

DOI:10.3969/j.issn.1003-5060.2025.09.016

基于 TCN-LSTM 模型的页岩气产量预测

史峥峥¹, 李道伦¹, 付宁², 张康²

(1. 合肥工业大学 数学学院, 安徽 合肥 230601; 2. 中国石油川庆钻探长庆井下技术作业公司, 陕西 西安 710016)

摘要:准确预测页岩气产量有助于提前规划生产计划、优化生产方案。现有研究在进行产量预测时,往往需要长时间的生产数据或大量特征数据,当生产时间较短或特征数据较少时,难以准确预测产量。为此,文章提出一种具有注意力机制的时间卷积网络-长短期记忆网络(temporal convolutional network-long short-term memory network, TCN-LSTM)模型。该模型使用 3 口井生产数据联合训练,其中 TCN 和 LSTM 模块分别提取局部和全局特征,然后用全连接网络融合;并使用注意力机制聚焦关键信息,从已有井生产数据中学习流动规律,提高了对初期数据匮乏的新井的预测精度。结果表明,多井联合预测模型在精度和趋势预测方面均优于单井预测模型,基于平均绝对误差(mean absolute error, MAE)评估指标的预测精度提高了约 4 倍,并且减少了对长周期数据和多特征的依赖,在油藏开发中具有重要意义。

关键词:时间卷积网络(TCN);长短期记忆网络(LSTM);注意力机制;产量预测;多井

中图分类号:TE332 **文献标志码:**A **文章编号:**1003-5060(2025)09-1259-07

Shale gas production prediction based on TCN-LSTM model

SHI Zhengzheng¹, LI Daolun¹, FU Ning², ZHANG Kang²

(1. School of Mathematics, Hefei University of Technology, Hefei 230601, China; 2. Changqing Downhole Technology Company, CNPC Chuangqing Drilling Engineering Co., Ltd., Xi'an 710016, China)

Abstract: Accurate prediction of shale gas production helps to plan production schedules in advance and optimize production schemes. Current research on output prediction often requires long-term production data or a large amount of feature data. When the production time is short or the feature data is scarce, it is difficult to accurately predict the output. To this end, this paper proposes a temporal convolutional network-long short-term memory network(TCN-LSTM) model with an attention mechanism. This model is jointly trained using the production data of three wells. The TCN and LSTM modules extract local and global features respectively, which are then fused through the fully connected network. The attention mechanism is used to focus on key information, learn the flow laws from the existing well production data, and improve the prediction accuracy in scenarios where new wells have limited initial data. The results show that the multi-well joint prediction model outperforms the single-well prediction model in terms of accuracy and trend prediction. Based on the mean absolute error(MAE) evaluation index, the prediction accuracy increases by approximately four times. Additionally, the model reduces the reliance on long-term data and multiple features. It is of great significance in reservoir development.

Key words: temporal convolutional network(TCN); long short-term memory network(LSTM); attention mechanism; production prediction; multi-well

收稿日期:2025-05-08;修回日期:2025-05-30

基金项目:国家自然科学基金资助项目(12172115;12372244)

作者简介:史峥峥(1999—),女,安徽池州人,合肥工业大学硕士生;

李道伦(1972—),男,安徽合肥人,博士,合肥工业大学教授,博士生导师,通信作者, E-mail:ldaol@hfut.edu.cn.

准确的页岩气产量预测对于制定气田开发方案至关重要,有助于及时调整开发方案,满足经济发展需求。近年来,机器学习和神经网络在油藏开发技术升级换代中具有广泛的应用^[1-3]。国内外学者探索了多种神经网络模型,用于不同条件和不同储层类型下的模拟和预测。

文献[4]设计了一种具有很强的非线性学习能力的前馈神经网络(feedforward neural network, FNN)模型作为预测油藏生产动态的替代技术,并使用来自油田的真实历史生产数据来训练网络;该模型是油藏生产管理的实用工具,然而, FNN 只能向前传播信息,限制了它从过去序列中学习的能力,并阻止了它有效地连接过去和未来的数据^[5]。

为了处理复杂的时间序列数据,引入循环神经网络(recurrent neural network, RNN)。RNN 的循环结构允许将早期时间步长的信息传递到后续时间步,从而能够捕获数据中的时间特征^[6]。文献[7]利用 RNN 建立了产量预测模型,将生产指标与影响因素关联起来。然而,随着时间间隔的增加, RNN 往往会失去学习长期信息的能力,从而导致预测误差增加^[8]。长短期记忆网络(long short-term memory network, LSTM)的开发是为了缓解这个问题。文献[9]应用 LSTM 模型预测了地质和压裂储层约束下的页岩气产量;文献[10]使用 LSTM 模型来指导页岩气井的生产,证明了该模型能够捕捉 10 d 内的生产趋势;文献[11]引入包含 LSTM 的双三网络模型,该模型在拟合气田采收率方面表现出色。

文献[12]提出时间卷积网络(temporal convolutional network, TCN)模型进行序列建模。作为卷积网络的一种变体, TCN 保留了强大的特征提取能力,可以比 LSTM 更有效地捕获长期序列相关性,在计算效率和拟合能力方面具有优势。因此, TCN 在时间序列数据分析中受到关注^[13]。TCN 通过有效地学习过去的的数据,并根据井口压力适应各种模式和序列,在准确预测页岩气井产量方面发挥着至关重要的作用^[14]。但是该方法仍然需要 150~300 d 的实测数据来训练,预测的时间偏短,否则预测误差变大。

目前的研究通常使用单井的历史数据,应用各种神经网络模型来预测页岩气井产量。当单井历史数据较少时,传统的预测模型很难获得准确的结果^[14-15]。因此,有效利用多井数据提高模型预测精度已成为重点研究方向。文献[16]提出了

一种新的基于双向门控循环单元和深度混合神经网络的物理约束深度学习框架,使用 15 个静态和动态特征用于多口压裂井的长期产量预测。文献[17]基于 250 口井的生产数据,对具有不同生产特征的地层进行分类,并确定产量与关键因素之间的关系,对页岩地层中现有和新开发的多井进行产量预测。

综上所述,当前产量研究还存在很多不足,例如,需要从数百天的数据中才能学习到规律,且预测时间还短^[14];需要 250 口井的生产数据或 15 个特征才能有好的结果^[16-17]。因而,有关仅从若干口井的极少量特征来学习规律,并长时间、高精度进行产量预测的研究不多。

为了解决这一问题,本文提出了一种产量预测方法,仅需 3 口井的一个特征即可实现新井产量长时间、高精度预测。该方法是基于多头注意力机制的 TCN-LSTM 模型,引入注意力机制块^[18]可以使网络更关注重要的信息。模型先利用 TCN 提取序列中的局部特征,再由 LSTM 对这些特征进行长期依赖建模,从而提高模型对序列数据的整体理解能力,既能捕获序列中的长期关系,又能有效地捕捉数据中的局部模式,克服了以往方法的局限性。

1 相关研究方法

1.1 时间卷积网络

时间卷积网络^[19-20]是一种基于传统卷积神经网络(convolutional neural network, CNN)演变而来的架构,将卷积操作作为过滤器,从输入数据中提取特征。随着网络深度的增加,输出元素涵盖的时间范围扩大。TCN 通过卷积结构解决时间序列分析的问题,其显著特点是输入与输出长度一致。

扩张因果卷积(dilated causal convolutional, DCC)^[14]是 TCN 的核心组成部分,为 TCN 实现对时序数据的有效处理提供了关键能力。扩张因果卷积结合了扩张卷积和因果卷积^[18],常用于处理时间序列数据。通过增大扩张率(dilation rate)增加了卷积核之间的间隔,从而扩大了感受野,同时保持因果关系,即每个时间步的输出只依赖于过去的时间步。

DCC 网络结构示意图如图 1 所示。该网络为一个核数 $K=2$ 、输入时间窗 $T=8$ 、扩展因子 $d=2^i$ ($i=0, 1, 2$) 的 4 层扩张因果卷积网络。隐藏层 1 仍然是与图 1 类似的因果卷积层,其余层

是扩张卷积层,可以跳过一些单元进行操作。从图 1 可以看出,在卷积核大小为 2、步长为 1、卷积层数为 3 的情况下,第 3 层的输出 y_8 可以追溯到 x_1, x_2, \dots, x_8 。




图 1 DCC 网络结构示意图

1.2 长短期记忆网络

LSTM^[21]的核心思想在于通过精心设计的门控单元动态调控信息流,从而实现重要特征的长期记忆与无关信息的主动遗忘。LSTM 单元包含遗忘门、输入门和输出门 3 个门控结构。输入门负责筛选当前输入数据中的有效特征,并将其与候选细胞状态结合,更新当前时刻的细胞状态。遗忘门通过 Sigmoid 函数决定细胞状态中哪些历史信息需要保留或丢弃,其输出值介于 0 到 1 之间,0 表示完全遗忘,1 表示完整保留。输出门进一步基于更新后的细胞状态和当前输入生成隐藏状态,作为后续时间步的输入或最终预测结果。

1.3 注意力机制

1.3.1 自注意力机制

注意力机制^[18]最早源于对人类视觉的研究。在深度学习框架下,注意力机制通过构建动态权重矩阵,使模型能够根据任务需求自适应地调整对输入特征的关注程度。自注意力使序列中的每个元素都能自主建立与其他元素的关联。给定查询向量 Q 、键向量 K 和数值向量 V ,自注意力机制公式为:

$$\text{Attention}(Q, K, V) = \text{Softmax}\left(\frac{QK^T}{\sqrt{d_k}}\right)V \quad (1)$$

通过缩放点积法,可以确保注意力计算的稳定性和有效性,从而提高了注意力机制在各种任务中的性能和可训练性。

1.3.2 多头注意力机制

多头注意力机制^[22]是在自注意力的基础上实现了认知维度的拓展。通过并行运行多个独立的注意力子空间,每个子空间学习不同的特征表示模式,最后将各子空间的输出进行融合。这种

设计理念类似于多专家协同工作机制,不同的注意力头可以分别关注不同层面的信息。多头注意力机制的公式为:

$$\begin{aligned} \text{MultiHead}(Q, K, V) = & \\ & \text{Concat}(\text{Attention}(Q_1, K_1, V_1), \dots, \\ & \text{Attention}(Q_h, K_h, V_h))W_O \quad (2) \end{aligned}$$

$$\text{Attention}(Q_i, K_i, V_i) = \text{Softmax}\left(\frac{Q_i K_i^T}{\sqrt{d_k}}\right)V_i \quad (3)$$

其中: W_O 为可学习的权重矩阵; Q_i 为第 i 个头的查询向量; K_i 为第 i 个头的键向量; V_i 为第 i 个头的数值向量。

2 产量预测模型

2.1 数据选择

收集中国页岩气藏的不同气井的生产数据,包括日产气量、生产日期、日生产时长、井口压力和气井状态。气井状态用 0 和 1 表示,其中 0 表示关井,1 表示开井。对于给定的页岩气井数据,下文模型的输入均由日生产时长、生产日期、井口压力和气井状态组成,输出为页岩气的日产气量。

2.2 数据处理

对于多井数据的处理,首先将训练集和测试集数据按列进行堆叠,得到总训练集和总测试集;然后划分时间窗口,生成用于模型训练的输入序列和目标标签。

在实际生产数据处理中,可能因各种原因导致部分数据缺失或未被记录。对于单个数据缺失的情况,一般采用前后平均法进行填补,而对于短期内连续缺失的数据,则采用线性插值法进行填充。其计算公式如下:

$$x_m = x_f + \frac{(m-f)(x_f - x_l)}{f-l} \quad (4)$$

其中: x_m, x_f, x_l 分别为缺失数据、缺失位置前、后的数据; m, f, l 分别为各自的索引标签。

在实际生产序列中,某些时间点可能存在突变,可能对模型的学习产生不利影响。因此,在将数据输入模型之前,本文采用一种有效的 3 阶中值滤波器进行平滑处理。

2.3 模型

本文使用的模型主要由 1 个 TCN 块和 1 个 LSTM 块网络层组成。输入分别经过 TCN 块和 LSTM 块,输出的信息进行特征维度的叠加,特征进入注意力块,自动学习和选择重要的特征,再经过全连接层(Dense)得到输出。整体框架如

图 2 所示。在该模型中,TCN 块用来学习输入与输出之间的非线性映射关系,确保信息不会从未来泄漏到过去,从而使输出更加合理;LSTM 块能根据时间序列的实时变化,动态选择保留或遗忘关键信息;全连接层主要用于学习线性映射能力,直接反映了输入与输出之间的线性关系,增强了模型的解释能力。




图 2 基于 TCL-LSTM 的多井联合预测模型

其中,TCN 块由 L 层的 R-C 块(剩余连接块)和 1 个 Conv1D 组成。输入依次经过每个 R-C 块,第 l 层 R-C 块的卷积核大小为 2、扩张因子为 2^{l-1} ,则 L 层 R-C 块构成的 TCN 块可实现接受域大小为 2^L 。同时,输入还要经过残差连接,即 Conv1D,并与 R-C 块得到的输出进行相加,得到 TCN 块的输出。R-C 块分别为因果和膨胀卷积层、Batch-Normalization 层、ReLU 层和 SpatialDropout1D^[32]层,最外层加一个 Conv1D 层,用于残差连接。

2.4 参数设置

对于多井联合预测模型参数的选择,主要是要确定 TCN 块和 LSTM 块的参数。该模型采用 Adam 优化算法迭代更新神经网络权值,学习率设置为默认值 0.001。目标函数是均方误差,使用网格搜索法确定本研究中模型合适的超参数,其中超参数的搜索空间时间片段 $t \in \{5, 7, 10, 16, 21, 25, 30, 42\}$,TCN 块中卷积核的数量 $n \in \{2^2, 2^3, \dots, 2^6\}$ 。模型的最佳参数配置见表 1 所列。

表 1 模型的最佳参数配置

类型	层数	滤波器数量	卷积核大小	扩张率	填充	激活函数
TCN 块	Conv1D	32	2	2^i	causal	ReLU
	Conv1D	1			same	ReLU
LSTM 块	LSTM	16				ReLU
	Dense	1				linear
Dense	Dense	32				ReLU
	Dense	1				linear

2.5 评估指标

为了更准确地评估时间序列的数值变化,本研究采用均方根误差(root mean square error,

RMSE)、平均绝对误差(mean absolute error-MAE)和对称平均绝对百分比误差(symmetric mean absolute percentage error, SMAPE)来评估建立模型的预测性能。3 种误差的值越小,表明模型的预测越准确。3 种误差的计算公式分别如下:

$$R_{MSE} = \sqrt{\frac{1}{m} \sum_{k=1}^m (y_k - \hat{y}_k)^2} \quad (5)$$

$$M_{AE} = \frac{1}{m} \sum_{k=1}^m |y_k - \hat{y}_k| \quad (6)$$

$$S_{MAPE} = \frac{1}{m} \sum_{k=1}^m \frac{|y_k - \hat{y}_k|}{(y_k + \hat{y}_k)/2} \quad (7)$$

其中: m 为预测值的数量; y_k, \hat{y}_k 分别为真实值和预测值。

3 实验与分析

3.1 多井联合预测模型预测实验

传统的单井预测模型在生产时间很短时,预测效果不佳,因此本实验充分利用多口井的生产数据,构建了更为鲁棒的多井联合预测模型。

为了体现多井联合预测模型具有更好的预测效果,本文使用 TCN-LSTM 模型进行页岩气井产量预测。选取 Well4 的前 20% 的数据作为训练集,后 80% 的数据作为测试集。Well4 提供了 498 d 的生产数据,共 100 个训练数据和 398 个测试数据。

单井预测模型的预测结果如图 3 所示。图 3 中,蓝色虚线划分训练集和测试集。




图 3 单井预测模型的预测结果

从图 3 可以看出,传统单井预测模型有一定的局限性。一般情况下,生产井的生产周期分为递增期、稳产期和递减期。由于 Well4 前 20% 的生产数据处于缓慢递增期,无法体现递减期特征。因此,单井预测模型在训练时只能捕捉到页岩气井日产气量缓慢递增的趋势特征。当预测后

80%的数据时,该模型无法准确预测出数据的缓慢下降趋势。这体现了单井预测模型的局限性,即它们在训练数据很少或趋势变化较大时,预测准确性会显著下降。因此,采用多井联合预测模型是有必要的。

对于多井数据预测实验,选取 Well1、Well2、Well3 的全部数据以及 Well4 的前 20%的数据作为训练集,Well4 后 80%的数据作为测试集。具体地,Well1 提供了 610 d 的生产数据,Well2 提供了 610 d 的生产数据,Well3 提供了 280 d 的生产数据,Well4 提供了 498 d 的生产数据。总共 1 600 个训练数据和 398 个测试数据作为索引。根据网格搜索法确定的最佳时间片段 t 为 25,即需要叠加 6 层 R-C 块来实现扩张系数 $2^{6-1} > 25$,训练次数为 8 000 次。

为了消除神经网络不同初始化造成的随机性影响,本文模型的预测结果为 10 次训练后的平均值,如图 4a 所示,Well4 的预测结果如图 4b 所示。图 4 中:绿色虚线划分 4 口井;蓝色虚线划分训练集和测试集。




图 4 多井联合预测模型的预测结果

通过在训练集中加入 3 口井的完整生产数据,帮助模型有效学习不同生产周期的特征,从而

在仅学习 Well4 前 20%数据的情况下,就能有效预测递减期的产量。结果表明,通过多井数据的联合训练,模型能够有效利用多口井的数据,大幅提升了预测的准确性和稳定性。

Well4 分别在单井预测模型和多井联合预测模型上的预测误差见表 2 所列。结果显示,多井联合预测模型在所有评估指标上均表现出色,显著优于单井预测模型,证明了其在多井联合预测任务中的卓越性能。表明带有注意力机制的 TCN-LSTM 模型能够更好捕捉特征,提高预测性能。

表 2 单井预测模型与多井联合预测模型的误差

预测模型	R_{MSE}/m^3	M_{AE}/m^3	SMAPE
单井	5 659.51	4 582.98	0.26
多井	2 579.71	1 132.97	0.14

3.2 对比实验

为了验证多头注意力机制相较于自注意力机制在 TCN-LSTM 模型中基于多井数据的页岩气井产量预测的优越性,本实验将带有多头注意力机制的预测模型与带有自注意力机制的预测模型进行对比,此处的训练方式皆为多井联合训练。

本实验的数据选择与前述实验一样,模型最佳参数设置与前述实验相同(见表 1),训练次数为 8 000 次。对比实验的预测结果如图 5 所示。每个模型预测结果取 5 次结果的平均值。




图 5 自注意力机制和多头注意力机制模型的预测结果

图 5 中:红色线代表真实值;黄色线代表带有自注意力机制的 TCN-LSTM 多井联合预测模型的结果;黑色线代表带有多头注意力机制的 TCN-LSTM 多井联合预测模型的结果。Well4 分别在带有自注意力机制的 TCN-LSTM 多井联合预测模

型和带有多头注意力机制的 TCN-LSTM 多井联合预测模型上的预测误差见表 3 所列。

从图 5 和表 3 可以看出,带有多头注意力机制的多井联合预测模型拟合效果比带有自注意力机制的多井联合预测模型更好。

表 3 自注意力机制模型和多头注意力机制模型预测误差

模型	R_{MSE}/m^3	M_{AE}/m^3	S_{MAPE}
自注意力机制模型	2 591.45	1 641.41	0.22
多头注意力机制模型	2 579.71	1 132.97	0.14

3.3 消融实验

本实验旨在验证注意力机制在多井联合预测模型中的作用,通过消融实验比较有、无多头注意力机制的模型性能,以评估其对预测效果的影响。本实验设计了无注意力机制的 TCN-LSTM 模型和带有多头注意力机制的 TCN-LSTM 模型,本实验的数据选择仍与上述实验一致,消融实验的预测结果如图 6 所示。

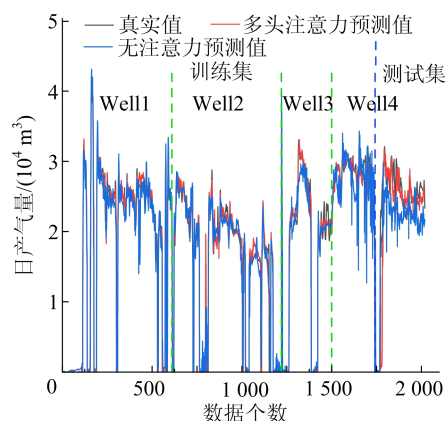


图 6 无注意力机制模型和多头注意力机制模型预测结果

Well 4 分别在 TCN-LSTM 多井联合预测模型和带有多头注意力机制的 TCN-LSTM 多井联合预测模型上的预测误差见表 4 所列。从图 6 和表 4 可以看出,带有多头注意力机制的模型预测效果明显增强,数据的拟合效果更好,更准确地捕捉了趋势的变化。

表 4 无注意力机制模型和多头注意力机制模型预测误差

模型	R_{MSE}/m^3	M_{AE}/m^3	S_{MAPE}
无注意力机制模型	2 934.14	1 837.30	0.31
多头注意力机制模型	2 579.71	1 132.97	0.14

4 结 论

本文提出了一种基于注意力机制的 TCN-LSTM 的页岩气井产量预测模型,通过井口压力

数据来预测产量,得出以下主要结论:

1) 多井联合预测模型在极少数据下,能长时间、高精度预测产量。仅 3 口气井的压力与产量数据、待预测井 100 d 的生产数据进行训练,能准确预测 400 d 的产量,且 SMAPE 小于 0.15。预测时间远远高于训练时间,说明该模型的有效性与其健壮性。以 RMSE 为关键指标,多井联合预测模型的预测精度是单井预测模型的 2.19 倍。

2) 通过对比实验结果发现,以 SMAPE 为关键指标,带有多头注意力机制的 TCN-LSTM 模型预测精度高于带有自注意力机制的 TCN-LSTM 模型,是其 1.57 倍。多头注意力机制借多个头并行运算,可从不同角度捕捉多井数据之间的复杂关系,从而增强模型的特征提取能力和预测鲁棒性。

3) 通过消融实验验证了注意力机制在多井联合预测模型中的作用。多井生产数据中包含大量复杂信息,注意力机制可以自动学习数据中的重要特征,让模型更关注与单井产量预测相关度高的信息。以 MAE 为关键指标,多头注意力模型的预测精度是无注意力机制模型的 1.62 倍。

[参 考 文 献]

- [1] 李道伦,刘旭亮,查文舒,等. 基于卷积神经网络的径向复合油藏自动试井解释方法[J]. 石油勘探与开发, 2020, 47(3): 583-591.
- [2] 宋兆杰,何吉祥,宋宜磊,等. 基于深度学习的页岩油生产井最终可采储量预测模型:以吉木萨尔凹陷芦草沟组为例[J]. 非常规油气, 2025, 12(1): 95-105.
- [3] 孙正心,金衍,孟翰,等. 基于深度学习数据融合的测井数据精细表征[J]. 石油科学通报, 2025, 10(1): 75-86.
- [4] ELMABROUK S, SHIRIF E, MAYORGA R. Artificial neural network modeling for the prediction of oil production[J]. Petroleum Science and Technology, 2014, 32(9): 1123-1130.
- [5] JUAN J M M, POL A L P, GRACIA P M. Artificial neural networks applied to forecasting time series[J]. Psicothema, 2011, 23(2): 322-329.
- [6] ZHU J, JIANG Q, SHEN Y, et al. Application of recurrent neural network to mechanical fault diagnosis: a review[J]. Journal of Mechanical Science and Technology, 2022, 36(2): 527-542.
- [7] WANG H, LONGXIN M U, SHI F, et al. Production prediction at ultra-high water cut stage via Recurrent Neural Network [J]. Petroleum Exploration and Development, 2020, 47(5): 1084-1090.
- [8] ZHANG P, XUE J, LAN C, et al. EleAtt-RNN: adding attentiveness to neurons in recurrent neural networks [J]. IEEE Transactions on Image Processing, 2020, 29: 1061-1073.

(下转第 1275 页)

- 点抗震性能试验研究[J]. 同济大学学报(自然科学版), 2020, 48(3):340-348.
- [10] 雷远德, 曲哲, 王涛. 钢筋混凝土空间框架底层梁柱节点双向往复加载试验研究[J]. 土木工程学报, 2014, 47(12): 64-72, 106.
- [11] HAN L H, ZHENG Y Q, TAO Z. Fire performance of steel-reinforced concrete beam-column joints[J]. Magazine of Concrete Research, 2009, 61(7):409-428.
- [12] 宋天谥. 火灾后钢-混凝土组合框架梁-柱节点的力学性能研究[D]. 北京:清华大学, 2010.
- [13] 谭清华. 火灾后型钢混凝土-柱平面框架力学性能研究[D]. 北京:清华大学, 2012.
- [14] LIE T T. Fire resistance of circular steel columns filled with bar-reinforced concrete[J]. Journal of Structural Engineering, 1994, 120(5):1489-1509.
- [15] 韩林海. 钢管混凝土结构:理论与实践[M]. 3版. 北京:科学出版社, 2016:109-110.
- [16] HONG S, VARMA A H. Analytical modeling of the standard fire behavior of loaded CFT columns[J]. Journal of Constructional Steel Research, 2009, 65(1):54-69.
- [17] ECCS. Safety of steel structures[S]. Sweden: Technical Committee, 1985:1-8.
- [18] GERNAY T, MILLARD A, FRANSSSEN J M. A multi-axial constitutive model for concrete in the fire situation: theoretical formulation[J]. International Journal of Solids and Structures, 2013, 50(22):3659-3673.
- [19] 陈宗平, 徐金俊, 陈宇良, 等. 基于修正 Park-Ang 模型的型钢混凝土异形柱框架节点地震损伤研究[J]. 建筑结构学报, 2015, 36(8):90-98.
- [20] 曾磊. 型钢高强高性能混凝土框架节点抗震性能及设计计算理论研究[D]. 西安:西安建筑科技大学, 2008.
- [21] 韩林海, 宋天谥, 周侃. 钢混凝土组合结构抗火设计原理[M]. 2版. 北京:科学出版社, 2017:271-272.
- [22] ISO. Fire-resistance tests-elements of building construction-part 1:general requirements ;ISO 834-1[S]. Geneva: International Organization for Standardization, 1999:1-25.

(责任编辑 吴亮)

(上接第 1264 页)

- [9] WANG T, WANG Q S, SHI J, et al. Productivity prediction of fractured horizontal well in shale gas reservoirs with machine learning algorithms [J]. Applied Sciences, 2021, 11(24):1-11.
- [10] ZHU Q, LIN B, 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):886-894.
- [11] LI D, ZHOU X, XU Y, et al. Deep learning-based analysis of the main controlling factors of different gas-fields recovery rate[J]. Energy, 2023, 285:128767.
- [12] BAI S, KOLTER J Z, KOLTUN V. An empirical evaluation of generic convolutional and recurrent networks for sequence modeling[EB/OL]. (2018-03-03)[2024-05-01]. <https://arxiv.org/abs/1803.01271>.
- [13] WANG H, ZHANG Z. TATCN: time series prediction model based on time attention mechanism and TCN[C]//2022 IEEE 2nd International Conference on Computer Communication and Artificial Intelligence (CCAI). Beijing: IEEE, 2022:26-31.
- [14] LI D, WANG Z, ZHA W, et al. Predicting production-rate using wellhead pressure for shale gas well based on Temporal Convolutional Network[J]. Journal of Petroleum Science and Engineering, 2022, 216:110644.
- [15] 韩江峡, 薛亮, 位云生, 等. 基于深度自回归神经网络的多井产量概率预测[J]. 石油科学通报, 2024, 9(4):679-689.
- [16] LI X, MA X, XIAO F, et al. A physics-constrained long-term production prediction method for multiple fractured wells using deep learning[J]. Journal of Petroleum Science and Engineering, 2022, 217:110844.
- [17] SHIN H J, LIM J S, JANG I S. Probabilistic prediction of multi-wells production based on production characteristics analysis using key factors in shale formations[J]. Energies, 2021, 14(17):5226.
- [18] SELVIN S, VINAYAKUMAR R, GOPALAKRISHNAN E A, et al. Stock price prediction using LSTM, RNN and CNN-sliding window model[C]//2017 International Conference on Advances in Computing, Communications and Informatics (ICACCI). Udupi: IEEE, 2017:1643-1647.
- [19] 李道伦, 查文舒, 刘旭亮, 等. 深度学习网络在非常规油气开发中的应用研究[J]. 非常规油气, 2024, 11(6):1-7.
- [20] HU X Y, LI B J, SHI J, et al. A novel forecasting method for short-term load based on TCN-GRU model[C]//2021 IEEE International Conference on Energy Internet (ICEDI). Southampton: IEEE, 2021:79-83.
- [21] BAHDANAU D, CHO K, BENGIO Y. Neural machine translation by jointly learning to align and translate[EB/OL]. (2014-09-01)[2024-05-01]. <https://arxiv.org/abs/1409.0473>.
- [22] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. [S. l.]: IEEE, 2016:770-778.

(责任编辑 闫杏丽)