



DOI:10.12404/j.issn.1671-1815.2404595

引用格式:何志强,陈界学,谭健,等.改进时空图神经网络的储气库井筒温度预测[J].科学技术与工程,2025,25(15):6304-6309.

He Zhiqiang, Chen Jie-xue, Tan Jian, et al. Gas storage wellbore temperature prediction based on advanced spatiotemporal graph convolutional neural networks[J]. Science Technology and Engineering, 2025, 25(15): 6304-6309.

## 改进时空图神经网络的储气库井筒温度预测

何志强<sup>1</sup>, 陈界学<sup>1</sup>, 谭健<sup>1</sup>, 尹爱军<sup>2\*</sup>, 何泉<sup>2</sup>

(1. 中国石油天然气股份有限公司西南油气田分公司重庆气矿, 重庆 400021; 2. 重庆大学机械与运载工程学院, 重庆 400044)

**摘要** 在天然气储气站点,异常井筒温度将严重影响储气作业过程,准确地预测井筒温度对于提升作业过程的安全性具有重要意义。在作业过程关联参数分析的基础上,提出了改进时空图卷积神经网络(advanced spatiotemporal graph convolutional neural network, A-SGCN)的储气库井筒温度预测方法。A-SGCN 分别通过 GCN 和长短期记忆网络(long short term memory network, LSTM)进行空间依赖性建模和时间依赖性建模,结合自适应残差注意力机制有效捕捉时空数据之间的复杂关系,最终实现对温度的准确预测。方法的有效性通过黄草峡储气库2号注采站进行了验证,通过草储1井与草储6井的关联监测参数实现了对草储1井井口温度的准确预测。

**关键词** 天然气; 储气库; 井筒; 温度预测; 图卷积神经网络  
**中图分类号** TE978 TP183; **文献标志码** A

### Gas Storage Wellbore Temperature Prediction Based on Advanced Spatiotemporal Graph Convolutional Neural Networks

HE Zhi-qiang<sup>1</sup>, CHEN Jie-xue<sup>1</sup>, TAN Jian<sup>1</sup>, YIN Ai-jun<sup>2\*</sup>, HE Quan<sup>2</sup>

(1. Chongqing Gas Field, PetroChina Southwest Oil and Gas Field Company, Chongqing 400021, China;  
2. College of Mechanical and Vehicle Engineering, Chongqing University, Chongqing 400044, China)

**[Abstract]** Gas storage operations can be significantly impacted by abnormal wellbore temperatures at natural gas storage sites. Accurately predicting wellbore temperatures is of paramount importance for enhancing the safety and efficiency of these operations. Based on the analysis of operational parameter correlations, a gas storage wellbore temperature prediction method was proposed using advanced spatiotemporal graph convolutional neural network (A-SGCN). Both GCN and long short-term memory (LSTM) networks were employed by A-SGCN to capture spatial and temporal dependencies, respectively. Based on this framework, an adaptive residual attention mechanism was incorporated to effectively capture the intricate relationships between spatiotemporal data, ultimately enabling accurate temperature prediction. The effectiveness of the method is validated through its application at the Huangcaoxia gas storage No. 2 injection-production station. Accurate prediction of wellhead temperature at Well No. 1 is achieved through the association of monitoring parameters between Well No. 1 and Well No. 6.

**[Keywords]** natural gas; gas storage; wellbore; temperature prediction; graph convolutional neural network

天然气被广泛应用于供热、工业生产和发电等领域,其有效开采和处理对于能源行业至关重要<sup>[1-2]</sup>。在天然气储气作业过程中,井筒温度是关键参数,直接影响着生产效率与安全性。开展储气库井筒温度预测研究对于提升作业过程管控的有效性具有重要意义<sup>[3]</sup>。

现有针对天然气生产过程的作业参数预测研究整体可分为三类,即基于理论参数预测、基于化工过程仿真的参数预测和基于数据驱动的参数预测<sup>[4-6]</sup>。基于理论参数预测方法建模泛用性较

差,通常辅助用于仿真建模<sup>[7]</sup>。基于化工过程仿真的参数预测方法结合设备参数和工艺参数进行作业过程仿真建模,通过优化模型进行温度、压力等关键参数的预测,如 Aspen HYSYS<sup>[8]</sup>。此类方法的局限性在于天然气生产过程复杂、工艺参数多样,难以通过仿真过程进行准确表征。

基于数据驱动的参数预测方法通过海量历史数据挖掘工艺参数间隐含的关联逻辑实现关键参数的准确预测,常用预测方法有高斯过程回归(gaussian process regression, GPR)、长短期记忆网络

收稿日期:2024-06-19 修订日期:2024-11-24

基金项目:国家重点研发计划(2023YFB3406101)

第一作者:何志强(1969—),男,汉族,四川蓬溪人,高级工程师。研究方向:油气储运作业过程可靠性。E-mail:hezq@petrochina.com.cn。

\*通信作者:尹爱军(1978—),男,汉族,湖南邵阳人,博士,教授。研究方向:可靠性与健康管。E-mail:aijun.yin@cqu.edu.cn。

(long short term memory, LSTM)、极端梯度提升(extreme gradient boosting, XGBoost)、卷积神经网络(convolutional neural networks, CNN)等<sup>[9-12]</sup>。基于数据驱动的参数预测方法对作业过程先验知识的要求较低,通过大量样本的训练过程不断优化模型参数实现对目标参数时间序列特性和与其他参数间关联性的准确表征,在天然气生产工艺过程作业参数预测领域得到了广泛研究<sup>[13]</sup>。

现有针对储气库注采井井筒参数的预测研究主要基于理论研究和化工过程仿真。王建军等<sup>[14]</sup>基于流体力学质量守恒、能量守恒等理论进行了气体压强、温度、密度和流速的耦合分析和井筒温度场预测,该方法需对应用站点进行深度理论过程分析,通用性较差。于洋等<sup>[15]</sup>基于 Moody 摩阻系数计算理论和 PIPESIM 模拟软件进行了注采井井筒压力与温度的预测,但该方法仅适用于稳态过程的模拟。乔志杰等<sup>[16]</sup>研究了基于数据驱动的井筒温度和压力梯度预测方法,但未充分考虑梯度消失问题。

针对现有储气库井筒温度预测方法的局限性,提出基于改进时空图卷积神经网络(advanced spatiotemporal graph convolutional neural network, ASGCN)的储气库井筒温度预测方法以提升预测方法的有效性和泛用性。A-SGCN 在 LSTM 的基础上融合自适应模块实现邻接矩阵的动态构建,同时优化残差注意力模块减缓了梯度消失。方法的有效性在黄草峡储气库进行了验证。

## 1 改进时空图神经网络的预测模型

### 1.1 图卷积神经网络

与传统神经网络相比, CNN 具有更好的序列数据处理能力。 CNN 的卷积操作可以进行滑动窗口的计算,通过滤波器和池化层进行特征提取,公式为

$$C(i, j) = \sum_m \sum_n I(i + m, j + n) K(m, n) \quad (1)$$

式(1)中:  $C$  为输出特征;  $I$  为输入;  $K$  为卷积核;  $(i, j)$  为输出特征图坐标;  $(m, n)$  为卷积核坐标。

CNN 的卷积操作可以有效地降低计算量同时保留空间结构信息。池化层则能够在不改变特征维度的同时减少运算量和提高鲁棒性。 CNN 在处理欧式空间数据时具有显著优势,但对于非欧式空间时难以实现“平移不变性”,而显示作业过程中的监测数据可能为非欧式空间结构,为此通过图神经网络(graph convolutional neural network, GCN)进行储气库井筒监测参数的特征提取。

GCN 中,图结构为  $G = (V, E)$ ,其中  $V$  表示节点的集合,  $v_i \in \{V | i = 1, 2, \dots, N\}$ ;  $E$  表示边的集合,  $(v_i, v_j) \in \{E | i, j = 1, 2, \dots, N\}$ 。依据边的指向特性可分为无向图和有向图。基于无向图,通过度矩阵  $D$  和邻接矩阵  $A$  分别表示节点的邻居数量和节点之间的连边。二者之间的关系为

$$D_{i,i} = \sum_j A_{i,j} \quad (2)$$

对于 GCN 的推导,首先定义图拉普拉斯矩阵  $L = UAU^T = F(A)$ ,  $A$  为一个对角矩阵,其对角线上的元素是  $L$  的特征值。以此为基础进行特征向量  $x$  的卷积操作( $*$ )为

$$g_\theta * x = U g_\theta(A) U^T x \quad (3)$$

式(3)中:  $g_\theta(A) = \theta_0 A^0 + \theta_1 A^1 + \dots + \theta_n A^n + \dots$ , 即  $U g_\theta U^T = g_\theta[F(A)]$ 。

结合切比雪夫多项式和设置简化卷积公式为

$$g_\theta * x = \tilde{D}^{-1/2} \tilde{A} \tilde{D}^{-1/2} X \Theta \quad (4)$$

式(4)中:  $X$  为输入特征矩阵;  $\Theta$  为学习的权重矩阵。

整体而言, GCN 是对图结构的数据进行卷积操作的实现,将图信号  $x$  和卷积核映射至谱域,在此基础上进行谱域内的线性计算。基于二阶切比雪夫多项式近似卷积核进行逐层传播,表达式为

$$H^{(n+1)} = \sigma(\tilde{D}^{-1/2} \tilde{A} \tilde{D}^{-1/2} H^{(n)} W^{(n)}) \quad (5)$$

式(5)中:  $\tilde{A} = A + I$ ,  $I$  为单位矩阵;  $\tilde{D}$  为  $\tilde{A}$  的度矩阵;  $H^{(n)}$ 、 $H^{(n+1)}$  和  $W^{(n)}$  分别每层的输入、输出和权重矩阵;  $\sigma$  为 Sigmoid 激活函数。

### 1.2 注意力与自适应改进

天然气生产等典型工业过程监测数据中可能存在的大量冗余信息可能对预测模型的有害影响。进行关键参数的预测建模时融合注意力机制能够减少对低质量信息的关注程度,以提升预测模型的效率和准确性。对于注意力机制,有

$$h_n = \text{att}[q_n, (K, V)] \\ = \sum_{j=1}^N \text{softmax}[s(q_n, k_j)] v_j \quad (6)$$

式(6)中:  $(K, V) = [(k_1, v_1), (k_2, v_2), \dots, (k_N, v_N)]$  ( $k \in \mathbf{R}^{N \times d_k}$ ,  $v \in \mathbf{R}^{N \times d_v}$ ) 表示  $N$  个输入数据;  $K, V$  分别为注意力计算过程中的键向量和值向量;  $Q$  为查询向量,  $q \in \mathbf{R}^{N \times d_k}$ ; 为注意力函数  $s(q_n, k_j)$ 。

注意力的具体实现过程是根据  $q$  与  $k$  的关系对  $v$  进行加权求和,其会在输出关键信息的同时涵盖所有值的信息。本文中所采用的自注意力机制依据输入数据本身映射出  $Q, K, V$ 。

在此基础上,本文融入残差注意力机制,分别对 LSTM 的隐藏状态和细胞状态进行打分,涉及对应的长期记忆和短期记忆。基于二者对隐藏状态进行加权求和,经过 tanh 函数激活后与隐藏状态相加以缓解注意力机制前期打分随机的情况。残差注意力机制的实现如图 1 所示。表达式为

$$H_{i,c}(x) = [1 + M_{i,c}(x)] * F_{i,c}(x) \quad (7)$$

式(7)中:  $M(x)$  通过最后的 tanh 激活函数得到的,其值在  $[0, 1]$  之间;  $F(x)$  为卷积网络的输出。

对于自适应问题,GCN 基于邻接矩阵提取节点信息,常规的实现方式为由空间或语义进行构建,但此类方法不适用于构建天然气作业过程特征的邻接矩阵。通过自适应模块实现天然气作业过程监测数据的关联性挖掘。自适应模块的实现基于控循环单元(gated recurrent unit,GRU)和注意力机

制。时间序列数据经过 GRU 层得到隐藏状态  $H = [h_1, h_2, \dots, h_n]$ ,  $n$  个隐藏状态中的最后一个涵盖了所有时刻的信息。基于  $h_n$  结合自注意力机制计算邻接矩阵,即

$$A = \text{softmax}\left(\frac{QK^T}{\sqrt{d}}\right) \quad (8)$$

式(8)中:  $Q$  和  $K$  为时间序列所映射出的矩阵;  $A(R^{N \times N})$  为计算得到的邻接矩阵。

### 1.3 基于改进时空图神经网络的参数预测

本文提出的 A-SGCN 参数预测方法实现过程如图 2 所示。模型包括自适应模块,时空图卷积模块和注意力模块。其中时空图卷积模块由 GCN 和 LSTM 组成。GCN 实现空间依赖性建模,LSTM 实现时间依赖性建模。注意力机制模块将 LSTM 输出的各个时刻的隐藏状态和细胞状态作为  $Q$ ,以 LSTM 的

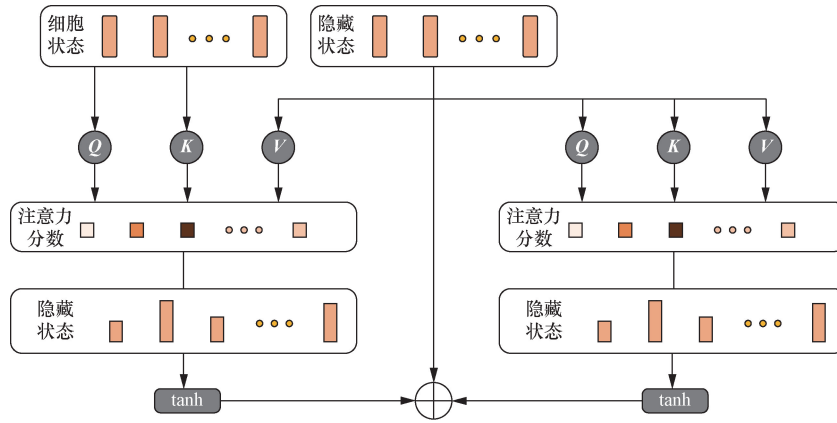


图 1 残差注意力的实现

Fig. 1 Realization of residual attention

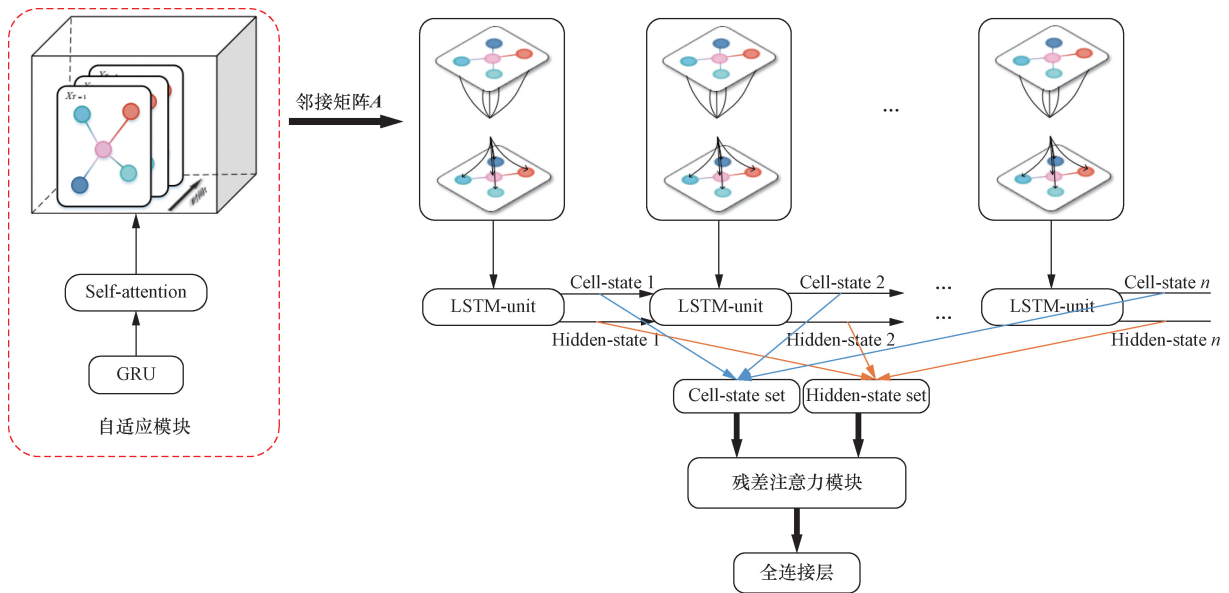


图 2 自适应时空图卷积神经网络

Fig. 2 Adaptive spatiotemporal graph convolutional neural networks

输出作为  $(K, V)$ , 对 LSTM 输出的时间信息按权重进行调整。

## 2 储气库井筒温度预测

### 2.1 站点概况

基于黄草峡 2 号注采站进行 A-SGCN 储气库井筒温度预测有效性验证。该站仅有草储 1 井和草储 6 井处于试运行状态,能获取实时监测参数,监测参数如表 1 所示,以草储 1 井计量温度为目标参数,涉及 7 个生产过程关联参数。监测数据涉及时间段为 2023 年 8—11 月,采样间隔为 30 min。

目标参数草储 1 井计量温度原始数据如图 3 所示。选取目标参数和关联参数监测时间段 80% 的数据作为模型训练样本,剩余 20% 数据为测试样本。

表 1 黄草峡储气库监测数据

编号	监测参数
目标参数 $X$	草储 1 井计量温度
关联参数 $F_1$	草储 1 井体积流量
关联参数 $F_2$	草储 1 井流速
关联参数 $F_3$	草储 1 井计量压力
关联参数 $F_4$	草储 6 井体积流量
关联参数 $F_5$	草储 6 井流速
关联参数 $F_6$	草储 6 井计量压力
关联参数 $F_7$	集注站来气压力




图 3 草储 1 井计量温度变化趋势

Fig. 3 Trend of measuring temperature in Caochu 1 well

### 2.2 数据预处理

为消除不同监测参数的量级差异,对参数进行标准化处理,将数据的范围映射到 0~1。线性归一化的公式为

$$x_{norm}^i = \frac{x^i - x_{min}^i}{x_{max}^i - x_{min}^i} \quad (9)$$

式(9)中:  $x_{norm}^i$  为对第  $i$  个监测参数的数据  $x^i$  进行标准化处理的结果;  $x_{max}^i$  为第  $i$  个监测参数的最大值;

$x_{min}^i$  为第  $i$  个监测参数的最小值。

考虑到关联参数与目标参数在储气作业过程相关性的差异性,在进行后续预测建模前首先剔除无关参数。本文中依据随机森林方法进行关联分析,以基尼指数作为贡献度的量化表征。对表 1 中的 7 个关联参数的重要性排序如图 4 所示。根据重要性排序,剔除关联性较低的参数草储 6 井流速( $F_5$ ),选择其他 6 个参数进行后续预测模型的建立。




图 4 计量温度关联参数重要性排序

Fig. 4 Ranking the importance of temperature correlation parameters

### 2.3 预测模型的有效性验证

为凸显本文提出的基于 A-SGCN 的作业参数预测方法的优势,在测试集上与未涉及自适应优化的图卷积 LSTM 方法 (graph convolutional LSTM, GCLSTM) 进行对比,如图 5 所示。

集成了自适应和残差注意力模块的 A-SGCN 在井口温度预测结果上展现出更高的准确性,其预测曲线与实际数据曲线高度吻合,而 GCLSTM 模型在数据拟合和趋势捕捉方面则稍显逊色。这一结果表明,A-SGCN 模型的注意力与自适应改进能够对生产作业过程进行更为准确的表征。进一步将 A-SGCN 与主流预测方法进行对比,如图 6 所示。

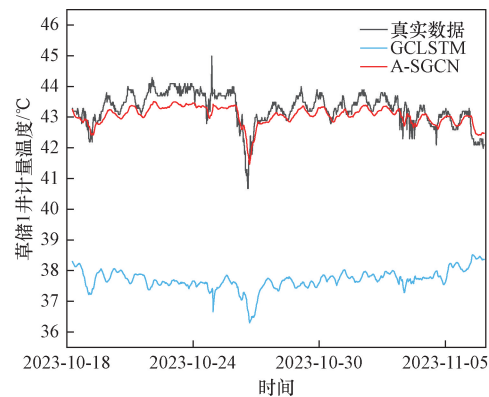


图 5 测试样本下的方法有效性验证

Fig. 5 Method validity verification under test sample

由图6可以看出,随机森林、支持向量机和XGBoost的预测结果波动范围较小,而井口温度测试样本的波动较大且有非常明显的数值变化,显示出它们在拟合数据变化趋势方面存在不足。当下预测时序数据最常用的LSTM能够较好地拟合数据变化趋势,但是对比LSTM预测数据与测试出数据发现预测偏差较大。相比之下,本文提出的A-SGCN预测结果不仅贴合真实值的趋势,而且在具体数值的预测上也展现出较高的精准度。为了进一步量化方法的预测精度,通过平均绝对误差(mean absolute error, MAE)、均方根误差(root mean square error, RMSE)和平均绝对百分比误差(mean absolute percentage error, MAPE)三种统计参数对测试样本下的预测结果进行量化对比,如表2所示。

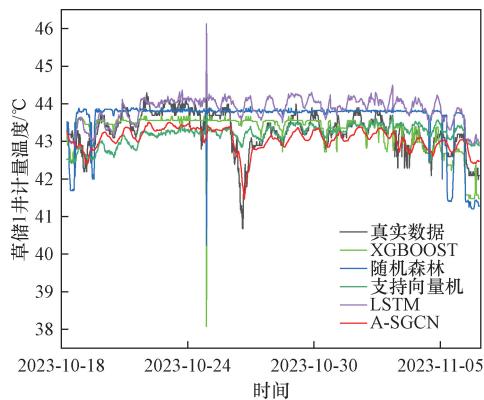


图6 A-SGCN与主流方法效果对比

Fig. 6 Comparison between A-SGCN and mainstream methods

表2 预测方法效果对比

Table 2 Comparison of prediction methods

方法	MAE	RMSE	MAPE
XGBOOST	0.014 33	0.022 24	0.016 38
随机森林	0.023 07	0.030 58	0.026 49
支持向量机	0.017 05	0.021 38	0.019 31
LSTM	0.024 86	0.030 65	0.028 43
GC-LSTM	0.238 51	0.239 95	0.268 21
A-SGCN	0.013 36	0.015 93	0.014 99

由表2可知,XGBoost、随机森林和支持向量机在预测精度上表现相对接近,且预测精度相对较高。结合图6可知,这三种方法的预测结果呈现出较为集中的趋势,其预测值大多接近测试样本的均值。即这三种方法在一定程度上忽略了数据的动态变化趋势,在时序数据预测场景中过度追求较小的预测误差显然是不可取的。与此相反,LSTM在拟合数据变化趋势方面表现出色,能够较好地捕捉数据的动态特性。但其在单个数据点的预测值与真实值之间仍存在较明显的偏差。这可能是由于LSTM在处理复杂时序数据时,对于数据中的噪声

和异常值较为敏感,从而影响了其预测精度。

本文中提出的A-SGCN相比于以上方法,在预测精度和趋势拟合方面均表现出较好的性能。A-SGCN在保证较小预测误差的同时,能够准确地拟合数据的动态变化趋势,更为适应天然气储气站点作业过程对参数预测的要求。

### 3 结论

天然气储气井站计量温度对于作业过程的正常运行十分重要。井站各监测参数与计量温度存在一定的映射关系,为更加准确的预测计量温度,本文提出了A-SGCN天然气生产过程参数预测方法,在空间依赖性和时间依赖性建模的基础上融合自适应残差注意力机制实现关联参数与目标参数间时空数据复杂关系的有效捕捉。方法的有效性通过真实作业站点的井口温度预测进行了对比验证。

### 参考文献

- [1] 梁兵,董莎莎,任玉清,等. 基于随机优化算法的天然气管道运行优化研究综述[J]. 重庆理工大学学报(自然科学), 2024, 38(2): 226-235.  
Liang Bing, Dong Shasha, Ren Yuqing, et al. Research review of natural gas pipeline operation optimization based on stochastic optimization algorithm [J]. Journal of Chongqing University of Technology (Natural Science), 2024, 38(2): 226-235.
- [2] Zhang S J, Luo M, Qian H, et al. A review of valve health diagnosis and assessment: insights for intelligence maintenance of natural gas pipeline valves in China [J]. Engineering Failure Analysis, 2023, 153: 107581.
- [3] Ma S H, Wang H X, Lan W J, et al. Mechanical detection system for injection production string in oil and gas wells with high temperature and high pressure [J]. IEEE/ASME Transactions on Mechatronics, 2023, 28: 3241289.
- [4] 李增强,韩卓. 激波对天然气超音速低温脱水性能的影响[J]. 低温与超导, 2023, 51(8): 82-88.  
Li Zengqiang, Han Zhuo. Effect of shock wave on supersonic low temperature dehydration of natural gas [J]. Cryogenics and Superconductivity, 2023, 51(8): 82-88.
- [5] 殷雄,徐波,刘天尧,等. 考虑温压补偿的天然气管道自适应仿真方法[J]. 油气储运, 2024, 43(6): 710-719.  
Yin Xiong, Xu Bo, Liu Tianyao, et al. Adaptive simulation method of natural gas pipeline considering temperature and pressure compensation [J]. Oil and Gas Storage and Transportation, 2024, 43(6): 710-719.
- [6] Wang Q Y, Song Y H, Zhang X S, et al. Evolution of corrosion prediction models for oil and gas pipelines: from empirical-driven to data-driven [J]. Engineering Failure Analysis, 2023, 146: 107097.
- [7] 杨飞,邓琅,罗涛,等. 高压天然气井口降压分离装置设计与流场分析[J]. 钻采工艺, 2023, 46(5): 113-118.  
Yang Fei, Deng Lang, Luo Tao, et al. Design and flow field analysis of high-pressure natural gas wellhead drop separation device

- [J]. *Drilling & Production Technology*, 2023, 46(5): 113-118.
- [8] 范学君, 李巍, 李华山, 等. 海上平台三甘醇脱水装置故障分析及工艺优化[J]. *石油与天然气化工*, 2024, 53(1): 14-19.  
Fan Xuejun, Li Wei, Li Huashan, et al. Fault analysis and process optimization of triethylene glycol dehydration Unit on offshore platforms [J]. *Oil & Gas Chemical Industry*, 2024, 53(1): 14-19.
- [9] Marrel A, Iooss B. Probabilistic surrogate modeling by Gaussian process: a review on recent insights in estimation and validation [J]. *Reliability Engineering & System Safety*, 2024, 247: 110094.
- [10] 付子骏, 吴永明, 徐计. TD-LSTM-S 模型在二氧化碳浓度预测中的应用 [J]. *重庆理工大学学报(自然科学)*, 2023, 37(4): 192-199.  
Fu Zijun, Wu Yongming, Xu Ji. Application of TD-LSTM-S model in CO<sub>2</sub> concentration prediction [J]. *Journal of Chongqing University of Technology (Natural Science)*, 2023, 37(4): 192-199.
- [11] 熊伟, 何彦霖, 宋伟, 等. 极端梯度提升与随机森林融合的天然气露点预测方法 [J]. *装备环境工程*, 2022, 19(6): 133-140.  
Xiong Wei, He Yanlin, Song Wei, et al. Natural gas dew point prediction method based on extreme gradient lifting and random forest fusion [J]. *Equipment and Environmental Engineering*, 2022, 19(6): 133-140.
- [12] Al-Sabaei A M, Alhussian H, Abdulkadir S J, et al. Prediction of oil and gas pipeline failures through machine learning approaches: a systematic review [J]. *Energy Reports*, 2023, 10: 1313-1338.
- [13] Niu W T, Lu J L, Sun Y P, et al. A review of the application of data-driven technology in shale gas production evaluation [J]. *Energy Reports*, 2023, 10: 213-227.
- [14] 王建军, 曾祥俊, 贾善坡, 等. 储气库注采井井筒温度场预测与影响因素分析 [J]. *科学技术与工程*, 2022, 22(18): 7890-7902.  
Wang Jianjun, Zeng Xiangjun, Jia Shanpo, et al. Prediction of wellbore temperature field and analysis of influencing factors in gas storage injection-production wells [J]. *Science Technology and Engineering*, 2022, 22(18): 7890-7902.
- [15] 于洋, 李力民, 董宗豪, 等. 相国寺储气库注采井井筒温度压力预测 [J]. *石油管材与仪器*, 2019, 5(2): 35-38.  
Yu Yang, Li Limin, Dong Zonghao, et al. Temperature and pressure prediction of injection and production well in Xiangguosi Gas Storage [J]. *Petroleum Pipe & Instrument*, 2019, 5(2): 35-38.
- [16] 乔志杰, 田赤中. 基于大数据建模的井筒压力温度梯度预测 [J]. *信息技术与信息化*, 2021(1): 225-228, 231.  
Qiao Zhijie, Tian Chizhong. Wellbore pressure and temperature gradient prediction based on big data modeling [J]. *Information Technology and Informatization*, 2021(1): 225-228, 231.