未来投放柱塞泡排策略的依赖关系。将 D_{data} 送入 LSTM 网络进行处理,LSTM 根据其数据分布特点生成具有相同分布的数据。经过 LSTM 处理后的数据记为 L_{data} ,即:

$$L_{data} = LSTM(D_{data}) \quad (1)$$

将 L_{data} 送入 WGAN 网络中进行判别, 即:

$$D(G(z)) = D(L_{data}) \quad (2)$$

2.3 Wasserstein 生成对抗网络

GAN 网络是基于博奕论的思想, 由生成器 G 与判别器 D 两个模型网络组成。判别器 D 的作用是学会判断一个样本是来自模型分布还是数据分布。生成器 G 试图制造假样本并在未被发现的情况下使用它, 而判别器 D 试图检测出假样本。通过生成器 G 与判别器 D 的相互对抗驱使它们改进各自的方法, 直到假样本与真样本无法区分。WGAN 中引入了 Wasserstein 距离来代替 JS(Jensen-Shannon) 和 KL(Kullback-Leibler) 发散, 以解决 GAN 网络中生成器的梯度消失问题和网络训练不稳定的情况。与 GAN 相比, WGAN 模型显著提高了网络模型稳定性, 降低了模型崩溃的风险^[18]。将 WGAN 的函数定义为:

$$V_w = E_{x \sim P_{data}}[f_w(x)] - E_{z \sim P_z}[f_w(g_\theta(z))] \quad (3)$$

其中, w 和 θ 是对应的参数, 当函数 V_w 最大时, 可以采用它来模拟生成样本分布到实际样本分布的 W 距离, 通过不断训练将其最小化, 从而缩小生成样本和实际样本之间的差距, $x \sim P_{data}$ 指样本中采样的真实数据, z 是隐含层中的向量, $z \sim P_z$ 指生成随机噪声。将真实的油套压差和水气比数据传入 $x \sim P_{data}$ 中, LSTM 接收噪声向量 z 作为输入, 并通过网络结构转换, 生成尽可能接近真实的油套压差、水气比分布的数据 L_{data} 。将 $x \sim P_{data}$ 和 L_{data} 传入判别器 D 中进行区分判别。

2.4 LSTM-WGAN 模型

基于以上理论, 本文构建了一个 LSTM-WGAN 深度学习模型。LSTM-WGAN 网络模型利用 WGAN 网络的数据生成能力和 LSTM 对时序数据前后依赖关系的分析能力, 可对气井油套压差和水气比数据进行预测, 解决了投放泡排柱塞频率的问题。基于该模型的预测控制流程如图 8 所示。数据在模型中训练步骤如下: 首先输入现场井筒数据(油套压差、水气比), 然后使用 DBSCAN 处理数据中的异常值, 将异常值处理后的数据使用 Min-Max 法归一化, 利用 LSTM-WGAN 网络对训练集数据进行训练, LSTM-WGAN 预测模型测试数据得到预测结果, 最后通过智能管理系统执行模型预测结果做出相应的投放策略。

3 实验及结果分析

3.1 数据预处理

在本文研究中, 数据预处理是实现预测结果准确、可靠的关键步骤。这一阶段目的是通过一系列处理步骤来改善数据的质量, 使其适用于后续的分析和建模。

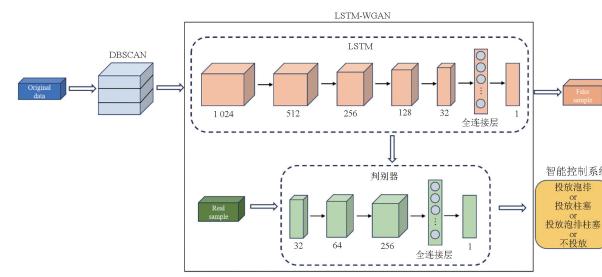


图 8 基于 LSTM-WGAN 的预测控制模型

Fig. 8 Predictive control model based on LSTM-WGAN

1) 缺失值处理

实验使用数据是长宁气田采集到的油压、套压、日产气和日产水等数据。现场采集信息时由于遗漏、无响应、或者任何其他的因素会导致采集到的数据出现缺失。缺失值会减少样本量并影响预测结果的质量, 需要在进行模型训练前对数据中的缺失值进行处理。数据中的缺失值如表 1 所示, 其中表中方框表示为缺失值。

表 1 实验数据及缺失值

Table 1 Experimental data and missing values

| 日期 | 套压 | 油压 | 日产气 | 日产水 |
|------------|------|------|------|------|
| 2020/10/27 | 8.60 | 1.61 | 0.51 | 2.00 |
| 2020/10/28 | 8.61 | 1.61 | 0.53 | 1.00 |
| 2020/10/29 | 8.61 | 3.80 | 0.23 | 2.00 |
| 2020/10/30 | 8.64 | 5.15 | 0.19 | 2.00 |
| 2020/10/31 | 8.71 | 5.07 | 0.21 | 1.00 |
| 2020/11/1 | — | — | 0.22 | 1.00 |
| 2020/11/2 | 8.88 | 3.78 | 0.74 | 1.00 |
| 2020/11/3 | 8.89 | 1.87 | 0.87 | 1.00 |
| 2020/11/4 | 8.90 | 1.68 | 0.38 | 2.00 |
| 2020/11/5 | 8.90 | 1.57 | 0.20 | 1.00 |

为保证数据的连续性, 实验采用平均值法填充, 计算缺失值前后 5 d 数据的平均值进行填充, 排除缺失值对实验结果的影响, 最后计算数据的油套压差和水气比值。

2) 异常值处理

现场采集油压、套压、日产气、日产水等数据时, 会因为传感器的不稳定或者其他不确定因素而使采集到的数据和真实数据出现明显的误差, 从而影响预测的准确性。数据中的异常值如表 2 所示, 其中框中的数字为异常值。

实验采用 DBSCNA 算法检测数据集中的异常值。实验中分别对训练集、测试集数据进行了异常值的检测。图 9 展示了对数据集的异常值检测效果。

3) 归一化处理

将异常值处理后的油套压差和水气比采用 Min-Max 方法进行归一化处理。其中, X_{max} 为数据的最大值, X_{min} 为数据的最小值, X^* 为归一化后的数据。归一化处理使

表 2 实验数据及异常值

Table 2 Experimental data and outliers

| 日期 | 套压 | 油压 | 日产气 | 日产水 |
|-----------|-------|------|------|-------|
| 2017/5/2 | 8.94 | 4.91 | 4.26 | 10.00 |
| 2017/5/3 | 8.87 | 5.02 | 4.14 | 9.00 |
| 2017/5/4 | 8.76 | 4.83 | 4.20 | 8.00 |
| 2017/5/5 | 8.83 | 4.66 | 4.31 | 10.00 |
| 2017/5/6 | 8.80 | 4.58 | 4.51 | 10.00 |
| 2017/5/7 | 29.30 | 4.70 | 4.50 | 9.00 |
| 2017/5/8 | 8.77 | 4.57 | 4.41 | 9.00 |
| 2017/5/9 | 8.70 | 4.58 | 4.39 | 9.00 |
| 2017/5/10 | 8.70 | 4.46 | 4.31 | 11.00 |
| 2017/5/11 | 8.63 | 4.63 | 4.42 | 10.00 |

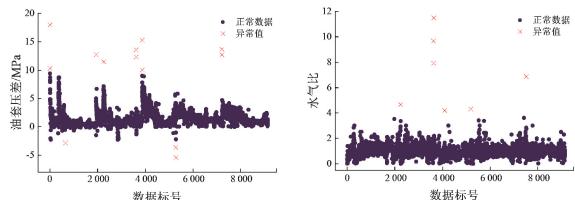
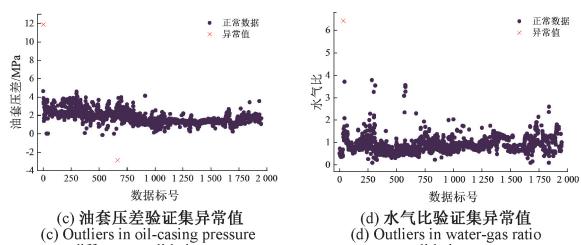
(a) 油套压差训练集异常值
(a) Outliers in oil-casing pressure difference training set

图 9 异常值检测效果

Fig. 9 Effectiveness of outlier detection

数据归一化到 $[0, 1]$ 区间内, 减小数据因素对预测模型精度的影响。

$$X^* = \frac{X - X_{\min}}{X_{\max} - X_{\min}} \quad (4)$$

3.2 实验模型和评价指标

为了比较不同模型的预测性能, 实验采用均方误差 (MSE)、平均绝对误差 (MAE) 和均方根误差 (RMSE) 对实验结果进行评估, MSE、MAE 和 RMSE 的值越小, 模型预测准确性越高, 预测值与真实值的差距越小^[19]。

选取了 2 种预测模型 (GAN^[20]、LSTM^[21]) 与 LSTM-WGAN 进行对比, 以测试 LSTM-WGAN 模型的预测能力。3 种模型实验的相关参数如表 3 所示。

3.3 实验结果与分析

为了验证本文提出的 LSTM-WGAN 预测模型的预测能力, 将 LSTM-WGAN 与 GAN 模型和 LSTM 模型进行对比。油套压差实验结果如图 10 所示, 水气比实验结果如图 11 所示。

表 3 3 种模型相关参数

Table 3 Relevant parameters of three models

| 参数/模型 | GAN/LSTM/LSTM-WGAN |
|----------|--------------------|
| 时间步长 | 30 |
| 预测步长 | 1 |
| 隐藏层数 | 5 |
| 学习率(生成器) | 0.000 2 |
| 学习率(判别器) | 0.000 1/0.000 1/- |
| Epoch | 150 |
| 批次大小 | 16 |

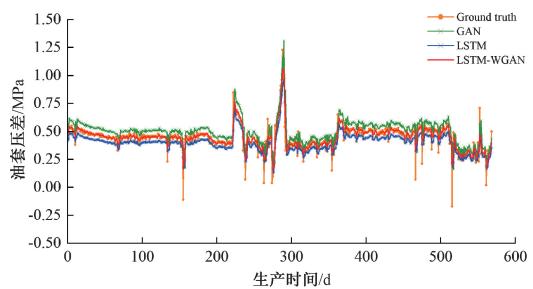


图 10 油套压差预测值

Fig. 10 Predicted tubing pressure difference

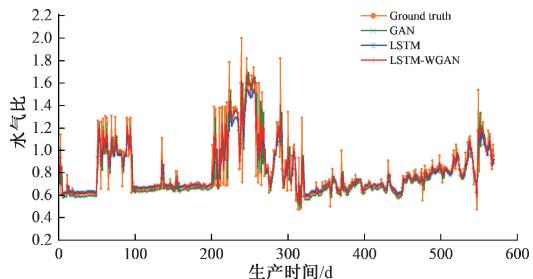


图 11 水气比预测值

Fig. 11 Predicted water-gas ratio

此外, 表 4 和 5 为 LSTM-WGAN 与其他两种模型的评价指标量化对比。所提模型的评价指标相比其他两种单一模型的评价指标较小, 这是由于 GAN 采用 JS 发散, 计算复杂程度低于 Wasserstein 距离, 相较于 LSTM-WGAN, GAN 的收敛速度更快, 但生成数据质量更低; LSTM 的计算复杂程度同样低于 LSTM-WGAN, 但难以处理数据分布不平衡的气井数据, 容易出现过拟合问题。结果表明所提预测模型可利用其基线模型的优势来提高预测精度。

表 4 油套压差结果评价指标对比

Table 4 Comparison of evaluation metrics for tubing pressure difference results

| 神经网络模型 | RMSE | MSE | MAE |
|-----------|----------|----------|----------|
| GAN | 0.086 36 | 0.007 46 | 0.068 62 |
| LSTM | 0.066 94 | 0.004 48 | 0.066 12 |
| LSTM-WGAN | 0.065 17 | 0.004 25 | 0.047 45 |

表5 水气比结果评价指标对比

Table 5 Comparison of evaluation metrics for water-gas ratio results

| 神经网络模型 | RMSE | MSE | MAE |
|-----------|----------|----------|----------|
| GAN | 0.156 76 | 0.024 57 | 0.085 54 |
| LSTM | 0.126 40 | 0.015 98 | 0.074 59 |
| LSTM-WGAN | 0.115 26 | 0.014 69 | 0.069 67 |

综上所述,将LSTM-WGAN与次优模型相对比,油套压差的RMSE、MSE、MAE分别平均降低了2.64%、5.13%、11.75%,水气比的RMSE、MSE、MAE分别平均降低了8.81%、8.07%、6.60%。这也进一步验证了本文方法的有效性。

表6 3种模型预测油套压差和水气比的评价指标对比

Table 6 Comparison of evaluation indicators of three models for predicting oil-casing pressure difference and water-gas ratio

| 模型 | 评价指标(RMSE) | | | | | | | | | | 总体 |
|------|------------|----------|----------|----------|----------|----------|----------|----------|----------|----------|----------|
| | 第1天 | 第2天 | 第3天 | 第4天 | 第5天 | 第6天 | 第7天 | 第8天 | 第9天 | 第10天 | |
| 油套压差 | A | 0.065 17 | | | | | | | | | 0.065 17 |
| | B | 0.066 72 | 0.071 23 | 0.079 27 | 0.092 32 | 0.103 44 | | | | | 0.082 60 |
| | C | 0.065 27 | 0.070 22 | 0.082 01 | 0.090 21 | 0.097 82 | 0.103 12 | 0.109 92 | 0.117 64 | 0.130 97 | 0.143 44 |
| 水气比 | A | 0.115 26 | | | | | | | | | 0.115 26 |
| | B | 0.114 82 | 0.129 84 | 0.144 29 | 0.159 76 | 0.164 69 | | | | | 0.142 68 |
| | C | 0.115 39 | 0.127 83 | 0.146 27 | 0.160 03 | 0.164 38 | 0.162 20 | 0.172 92 | 0.176 30 | 0.181 02 | 0.183 41 |
| | | | | | | | | | | | 0.158 98 |

3种LSTM-WGAN模型在测试集上的表现,如图12、13所示。A模型预测油套压差和水气比的值最接近真实数据,B模型表现稍差于A模型,C模型只能预测油套压差和水气比的大致走势。结果表明随预测时间延长,模型的整体预测精度会降低。

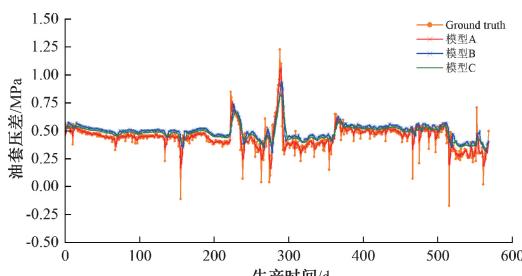


图12 不同预测时长LSTM-WGAN模型预测油套压差表现

Fig. 12 LSTM-WGAN model with different prediction time predicts the performance of oil-casing pressure difference

3.5 “关井时间”对LSTM-WGAN模型精度的影响

引入“关井时间”变量,表示当天下生产后连续关井的天数。加入“关井时间”变量后,剔除关井期间的静态数据,防止非生产时段的恒定参数影响模型预测的准确性。

3.4 不同预测时长的LSTM-WGAN模型对比

随机选取1200组数据为测试集。使用LSTM-WGAN模型建立基于30 d数据预测1 d的油套压差和水气比(A模型)、基于30 d数据预测5 d的油套压差和水气比(B模型)、基于30 d数据预测10 d的油套压差和水气比(C模型),3种模型对未来1~10 d预测结果的评价指标如表6所示。随预测天数增加,同一模型的评价指标在逐渐增大。在预测未来1 d时,A、B、C模型的评价指标相近。在预测未来1~5 d时,B、C模型的评价指标相近,并且RMSE随预测时间增加而增大,表明模型的预测精度会随预测天数的增加而降低;在预测同一天时,A、B、C模型的精度近似,但总体A模型预测效果最好。

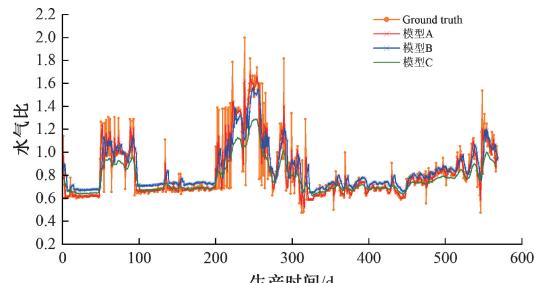


图13 不同预测时长LSTM-WGAN模型预测水气比表现

Fig. 13 LSTM-WGAN model with different prediction time predicts the performance of water-gas ratio

本研究选择了存在关井现象前15 d和开井当天的生产数据,并分别对比LSTM-WGAN模型加入和未加入“关井时间”变量预测开井当天油套压差、水气比数据与开井当天真实数据的差异,以验证加入“关井时间”后对LSTM-WGAN模型预测能力的影响,结果显示加入“关井时间”后模型的预测精度得到提高,如图14所示。

3.6 柱塞-泡排复合排采智能管理系统

开发了网络页岩气水平井柱塞-泡排复合排采智能管理系统,利用LSTM-WGAN预测控制模型由采集的

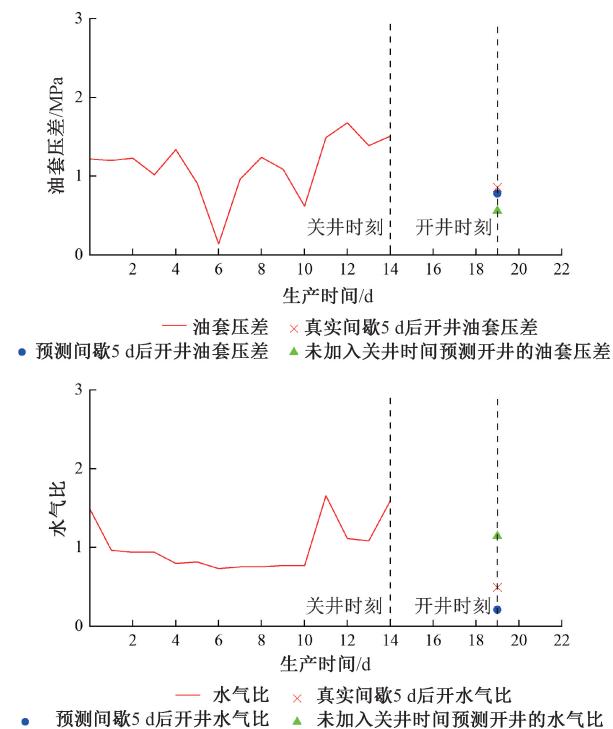


图 14 关井时间变量对 LSTM-WGAN 模型预测精度的影响

Fig. 14 Effect of the well shutdown time variable on the prediction accuracy of the LSTM-WGAN model

气井数据实时预测油套压差和水气比值, 动态监测井底积液的变化趋势。智能管理系统根据 LSTM-WGAN 模型的预测结果, 与投放依据作比较并发出相应的控制信号。

投放泡排柱塞依据如表 7 所示, 其中 T_1, T_2, T_3, T_4 为水气比阈值, $T_1 > T_2 > T_3 > T_4$; G_1, G_2, G_3 为油套压差阈值, $G_1 < G_2 < G_3$ 。

表 7 泡排柱塞投放依据

Table 7 Indicators for foam ball and plunger deployment

| 指标 | 操作 | 信号 |
|-------------------------------------|---------|----|
| 水气比 $\geq T_1$ | 不投放 | 00 |
| 水气比 $\leq T_2$, 油套压差 $\approx G_1$ | 投放泡排 | 01 |
| 水气比 $\leq T_3$, 油套压差 $\approx G_2$ | 投放柱塞 | 10 |
| 水气比 $\leq T_4$, 油套压差 $\approx G_3$ | 投放泡排和柱塞 | 11 |

智能管理系统控制界面如图 15 所示。

系统包括设备状态显示、数据图像显示和按钮控制部分。在自动模式中, 智能管理系统通过 LSTM-WGAN 模型判断预测的油套压差和水气比结果, 智能决策柱塞-泡排投放措施, 实现柱塞-泡排的全自动化投放。同时, 在手动模式下, 手动选择实现投放泡排、柱塞和添加泡排球等操作。在图像显示部分, 实时更新油套压差、水气比走势和模型预测结果以及柱塞-泡排投放状态。图 15 展

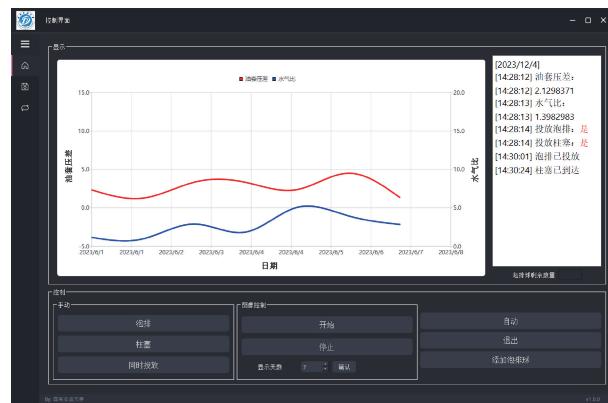


图 15 智能管理系统控制界面

Fig. 15 Intelligent management system control interface

示了智能管理系统根据模型预测结果控制柱塞-泡排复合排采系统同时投放泡排和柱塞, 并反馈泡排投放和柱塞到达状态。

4 结 论

针对单一排采工艺适应性差, 排采措施次数频繁的难题, 设计了一套页岩气水平井柱塞-泡排复合排采智能举升系统, 利用二者优势高效排除气井井底积液。针对该系统的泡排球和柱塞投放频率问题, 提出了一种基于 LSTM-WGAN 预测模型, 优化了 LSTM 模型对油套压差和水气比走势的捕捉能力, 解决了单一模型在处理长序列时的全局建模和多维向量间复杂交互关系不足的问题。通过在长宁气田数据上的验证, 模型准确地预测出油套压差和水气比的变化幅度, 所提出的网络框架显示出强大的泛化能力。同时将所提出的基于 LSTM-WGAN 井底积液预测控制模型与 LSTM 和 GAN 模型进行对比, 表明所提出的模型在井底积液预测方面具有更好的性能。但是, LSTM-WGAN 模型训练过程中仍然存在生成器和判别器之间不稳定问题, 尤其是在较为复杂的时间序列数据上。未来的研究将集中在设计更稳健的损失函数, 以及采用更高效的训练策略, 以加速收敛并减少模型训练不稳定现象。

参考文献

- [1] FADAIRO A, OLUGBENGA F, SYLVIA N C. A new model for predicting liquid loading in a gas well [J]. Journal of Natural Gas Science and Engineering, 2015, 26: 1530-1541.
- [2] 熊钰, 刘斌, 徐文龙, 等. 两种准确预测低渗低产气井积液量的简易方法 [J]. 特种油气藏, 2015, 22(2): 93-96, 155.
- XIONG Y, LIU B, XU W L, et al. Two simple methods

- to accurately predict the amount of liquid accumulation in low-permeability and low-yield gas wells [J]. Special Oil & Gas Reservoirs, 2015, 22(2): 93-96,155.
- [3] 段进贤. 分体式柱塞举升技术研究与应用 [D]. 成都: 西南石油大学, 2013.
- DUAN J X. Research and application of split plunger lifting technology [D]. Chengdu: SouthWest Petroleum University, 2013.
- [4] 周宇驰. 柱塞排水采气工艺模拟与优化 [D]. 成都: 西南石油大学, 2015.
- ZHOU Y CH. Simulation and optimization of plunger drainage gas production process [D]. Chengdu: SouthWest Petroleum University, 2015.
- [5] 黄伟明, 王尊策, 张洪涛, 等. 气井分体式柱塞优化设计及实验研究 [J]. 化工机械, 2020, 47 (5): 668-673.
- HUANG W M, WANG Z C, ZHANG H T, et al. Optimization design and experimental study of split plunger for gas wells [J]. Chemical Engineering & Machinery, 2020, 47(5): 668-673.
- [6] 宋汉华, 宋勘, 刘丹丹, 等. 一种远程自动投放球形泡排药剂装置的研制及应用 [J]. 石油钻采工艺, 2014, 36(5): 124-127.
- SONG H H, SONG J, LIU D D, et al. Development and application of a remote automatic spherical foaming agent device [J]. Oil Drilling & Production Technology, 2014, 36(5): 124-127.
- [7] 田雨露, 王纪伟, 李加玉. 泡沫排水用起泡剂的应用进展 [J]. 油田化学, 2021, 38(2): 368-373.
- TIAN Y L, WANG J W, LI J Y. Application progress of foaming agents for foam drainage [J]. Oilfield Chemistry, 2021, 38(2): 368-373.
- [8] 李萍, 吉勇, 熊杰, 等. BP 神经网络补偿算法在煤层气井产量预测中的应用 [J]. 中国煤层气, 2016, 13(5): 39-43.
- LI P, JI Y, XIONG J, et al. Application of BP neural network compensation algorithm in coalbed methane well production prediction [J]. China Coalbed Methane, 2016, 13(5): 39-43.
- [9] CALVETTE T, GURWICZ A, ABREU A C, et al. Forecasting smart well production via deep learning and data driven optimization [C]. OTC Brasil OnePetro, 2019.
- [10] LEE K, LIM J, YOON D, et al. Prediction of shale-gas production at Duvernay formation using deep-learning algorithm [J]. SPE Journal, 2019, 24(6): 2423-2437.
- [11] 祝启康, 林伯韬, 杨光, 等. 低压低产页岩气井智能生产优化方法 [J]. 石油勘探与开发, 2022, 49(4): 770-777.
- ZHU Q K, LIN B T, YANG G, et al. Intelligent production optimization method for a low pressure and low productivity shale gas well [J]. Petroleum Exploration and Development, 2022, 49(4): 770-777.
- [12] ZHAN CH, SANKARAN S, LEMOINE V, et al. Application of machine learning for production forecasting for unconventional resources [C]. Unconventional Resources Technology Conference, 2019.
- [13] KOCOGLU Y, GORELL S, MCELROY P. Application of Bayesian optimized deep Bi-LSTM neural networks for production forecasting of gas wells in unconventional shale gas reservoirs [C]. Unconventional Resources Technology Conference, 2021.
- [14] SONG X Y, LIU Y T, XUE L, et al. Time-series well performance prediction based on long short-term memory (LSTM) neural network model [J]. Journal of Petroleum Science and Engineering, 2020, 186: 106682.
- [15] 彭永志, 肖靖, 毛建旭, 等. 一种基于 DBSCAN 随机圆检测的多瓶口定位算法 [J]. 电子测量与仪器学报, 2021, 35(6): 43-52.
- PENG Y ZH, XIAO J, MAO J X, et al. A multi-bottle mouth positioning algorithm based on DBSCAN random circle detection [J]. Journal of Electronic Measurement and Instrumentation, 2021, 35(6): 43-52.
- [16] 何静, 高见, 张昌凡. 集成自适应变异混沌松鼠搜索和 LSTM 算法的 RUL 预测方法及应用 [J]. 电子测量与仪器学报, 2023, 37(5): 88-97.
- HE J, GAO J, ZHANG CH F. RUL prediction method and application based on integrated adaptive mutation chaotic squirrel search and LSTM algorithm [J]. Journal of Electronic Measurement and Instrumentation, 2023, 37(5): 88-97.
- [17] 魏玮, 吕游, 齐欣宇, 等. 基于 CNN-LSTM-AM 动态集成模型的电站风机状态预测方法 [J]. 仪器仪表学报, 2023, 44(4): 19-27.
- WEI W, LYU Y, QI X Y, et al. Power plant wind turbine state prediction method based on CNN-LSTM-AM dynamic integration model [J]. Chinese Journal of Scientific Instrument, 2023, 44(4): 19-27.
- [18] 李可, 魏琦, 武志高, 等. 一种基于生成对抗域的长短期记忆网络系统剩余寿命预测方法 [J]. 系统工程, 2024, 42(5): 131-141.
- LI K, WEI Q, WU ZH G, et al. A remaining life prediction method for long short-term memory network

- system based on generative adversarial domain [J]. Systems Engineering, 2024, 42(5) : 131-141.
- [19] 鹿晨东, 许英朝, 张帆, 等. 基于生成对抗网络的太阳辐照度预测模型 [J]. 厦门理工学院学报, 2023, 31(5) : 17-24.
LU CH D, XU Y CH, ZHANG F, et al. Solar irradiance prediction model based on generative adversarial network[J]. Journal of Xiamen University of Technology, 2023, 31(5) : 17-24.
- [20] LIN H CH, CHEN CH, HHUANG G F, et al. Stock price prediction using generative adversarial networks [J]. Journal of Computer Sciences, 2021, 17(3) : 188-196.
- [21] XI X, CHEN M, ZHOU D. Remaining useful life prediction for multi-component systems with hidden dependencies [J]. Science China Information Sciences, 2019, 62(2) : 57-72.

作者简介



赖欣(通信作者), 目前是西南石油大学机电工程学院教授, IEEE Senior Member, 主要研究领域为油气智能测控、状态估计与三维重建。

E-mail: xinlai06@163.com

Lai Xin (Corresponding author) is currently a professor with the School of Mechanical and Electrical Engineering, Southwest Petroleum University, IEEE senior Member. Her main research interests include intelligent measurement and control of oil & gas, state estimation and 3D reconstruction.