

引用格式:官文洁,彭小龙,朱苏阳,等.基于改进LSTM神经网络的加密井产能预测研究:以川南中深层页岩气为例[J].油气藏评价与开发,2025,15(3):479-487.

GUAN Wenjie, PENG Xiaolong, ZHU Suyang, et al. Research on productivity prediction method of infilling well based on improved LSTM neural network: A case study of the middle-deep shale gas in South Sichuan[J]. Petroleum Reservoir Evaluation and Development, 2025, 15(3): 479-487.

DOI: 10.13809/j.cnki.cn32-1825/te.2025.03.015

# 基于改进LSTM神经网络的加密井产能预测研究

## ——以川南中深层页岩气为例

官文洁,彭小龙,朱苏阳,杨晨,彭真,马潇然

(西南石油大学油气藏地质及开发工程全国重点实验室,四川成都610500)

**摘要:**川南中深层页岩气开发过程中,常规油气藏工程方法,如裂缝扩展、应力诱导分析和数值模拟等研究过程使得加密井的预测工作繁重,且无法有效应对不同生产阶段的产能差异性,应用条件苛刻。为了快速且准确预测加密井产能,根据老井生产压力曲线呈趋势性“三段式”递减的特征,将剧烈下降期作为前期产水期,快速下降和缓慢下降期作为后期产气期两部分,采用优化速度快、具有自适应性和信息反馈机制的灰狼优化算法(GWO)对长短期记忆(LSTM)神经网络模型进行超参数择优,分别构建由GWO计算最优解确定隐含层神经元个数、丢包率和批次数的前、后期模型,通过损失曲线和性能指标曲线确定迭代次数,采用线性学习率热身的方法动态调整学习率,实现高速训练过程,形成分阶段的产量预测模型。实例研究表明:GWO优化的LSTM神经网络模型在预设学习率为0.002、迭代450次的条件下,短时间内能够快速实现收敛,最终性能指标达到0.923。GWO优化的LSTM神经网络模型与传统LSTM神经网络模型预测结果相比,前、后期平均绝对误差分别降低了1.290 m<sup>3</sup>/d和0.213×10<sup>4</sup> m<sup>3</sup>/d;与数值模拟拟合结果相比,产气量预测的平均绝对误差降低了0.24×10<sup>4</sup> m<sup>3</sup>/d。因此,改进后的LSTM神经网络模型在不同生产阶段的产能预测中表现出色,且对应阶段模型能够准确预测川南中深层页岩气加密井的产能变化,为加密井产能预测方法提供理论依据。

**关键词:**页岩气;加密井;神经网络;GWO;产能预测

中图分类号:TE328

文献标识码:A

## Research on productivity prediction method of infilling well based on improved LSTM neural network: A case study of the middle-deep shale gas in South Sichuan

GUAN Wenjie, PENG Xiaolong, ZHU Suyang, YANG Chen, PENG Zhen, MA Xiaoran

(State Key Laboratory of Oil and Gas Reservoir Geology and Exploitation, Southwest Petroleum University, Chengdu, Sichuan 610500, China)

**Abstract:** During the development of middle and deep gas reservoirs in South Sichuan, conventional reservoir engineering methods—such as fracture propagation, stress-induced analysis, and numerical simulation—render productivity prediction of infilling wells laborious and ineffective in addressing variations in production capacity across different production stages, with stringent application conditions. In order to quickly and accurately predict the production capacity of infilling wells, this study classifies the “three-stage” declining trend observed in the production pressure curves of existing wells into: (1) A drastic decline period, regarded as the initial water production stage; (2) a rapid decline period; and (3) a slow decline period, both considered part of the later gas production stage. The Grey Wolf Optimizer(GWO) algorithm, a fast optimization algorithm with adaptive capabilities and an information feedback mechanism, is applied for hyperparameter optimization of the Long Short-term Memory (LSTM) neural network. Two stage-specific models were constructed, with the number of hidden layer neurons, dropout rate, and batch size determined by the optimal solutions obtained via GWO. The number of iterations was selected

收稿日期:2024-06-27。

第一作者简介:官文洁(2000—),女,在读硕士研究生,主要从事石油领域人工智能算法研究。地址:四川省成都市新都区新都大道8号,邮政编码:610500。E-mail:13628038631@163.com

通信作者简介:彭小龙(1973—),男,博士,教授,博士生导师,主要从事油气及煤层气藏渗流理论和数值模拟、地质建模数模一体化和油气藏分子模拟研究。地址:四川省成都市新都区新都大道8号,邮政编码:610500。E-mail:peng\_xl@126.com

基金项目:国家自然科学基金项目“基于煤粉群运移动力学特征的煤层气-水-固耦合传质机理研究”(52104036);四川省自然科学基金项目“考虑纳米尺度效应与微纳跨尺度流动的煤层气临界解吸机制研究”(2023NSFSC0932)。

based on the loss curve and performance metric curve, while a linear warm-up strategy was used to dynamically adjust the learning rate, facilitating high-speed training and the formation of a staged productivity prediction model. Example studies show that the GWO-optimised LSTM neural network model achieves rapid convergence with a preset learning rate of 0.002 and 450 iterations, ultimately reaching a performance index of 0.923. Compared to the conventional LSTM neural network model, the average absolute errors during the early and later stages are reduced by 1.290 m<sup>3</sup>/d and 0.213 × 10<sup>4</sup> m<sup>3</sup>/d, respectively. Compared with numerical simulation fitting results, the average absolute error in gas production prediction is reduced by 0.24 × 10<sup>4</sup> m<sup>3</sup>/d. Therefore, the improved LSTM neural network model demonstrates excellent performance in capacity prediction across different production stages, and the stage-specific productivity variations in infilling wells within middle and deep shale gas reservoirs in South Sichuan. This provides a theoretical foundation for productivity prediction methods of infilling wells.

**Keywords:** shales gas; infilling well; neural networks; GWO; productivity prediction

页岩气的开发,需要通过大规模体积压裂来提高产量<sup>[1-2]</sup>。气藏中流动通道复杂,孔渗分布非均质性强,多重介质的多尺度耦合传质规律也较为复杂<sup>[3]</sup>。页岩气井的生产过程,通常要经历压裂液返排、初期高产、快速递减和中后期稳产4个阶段。每个阶段的流体多相多尺度传质机制差异较大,衰竭开发过程中,气井控制的储层改造体积(SRV)变化明显。即使采用压裂缝扩展-流体传质数值模拟方法预测产能,也会因为拟合多解性强、地质特征过于复杂致使难度加大<sup>[4]</sup>。

页岩气加密井产能的快速预测是评价页岩气井网加密是否合理的关键。针对广泛应用的气藏工程预测方法,其产能数值计算通常需开展裂缝扩展,应力诱导分析以及多相流数值模拟研究。赵金洲等<sup>[5]</sup>提出了考虑多重微观渗流的产能预测模型,以增加压后动态分析的准确性和可靠性;李泽沛等<sup>[6]</sup>提出三重介质模型的页岩气储层数值模拟方法,研究渗透率变化对产能的影响;张晨招<sup>[7]</sup>提出了三孔线性流模型,为页岩气多级压裂水平井提供了基于测试数据的产能预测。而页岩气渗流趋于稳定的时间较长,通常不用系统试井进行产能测试,尽管地质-工程一体化方法在流动描述上具有优越性,但由于页岩气地质特征比较复杂,且不同生产阶段产能差异较大,在实际应用中条件苛刻,准确性难以保证。

AI人工智能具有强大的自我学习能力和拟合能力,能够有效映射油气藏中的非线性关系<sup>[8]</sup>。常规的BP神经网络无法处理时间序列数据<sup>[9-12]</sup>,循环神经网络(RNN)在处理长数据时容易发生梯度爆炸<sup>[13-14]</sup>,而长短期记忆(LSTM)神经网络模型所具有的长时间记忆能力,更适用于油气藏单井产量的快速预测<sup>[15-16]</sup>。刘嘉豪等<sup>[17]</sup>将LSTM神经网络与常规的BP神经网络对比预测误差,结果表明LSTM神经网络模型具有更高的预测精度与预测稳定性;韩克宁等<sup>[18]</sup>将产量递减与LSTM神经网络模型耦合;付钰琦等<sup>[19]</sup>构建了CNN-LSTM-ATT复合神经网络,进行多变量产量预测,结果均表明组合模型预测效果优于单一模型。目前,LSTM神经网络模型在预测产量上

趋于成熟,为达到理想的预测效果,需花费大量时间和经验对模型参数进行手动调优,因此,该模型存在一定主观性。

为解决页岩气加密井产能的快速预测问题,基于LSTM神经网络模型,针对模型参数多、调优困难、容易出现过拟合等问题,研究构建了一种由灰狼算法优化神经网络模型超参数的深层加密井产能预测模型,同时增加Dropout层和线性学习率热身策略,分阶段对研究区内老井生产动态进行历史数据拟合,以提高模型预测的准确性和计算效率。

## 1 川南页岩气加密井动态特征

川南页岩气<sup>[20]</sup>长宁主体区五峰组天然裂缝较发育,整体以网状缝为主。研究区位于长宁背斜构造中奥顶构造南翼区块内的某平台,储层品质好,是优质的“蜂蜜区”,但受地质认识不清和主体工艺未定型影响,早期井间距、段间距、簇间距普遍较大,加砂强度低,井控区域内储层改造不充分,井间有较多储量尚未动用。因此,对原500 m井距区域进行井间加密。研究区已有3口生产井W1井,W2井和W3井,新增2口加密井W-A井和W-B井。

老井W1井截至2022年6月底,累计生产2706 d,日均产气量为3.48×10<sup>4</sup> m<sup>3</sup>,累产气量为0.94×10<sup>8</sup> m<sup>3</sup>,日均产气量少,稳产期长,递减缓慢;加密井W-A并于2023年1月21日投入生产,截至同年10月23日,累计生产276 d,日均产气量为6.32×10<sup>4</sup> m<sup>3</sup>,累产气量为0.17×10<sup>8</sup> m<sup>3</sup>。老井W1井在配合2口加密井压裂后复产,日均产气量由关井前一周的1.98×10<sup>4</sup> m<sup>3</sup>上升至3.50×10<sup>4</sup> m<sup>3</sup>。2023年4—5月,老井关井33 d;加密井关井2次,共20 d。关井期间井底压力上升,开井后产气量增加,随着生产时间变化,产量递减程度增加,且加密井出现产量较大波动(图1)。与老井W1井相比,加密井W-A井日均产气量较高,约6.13×10<sup>4</sup> m<sup>3</sup>,产量递减模式与老井相似,开采潜力较好。

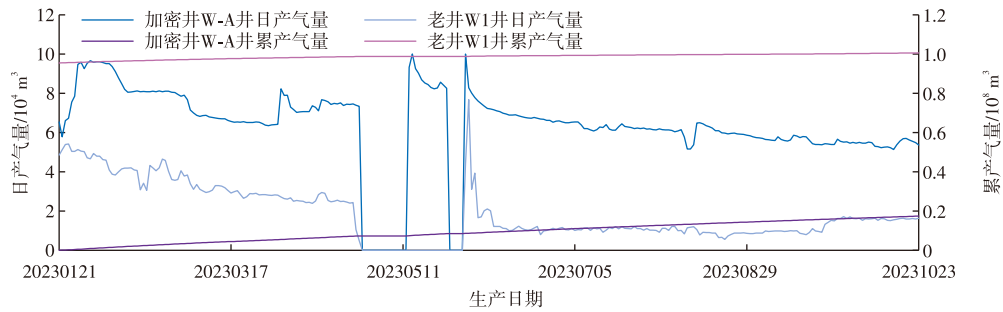


图1 川南页岩气研究区老井W1井与加密井W-A井生产曲线

Fig. 1 Production curves of well W1 (old) and well W-A (infilling) in South Sichuan shale gas study area

AI人工智能是建立在海量样本数据学习的基础上,通过机器学习算法进行模式识别和预测。人为关井压力恢复期间,井底流压和油压上升,产量为0;开井后,产量上升,老井与加密井的生产情况发生转变,因此,拟合存在阶段性。

## 2 基于LSTM神经网络模型的灰狼优化算法原理

灰狼优化算法(GWO)通过模拟狼群中的合作和竞争关系来解决优化问题,该算法的优势在于能够自适应调整收敛因子和信息反馈机制,在局部寻优与全局搜索之间实现平衡<sup>[21]</sup>。

灰狼算法优化过程的具体情况如下所示<sup>[22-23]</sup>:

### 1) 划分社会等级

根据问题的优化目标,构建灰狼社会等级层次模型,即计算每个灰狼个体的适应度值,将适应度值最高3个灰狼划分为 $\alpha$ 、 $\beta$ 和 $\delta$ ,剩下的灰狼划分为 $\omega$ 。

### 2) 包围猎物

通过计算个体与猎物之间的距离,不断更新每个灰狼个体的位置包围猎物。具体计算公式如下:

$$D = |CX_p(t) - X(t)| \quad (1)$$

$$X(t+1) = X_p(t) - AD \quad (2)$$

式中: $D$ 为灰狼个体与猎物之间的距离向量; $X_p$ 为猎物位置向量; $X$ 为灰狼位置向量; $t$ 为迭代次数; $A$ 和 $C$ 为系数向量。

其中,系数向量 $A$ 和 $C$ 的计算方法如式(3)和(4)所示:

$$A = 2\sigma r_1 - \sigma \quad (3)$$

$$C = 2r_2 \quad (4)$$

式中: $\sigma$ 为收敛因子,随着迭代次数增加而减小; $r_1$ 和 $r_2$ 为随机向量,为0~1之间的随机数。

### 3) 追捕猎物

当灰狼识别出猎物的位置后, $\alpha$ 、 $\beta$ 和 $\delta$ 指导 $\omega$ 进行追捕,实现全局优化。 $\omega$ 根据 $\alpha$ 、 $\beta$ 和 $\delta$ 的距离对下一时间步位置进行优化:

$$X_1 = |X_\alpha - A_1 D_\alpha| \quad (5)$$

$$X_2 = |X_\beta - A_2 D_\beta| \quad (6)$$

$$X_3 = |X_\delta - A_3 D_\delta| \quad (7)$$

$$X(t+1) = \frac{X_1 + X_2 + X_3}{3} \quad (8)$$

式中: $D_\alpha$ 、 $D_\beta$ 和 $D_\delta$ 分别为 $\omega$ 到 $\alpha$ 、 $\beta$ 和 $\delta$ 的向量距离; $X_1$ 、 $X_2$ 和 $X_3$ 为根据 $\alpha$ 、 $\beta$ 和 $\delta$ 灰狼位置计算得到的新的灰狼位置向量。

### 4) 攻击猎物

当灰狼逼近猎物时, $\sigma$ 的取值由初始值2线性递减至0, $A$ 的取值也在 $[-\sigma, \sigma]$ 之间变化,灰狼下一时刻的位置可以在当前与猎物之间的任何位置上。当 $|A| < 1$ 时,灰狼靠近猎物,进行局部搜索;当 $|A| > 1$ 时,灰狼远离猎物,进行全局搜索;当 $|A| = 1$ 时,灰狼的位置更新将会在猎物位置的边界上进行调整。

## 2.1 GWO-LSTM神经网络模型

GWO自动调节搜索策略,可以弥补LSTM神经网络模型中参数多、参数调优困难等不足,从而改善模型的性能和效率。LSTM神经网络模型超参数初始化为隐含层神经元个数、丢包率和批次数,并将参数作为初始值构建LSTM神经网络模型,进行训练。参数作为灰狼种群的初始值,计算每次参数寻优迭代时LSTM神经网络模型的预测结果与实际数据的差值,以最小化差值为优化目标不断更新灰狼的位置,最终得到最优的灰狼位置,即最优的LSTM神经网络模型超参数值,重构LSTM神经网络模型,进行分阶段产量预测(图2)。

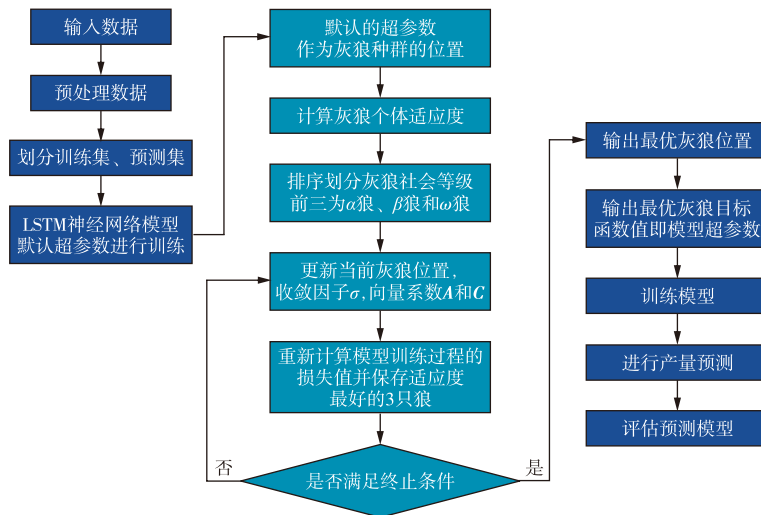


图2 GWO优化LSTM神经网络模型流程

Fig. 2 Flowchart of GWO-optimized LSTM neural network model

## 2.2 数据预处理

研究区内3口生产老井W1井、W2井、W3井和1口加密井W-A井的生产动态数据为GWO改进的LSTM神经网络模型的数据集。根据压力的递减过程,将3口老井的前40%生产数据作为前期数据,后60%作为后期数据。W1井、W2井的历年数据和W3井前、后期的前80%数据用于训练模型,约占总数据的93%。W3井剩余的生产数据用于验证,约占总数据的7%。加密井W-A井正处于生产前期,其生产数据作为前期产水模型的测试集。

在页岩气井的生产过程中,生产压力随开采时间逐步递减,生产压力曲线呈趋势性“三段式”递减,具体表现为初期剧烈下降、中期快速下降和后期缓慢下降,通过单井压力的递减过程可以反映深层页岩气井生产特征<sup>[24-28]</sup>。根据生产压力递减趋势,将单井生产过程分为前期与后期,生产压力剧烈下降期为前期,快速下降和缓慢下降期为后期。实际生产数据参数为生产时间、井底流压、油压、日产气量、累产气量、日产水量和累产水量7项,老井W1井的生产数据皮尔逊热力图,皮尔逊相关系数常被用于衡量2个随机变量之间的线性关联度(图3)。由热力图可知,日产气量与累产气量、累产水量具有强相关性,与油压和日产水量呈中等程度相关,与井底流压具有弱相关性;日产水量与井底流压、日产气量、累产气量和累产水量呈中等程度相关,与油压具有弱相关性。由于日产气量和累产气量,日产水量和累产水量具有累加关系,不适合同时作为输入特征,因此,选取井底流压作为前期模型输入特征,日产水量为输出层节点;井底流压和累产水量作为后期模型输入特征,日产气量作为输出层节点。



图3 生产数据皮尔逊相关性热力图

Fig. 3 Pearson correlation heatmap of production data

为降低噪声的影响,对训练需要的数据集进行均值滤波处理,异常数据和无效数据在数据集中的占比不足1%,直接删除。以最大最小标准化方法(Min-Max Normalization)对数据集进行归一化处理,消除数据之间的量纲影响,将数据映射至[0, 1],归一化公式如式(9)所示:

$$Y_{\text{scaler}} = \frac{Y - Y_{\min}}{Y_{\max} - Y_{\min}} \quad (9)$$

式中: $Y_{\text{scaler}}$ 为单个数据的取值; $Y$ 为当前数据值; $Y_{\min}$ 和 $Y_{\max}$ 分别为数据在不同时间的最小值与最大值。

## 2.3 学习率与迭代次数选取

学习率是神经网络优化时的重要参数,为保证网络在训练过程中能够稳定学习,将采用线性学习率热身(Linear Warm Up)的方法调整训练过程中的学习率。该方法在训练初期使用较小的学习率进行训练,在模型慢慢趋于稳定的过程中增大学习率,即当训练步数小于热

身步数时,学习率按照公式(10)更新;当模型相对稳定后,即训练步数大于热身步数时,使用预设的学习率0.002进行训练,使得收敛速度变得更快,并防止网络在收敛到最优点附近时出现震荡。

$$l(t) = l_{init} + t_l \frac{l_{max} - l_{init}}{N} \quad (10)$$

式中: $l$ 为学习率; $l_{init}$ 为热身起始的学习率; $l_{max}$ 为热身最终的学习率; $t_l$ 为训练步数; $N$ 为热身步数。

在确定模型网络结构和学习率取值后,需要选择合适的权重更新迭代次数(Epoch)。通过保存模型每次训练时间步的误差,并基于设定的误差阈值计算满足误差条件的样本比例作为性能指标,利用 matplotlib (Python的2D绘图库)绘制模型误差随训练轮次变化的曲线图,以及性能指标随训练轮次变化的曲线图,以寻找适合GWO优化的LSTM神经网络模型的最佳Epoch(周期/轮次)值(图4)。不同Epoch下的性能指标曲线和损失曲线显示,在500次时损失曲线仍有下降趋势,但性能指标曲线出现波动,且指标值在0.92~0.93之间,综合考虑模型收敛性能与训练时间,选择Epoch在450次左右为最佳。

为评估产量预测模型精度,将采用平均绝对误差(MAE)和均方根误差(RMSE)计算,二者值越小,表明预

测值与真实值之间的误差越小,模型预测精度越高。

$$L_{MAE} = \frac{1}{n} \sum_{i=1}^n |y_i - y_i'| \quad (11)$$

$$L_{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - y_i')^2} \quad (12)$$

式中: $L_{MAE}$ 为平均绝对误差值; $L_{RMSE}$ 为均方根误差值; $y_i$ 为第*i*个样本的真实值; $y_i'$ 为第*i*个样本的预测值; $n$ 为样本的总体数量。

### 3 应用实例及结果分析

#### 3.1 拟合与预测效果

将GWO优化的LSTM神经网络模型拟合、验证和测试阶段的结果与研究区块的实际生产数据对比,并以每半年取1次数据的方式统计模型的训练拟合数据,结果见表1。根据W3井训练数据集中全部预测值与实际值数据计算得出,训练集平均绝对误差值为 $0.16 \times 10^4 \text{ m}^3$ ,预测结果整体较为接近实际值。

表1 W3井日产气量预测值与实际值对比

Table 1 Comparison between predicted and actual daily gas production of well W3

日期	预测值/ $10^4 \text{ m}^3$	实际值/ $10^4 \text{ m}^3$	绝对误差值/ $10^4 \text{ m}^3$
20180717	0.80	0.81	0.01
20190115	2.81	2.84	0.03
20190716	1.74	1.76	0.02
20200114	1.28	0.91	0.37
20200714	1.23	1.60	0.37
平均值			0.16

将LSTM神经网络预测模型以同样的生产数据进行训练,经过同样的迭代次数,其前、后期模型的预测结果与实际结果、GWO优化的LSTM神经网络模型预测结果对比(图5)。输出二者前、后期模型验证集的平均绝对误差和均方根误差,结果见表2。由对比结果可知,GWO优化的LSTM神经网络预测模型的拟合精度与预测精度相比,传统的LSTM神经网络预测模型具有一定的提升。

将训练好的GWO优化LSTM神经网络前期模型应用到加密井W-A井的日产水量预测中(图6)。预测结果表明:基于老井生产数据学习的神经网络模型,能对同一区块内的加密井进行一定程度上的预测,具体表现在预测产量递减趋势上。而对于开井时期压力递减产水量却突增,关井时期压力升高却不产水的情况,神经网络模型无法准确地进行预测。

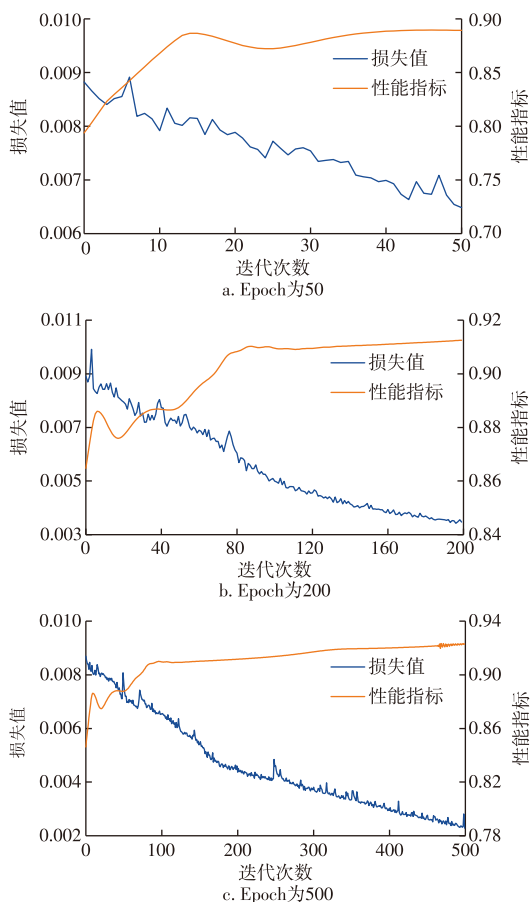


图4 不同Epoch下的损失曲线与性能指标曲线

Fig. 4 Loss and performance metric curves under different Epochs

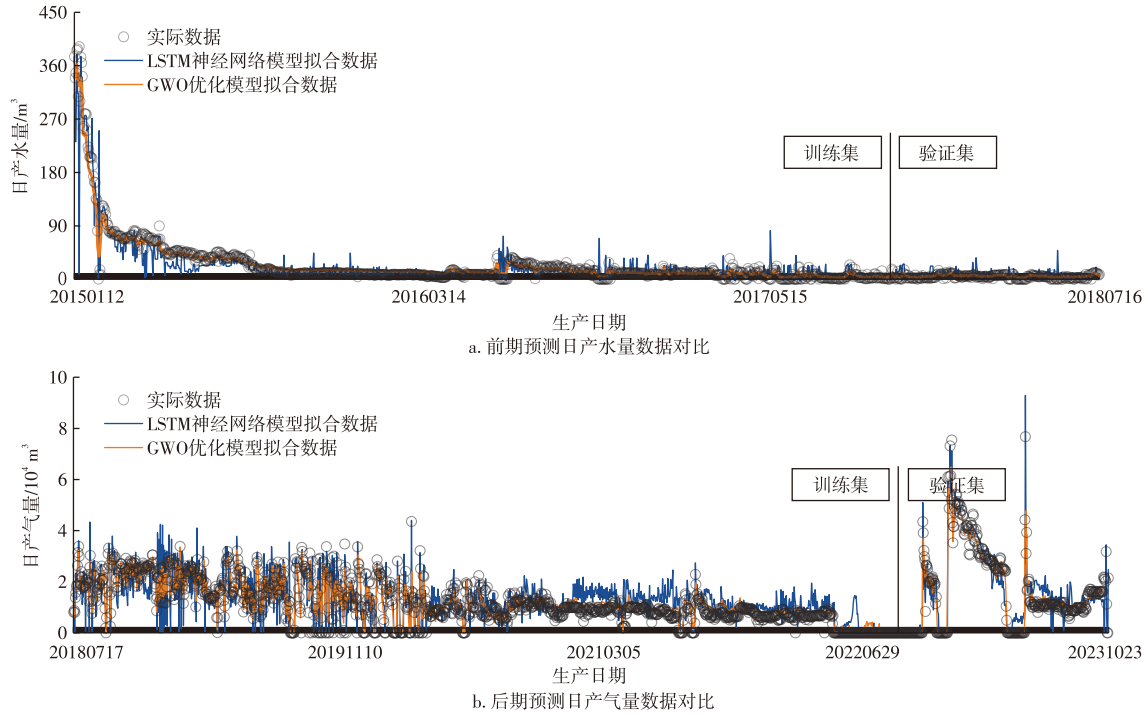


图5 GWO优化的LSTM神经网络模型预测数据与实际数据对比

Fig. 5 Comparison of predicted and actual values from GWO-optimized LSTM neural network model

表2 GWO优化模型与LSTM神经网络模型验证集误差对比

Table 2 Comparison of validation set errors between GWO-optimized model and LSTM neural network model

结果参数	LSTM神经网络前期模型/ (m³/d)	GWO优化前期模型/ (m³/d)	LSTM神经网络后期模型/ (10⁴ m³/d)	GWO优化后期模型/ (10⁴ m³/d)
平均绝对误差值	3.742	2.452	0.396	0.183
均方根误差值	6.131	3.444	0.569	0.315




图6 加密井的GWO优化神经网络模型预测数据与实际数据对比

Fig. 6 Comparison of predicted and actual values of GWO-optimized neural network model for infilling well

### 3.2 可靠性分析

数值模拟方法是一种基于计算机的模拟技术,该技术基于渗流数学模型构建复杂的地质模型,模拟油气藏开发全过程并制定开发方案。研究选用Petrel对研究区块进行地质建模,通过收集并整合地质、测井和生产数据,充分考虑储层非均质性和复杂性,构建了包含岩性、孔-渗-饱等关键地质参数的三维地质模型,相关地质与工程参数如下:原始地层压力为52 MPa,孔隙度为0.078,

压裂未动用区域渗透率为 $0.0005 \times 10^{-3} \mu\text{m}^2$ ,SRV区域渗透率平均为 $2.42 \times 10^{-3} \mu\text{m}^2$ ,水平最大地应力为73.2 MPa,水平最小地应力为64.5 MPa。利用Kinetix对研究区内水平井进行水力裂缝扩展模拟,在水平井段内形成复杂裂缝网络,以提高储层的渗流能力。为验证地质模型的准确性和水力压裂效果,对该研究区内水平井进行了生产历史拟合,将已有生产历史中的井底流压作为控制条件来拟合产量,14 d为1个生产周期拟合数据,拟合结果如图7、图8所示。由散点图对比可知,散点越集中在

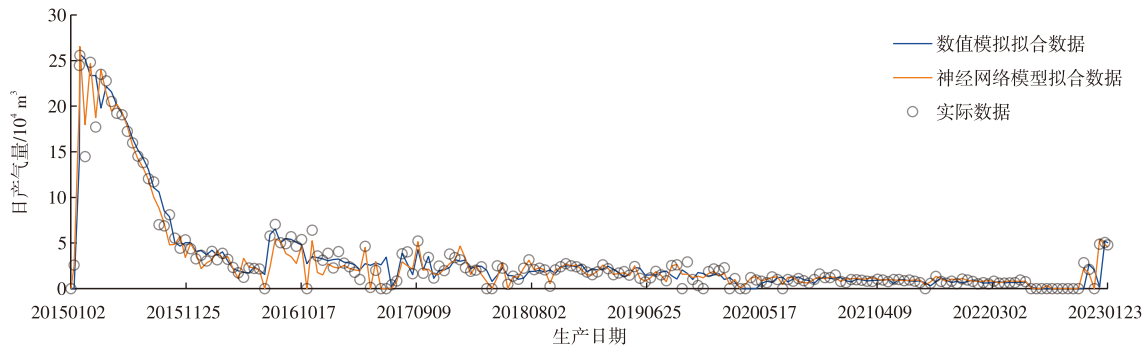


图7 神经网络模型拟合数据与数值模拟拟合数据对比

Fig. 7 Comparison between fitted results of neural network model and numerical simulation




图8 神经网络模型拟合数据与数值模拟拟合数据散点图对比

Fig. 8 Scatter plot comparison of neural network model vs. numerical simulation fitted results

斜对角线上,数据拟合程度越高,对拟合结果进行误差计算,数值模拟方法的单井产气量历史拟合的平均绝对误差约为  $0.716 \times 10^4 \text{ m}^3/\text{d}$ ,神经网络方法的平均绝对误差为  $0.476 \times 10^4 \text{ m}^3/\text{d}$ ,二者相比,神经网络模型拟合度稍高,且细节拟合准确度更高。

数值模拟方法和神经网络方法的工作量、准确度对比如下:

1) 工作量:数值模拟方法需要建立符合实际情况复杂的地理模型和数值模型,地理模型的构建需要极高的准确度,同时建立和验证数值模型也需要大量的计算和参数调整;神经网络算法通常需要收集大量的生产数据,进行数据预处理、特征选择、模型选择和参数调优等多个步骤。二者相较之下,神经网络方法工作量更小。

2) 准确度:数值模拟方法尽管在理论上可以更精准地反映复杂地质情况,但其准确度高度依赖于地理模型的构建质量和参数的校正精度;神经网络算法受噪声、缺失数据和异常值的影响极大,但在捕捉非线性复杂关系和细节拟合方面具有显著优势,且在数据较为完整的情况下,通过选择适当模型并及时进行调优,能对产量进行一定范围内比较精确地预测。

## 4 结论

根据气田实际生产情况的产量递减趋势,将单井生产过程分为前期和后期,分别建立了前期以井底流压为输入层,日产水量为输出层;后期以井底流压和累产水量为输入层,日产气量为输出层的GWO优化的LSTM神经网络模型,预测得到了较好的结果,结论如下:

1) 通过GWO优化调优后,根据性能指标曲线和损失曲线设置最大迭代训练次数450次,预设的全局学习率为0.002,进行线性学习率热身,使GWO优化的LSTM神经网络模型具有良好的拟合和预测能力。

2) 采用研究区块生产数据93%作为训练学习样本,7%作为检验样本。结果表明:GWO优化的LSTM神经网络模型与常规的LSTM神经网络模型对比其平均绝对误差和均方根误差,该模型的预测效果有一定的提升。

3) 模型测试结果表明:以老井生产数据为学习样本的神经网络模型,能对同一区块内加密井的产量进行预测,并对递减趋势进行准确预测,但对于人为操作开井关井的特定情况预测难度大。

4) 神经网络预测方法相较于数值模拟方法计算工

产量较少,且产量预测准确度高,数值模拟方法的预测误差大于神经网络算法的预测误差。

#### 参考文献

- [1] 许宁,张俊杰,叶锋,等.非常规油藏蓄能体积压裂的合理压裂规模研究[J].石油地质与工程,2024,38(2):97-101.  
XU Ning, ZHANG Junjie, YE Feng, et al. Study on reasonable fracturing scale of accumulative volume fracturing in unconventional reservoir[J]. Petroleum Geology and Engineering, 2024, 38(2): 97-101.
- [2] 王世禄.松辽盆地古龙页岩油水平井压裂施工参数优化[J].石油地质与工程,2023,37(5):94-99.  
WANG Shilu. Optimization of fracturing construction parameters for Gulong shale oil with horizontal wells in Songliao Basin[J]. Petroleum Geology and Engineering, 2023, 37(5): 94-99.
- [3] 苏玉亮,盛广龙,王文东,等.页岩气藏多重介质流体跨尺度传质表征方法研究[J].中国科学:技术科学,2018,48(5):510-523.  
SU Yuliang, SHENG Guanglong, WANG Wendong, et al. Characterization methods for mass transfer of multiple media in shale gas reservoirs[J]. Scientia Sinica(Technologica), 2018, 48(5): 510-523.
- [4] 刘子雄,李敬松,黄子俊,等.利用录井资料计算低渗气井压裂产能的新方法[J].断块油气田,2014,21(4):497-499.  
LIU Zixiong, LI Jingsong, HUANG Zijun, et al. A new method to calculate fracturing productivity of low permeability gas well using logging data[J]. Fault-Block Oil and Gas Field, 2014, 21(4): 497-499.
- [5] 赵金洲,李志强,胡永全,等.考虑页岩储层微观渗流的压裂产能数值模拟[J].天然气工业,2015,35(6):53-58.  
ZHAO Jinzhou, LI Zhiqiang, HU Yongquan, et al. Numerical simulation of productivity after fracturing with consideration to micro-seepage in shale reservoirs[J]. Natural Gas Industry, 2015, 35(6): 53-58.
- [6] 李泽沛,彭小龙,王毅.基于三重介质模型的体积压裂后页岩气储层数值模拟方法[J].油气地质与采收率,2016,23(6):105-111.  
LI Zepei, PENG Xiaolong, WANG Yi. Numerical simulation method of shale gas reservoirs after stimulated reservoir volume fracturing based on triple porous media model[J]. Petroleum Geology and Recovery Efficiency, 2016, 23(6): 105-111.
- [7] 张晨招.新的页岩气多级压裂水平井产能预测模型研究[J].地下水,2018,40(5):121-125.  
ZHANG Chenzhao. New shale gas multi-stage fracturing horizontal well productivity prediction model research[J]. Ground Water, 2018, 40(5): 121-125.
- [8] 张春晓,马含含,侯梦瑶,等.基于时间序列分析的油井产量预测应用综述[C]//2023国际石油石化技术会议论文集.西安:西安石油大学,2023.  
ZHANG Chunxiao, MA Hanhan, HOU Mengyao, et al. A review on application of oil well production prediction based on time series analysis method[C]// Proceedings of 2023 International Petroleum and Petrochemical Technology Conference. Xi'an: Xi'an Petroleum University, 2023.
- [9] 强璐,任宇飞,马焕焕,等.基于GA-BP神经网络的特低渗砂岩油藏水平井产能预测[J].石油地质与工程,2024,38(6):63-67.  
QIANG Lu, REN Yufei, MA Huanhuan, et al. Prediction of horizontal well productivity in ultra-low permeability sandstone reservoirs based on GA-BP neural network[J]. Petroleum Geology & Engineering, 2024, 38(6): 63-67.
- [10] 赵林丰,李晓静,王晶晶,等.多属性神经网络反演在重力流储层预测中的应用:以歧口凹陷歧南斜坡沙一段为例[J].石油地质与工程,2024,38(5):7-12.  
ZHAO Linfeng, LI Xiaojing, WANG Jingjing, et al. Application of multi-attribute neural network inversion in gravity flow reservoir prediction: A case study of Es1 Formation in Qinan Slope, Qikou Sag [J]. Petroleum Geology & Engineering, 2024, 38(5): 7-12.
- [11] 田亚鹏,鞠斌山.基于遗传算法改进BP神经网络的页岩气产量递减预测模型[J].中国科技论文,2016,11(15):1710-1715.  
TIAN Yapeng, JU Binshan. A model for predicting shale gas production decline based on the BP neural network improved by the genetic algorithm[J]. China Sciencepaper, 2016, 11(15): 1710-1715.
- [12] 赵军,夏宏泉,刘红歧.基于BP神经网络的油气产量历史预测[J].西南石油学院学报,1998,20(2):23-26.  
ZHAO Jun, XIA Hongquan, LIU Hongqi. Prediction of oil/gas history based on neural network[J]. Journal of Southwest Petroleum Institute, 1998, 20(2): 23-26.
- [13] 周于皓,刘慧卿,祁鹏,等.基于循环神经网络的缝洞型油藏油井产量预测[J].计算物理,2018,35(6):668-674.  
ZHOU Yuhao, LIU Huiqing, QI Peng, et al. Forecast of oil production in fractured-vuggy reservoir by using recurrent neural networks[J]. Chinese Journal of Computational Physics, 2018, 35(6): 668-674.
- [14] 高亚军,唐力辉,王振鹏,等.基于循环神经网络和数据差分处理的油田产量预测方法[J].中国海上油气,2023,35(3):126-136.  
GAO Yajun, TANG Lihui, WANG Zhenpeng, et al. A method for oilfield production prediction based on recurrent neural network and data differential processing[J]. China Offshore Oil and Gas, 2023, 35(3): 126-136.
- [15] 张春晓.基于深度长短期记忆神经网络的油气井产量预测优化方法[J].石油化工应用,2023,42(11):28-31.  
ZHANG Chunxiao. Optimization method for oil and gas well production prediction based on deep long short-term memory neural network[J]. Petrochemical Industry Application, 2023, 42(11): 28-31.
- [16] 王洪亮,林霞,蒋丽维,等.基于聚类及长短时记忆神经网络预测油田产量[J].石油科学通报,2024,9(1):62-72.  
WANG Hongliang, LIN Xia, JIANG Liwei, et al. An oilfield production prediction method based on clustering and long short-term memory neural network[J]. Petroleum Science Bulletin, 2024, 9(1): 62-72.
- [17] 刘嘉豪,刘浩.基于LSTM神经网络模型的石油单井产量预测[J].石油化工应用,2023,42(3):38-41.  
LIU Jiahao, LIU Hao. Production prediction of single oil well based on LSTM neural network model[J]. Petrochemical Industry Application, 2023, 42(3): 38-41.
- [18] 韩克宁,王伟,樊冬艳,等.基于产量递减与LSTM耦合的常压页岩气井产量预测[J].油气藏评价与开发,2023,13(5):647-656.  
HAN Kening, WANG Wei, FAN Dongyan, et al. Production forecasting for normal pressure shale gas wells based on coupling of production decline method and LSTM model[J]. Petroleum Reservoir Evaluation and Development, 2023, 13(5): 647-656.
- [19] 付钰琦,王杨,吴思樵,等.基于CNN-LSTM-ATT网络的页岩气井产量预测[J].天然气技术与经济,2024,18(2):32-38.  
FU Yuqi, WANG Yang, WU Siqiao, et al. Predicting the production in shale gas wells based on CNN-LSTM-ATT model[J]. Natural Gas

- Technology and Economy, 2024, 18(2): 32-38.
- [20] 缪欢, 郑洪扬, 范文龙, 等. 四川盆地龙马溪组深层页岩储层压力与含气量动态演化过程[J]. 世界石油工业, 2024, 31(5): 19-29. 39. MIAO Huan, ZHENG Hongyang, FAN Wenlong, et al. Dynamic evolution process of pressure and gas content in the Longmaxi Formation deep shale reservoir of Sichuan Basin[J]. World Petroleum Industry, 2024, 31(5): 19-29.
- [21] 史伟光, 王启任. 基于改进灰狼算法的多任务优化算法[J]. 天津工业大学学报, 2023, 42(5): 81-86. SHI Weiguang, WANG Qiren. Improved grey wolf algorithm based multitask optimization algorithm[J]. Journal of Tiangong University, 2023, 42(5): 81-86.
- [22] 秦宏伍, 王立铮, 傅渝, 等. 基于多策略结合的灰狼优化算法及应用[J]. 山东大学学报(理学版), 2024, 59(3): 51-60. QIN Hongwu, WANG Lizheng, FU Yu, et al. Grey wolf optimization algorithm based on multi-strategy combination and its application[J]. Journal of Shandong University (Natural Science), 2024, 59(3): 51-60.
- [23] 姜云. 灰狼优化混合算法及其K-means聚类优化研究[D]. 新乡: 河南师范大学, 2021. JIANG Yun. Research on hybrid grey wolf optimizers and their K-means clustering optimization[D]. Xinxiang: Henan Normal University, 2021.
- [24] 夏雪飞. 焦石坝背斜中北部页岩气井压力变化规律研究[J]. 江汉石油职工大学学报, 2018, 31(2): 14-17. XIA Xuefei. Research on pressure change pattern of north central shale gas wells in jiaoshiba anticline[J]. Journal of Jiangnan Petroleum University of Staff and Workers, 2018, 31(2): 14-17.
- [25] 商晓飞, 段太忠, 包汉勇, 等. 基于裂缝相表征的页岩气藏天然裂缝新模型: 以涪陵页岩气田焦石坝区块为例[J]. 天然气工业, 2023, 43(6): 44-56. SHANG Xiaofei, DUAN Taizhong, BAO Hanyong, et al. A new model of natural fractures in shale gas reservoirs based on fracture facies characterization: A case study from the Jiaoshiba Block of the Fuling Shale Gas Field[J]. Natural Gas Industry, 2023, 43(6): 44-56.
- [26] 贾承造, 王祖纲, 姜林, 等. 中国油气勘探开发成就与未来潜力: 深层、深水与非常规油气: 专访中国科学院院士、石油地质与构造地质学家贾承造[J]. 世界石油工业, 2023, 30(3): 1-8. JIA Chengzao, WANG Zugang, JIANG Lin, et al. Achievements and future potential for oil&gas exploration and development in China: Deep-formation, deep-water and unconventional reservoirs: Interview with JIA Chengzao, Academician of the CAS, geologist in petroleum geology and structure[J]. World Petroleum Industry, 2023, 30(3): 1-8.
- [27] 汪泽成, 赵振宇, 黄福喜, 等. 中国中西部含油气盆地超深层油气成藏条件与勘探潜力分析[J]. 世界石油工业, 2024, 31(1): 33-48. WANG Zecheng, ZHAO Zhenyu, HUANG Fuxi, et al. Ultra-deep hydrocarbon accumulation conditions and exploration potential in sedimentary basins of Central-Western China[J]. World Petroleum Industry, 2024, 31(1): 33-48.
- [28] 刘方圆. 涪陵页岩气田焦页XHF井生产动态分析及建议[J]. 地质科技情报, 2018, 37(3): 196-201. LIU Fangyuan. Advices for Well Jiaoye XHF, Fuling Shale gas field by analyzing production data[J]. Geological Science and Technology Information, 2018, 37(3): 196-201.

(编辑 郭群)

(上接第462页)

- [22] 张喜林, 朱筱敏, 钟大康, 等. 苏北盆地高邮凹陷古近系戴南组沉积相及其对隐蔽油气藏的控制[J]. 古地理学报, 2005, 7(2): 207-218. ZHANG Xilin, ZHU Xiaomin, ZHONG Dakang, et al. Sedimentary facies and its controlling on subtle oil and gas reservoirs of the Dainan Formation of Paleogene in Gaoyou Sag, Subei Basin[J]. Journal of Palaeogeography, 2005, 7(2): 207-218.
- [23] 袁静, 董道涛, 宋璠, 等. 苏北盆地高邮凹陷深凹带古近系戴南组一段沉积格局与时空演化[J]. 古地理学报, 2016, 18(2): 147-160. YUAN Jing, DONG Daotao, SONG Fan, et al. Sedimentary patterns and spatiotemporal evolution of the member 1 of Paleogene Dainan Formation in deep sag of Gaoyou Sag, Subei Basin[J]. Journal of Palaeogeography, 2016, 18(2): 147-160.
- [24] 高丽坤, 林春明, 姚玉来, 等. 苏北盆地高邮凹陷古近系戴南组沉积相及沉积演化[J]. 沉积学报, 2010, 28(4): 706-716. GAO Likun, LIN Chunming, YAO Yulai, et al. Sedimentary facies and evolution of Paleogene Dainan Formation in Gaoyou Sag, Subei Basin[J]. Acta Sedimentologica Sinica, 2010, 28(4): 706-716.
- [25] 周健, 林春明, 张霞, 等. 江苏高邮凹陷古近系戴南组一段物源体系和沉积相[J]. 古地理学报, 2011, 13(2): 161-174. ZHOU Jian, LIN Chunming, ZHANG Xia, et al. Provenance system and sedimentary facies of the member 1 of Paleogene Dainan Formation in Gaoyou Sag, Jiangsu Province[J]. Journal of Palaeogeography, 2011, 13(2): 161-174.
- [26] 袁静, 梁绘媛, 梁兵, 等. 湖相重力流沉积特征及发育模式: 以苏北盆地高邮凹陷深凹带戴南组为例[J]. 石油学报, 2016, 37(3): 348-359. YUAN Jing, LIANG Huiyuan, LIANG Bing, et al. Sedimentary characteristics and development model of lacustrine gravity flow: A case study of Dainan Formation in deep sag belt of Gaoyou Depression, Northern Jiangsu Basin[J]. Acta Petrolei Sinica, 2016, 37(3): 348-359.
- [27] 姚玉来, 林春明, 高丽坤, 等. 苏北盆地高邮凹陷深凹带东部古近系戴南组二段沉积相及沉积演化[J]. 沉积与特提斯地质, 2010, 30(2): 1-10. YAO Yulai, LIN Chunming, GAO Likun, et al. Sedimentary facies and evolution of the second member of the Paleogene Dainan Formation in the deep area of eastern Gaoyou Depression, North Jiangsu Basin[J]. Sedimentary Geology and Tethyan Geology, 2010, 30(2): 1-10.
- [28] 张妮, 林春明, 周健, 等. 苏北盆地高邮凹陷始新统戴南组一段稀土元素特征及其物源指示意义[J]. 地质论评, 2012, 58(2): 369-378. ZHANG Ni, LIN Chunming, ZHOU Jian, et al. REE characteristics of the 1st member of Eocene Dainan Formation in Gaoyou Depression of North Jiangsu Basin, and its significance in provenance instruction[J]. Geological Review, 2012, 58(2): 369-378.

(编辑 黄颖)