

引用格式:杨晨,彭小龙,朱苏阳,等.一种基于时序注意力动态卷积的油气井产量预测方法[J].油气藏评价与开发,2025,15(6):1046-1055.

YANG Chen, PENG Xiaolong, ZHU Suyang, et al. An oil and gas well production prediction method based on temporal attention and dynamic convolution[J]. Petroleum Reservoir Evaluation and Development, 2025, 15(6): 1046-1055.

DOI: 10.13809/j.cnki.cn32-1825/te.2025.06.010

一种基于时序注意力动态卷积的油气井 产量预测方法

杨晨,彭小龙,朱苏阳,王超文,官文洁,向东流

(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:目前机器学习对油气井产量预测效果不佳的原因在于常规方法过度依赖历史产量数据特征,使得预测结果更多地表现为对历史信息的重组,而难以预测新的趋势。这些方法忽略了其他重要的时序变量,如油气井的开发阶段、压力和产水等对产量的影响。为了解决这些问题,研究提出了压力、产水和产量的关联对策,并建立了一种基于时序注意力动态卷积神经网络的油气井产量预测方法,该方法以时域卷积神经网络为基础模型,引入了多头注意力和动态卷积机制,从而捕捉输入特征序列中不同时间步之间的长期依赖关系,并为每个时间步分配不同的权重。动态卷积模块可以根据时序注意力模块的输出,动态地生成卷积核参数,从而适应不同生产阶段的输入特征。通过安岳采气作业区多井真实复杂案例的验证,展示了基于时序注意力动态卷积的油气井产量预测模型的优越性。研究表明,所提出的模型在面对随机选取的4口井时表现出更好的预测效果。进一步通过对注意力权重和动态卷积权重的可视化分析,发现该模型能够根据不同开发阶段动态调整卷积核权重,特别是针对气井的初始阶段、过渡阶段和衰退阶段。通过结合开发阶段的压力、产水和产量关系,时序注意力动态卷积神经网络模型能自适应调整其结构和参数,从而实现对油气井产量的精准预测。

关键词:油气井产量预测;时域卷积神经网络;多头注意力;动态卷积;自适应

中图分类号:TE319

文献标识码:A

An oil and gas well production prediction method based on temporal attention and dynamic convolution

YANG Chen, PENG Xiaolong, ZHU Suyang, WANG Chaowen, GUAN Wenjie, XIANG Dongliu

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

Abstract: The current poor performance of machine learning in predicting oil and gas well production is primarily due to conventional methods relying excessively on historical production data features, which results in predictions that largely reconstruct past information and struggle to predict new trends. These methods overlook other important time-series variables, such as the development stage of oil and gas wells, pressure, and water production, which affect production. To address these issues, this study proposed strategies associating pressure and water production with output and established a novel oil and gas well production prediction method based on a temporal attention and dynamic convolutional neural network (TADyC). This method used a temporal convolutional neural network as the base model and introduced multi-head attention and dynamic convolution mechanisms to capture long-term dependencies between different time steps in the input feature sequence and assign different weights to each time step. The dynamic convolution module dynamically generated convolution kernel parameters based on the output of the temporal attention module, thereby adapting to the input features across different production stages. The superiority of the TADyC-based oil and gas well production prediction model was demonstrated through validation using multiple real and complex well cases from the Anyue gas production area. The results showed that the proposed model achieved better prediction performance when tested on four randomly selected wells. Furthermore, visualization analysis of the attention and dynamic

收稿日期:2024-08-01。

第一作者简介:杨晨(2000—),男,在读硕士研究生,从事油藏数值模拟和人工智能在油气领域应用方面的研究工作。地址:四川省成都市新都区新都大道8号,邮政编码:610500。E-mail:y1183797365@163.com

通信作者简介:彭小龙(1973—),男,博士,教授,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、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:四川省中央引导地方科技发展项目“油气藏多相渗流突变界面条件建立及数值模拟模型构建”(2022ZYD0003)。

convolution weights revealed that the model could dynamically adjust the convolution kernel weights according to different development stages, particularly for the initial, transition, and decline stages of gas wells. By integrating the relationships between pressure, water production, and production at different development stages, the TADyC model can adaptively adjust its structure and parameters, thereby achieving accurate prediction of oil and gas well production.

Keywords: oil and gas well production prediction; temporal convolutional network; multi-head attention; dynamic convolution; adaptivity

油气井产量数据是油田开发的重要指标,对于认识油藏、编制科学合理的开发调整方案具有指导意义。传统的油气预测模型依赖于数值模拟构建油藏的物理模型,从而模拟油气井的生产过程,但是这种方法需要大量的地层和开发资料,对模型参数选择极为敏感,且在复杂油气藏中预测结果不确定性较高。另外,对于生产周期短的油气藏,传统的油气预测模型生产状态反映也不完全准确。相较于传统方法,机器学习方法无需对油藏的物理模型做出过多假设,其通过挖掘数据中的内在规律来预测油气井的产量,展现出更强的非线性拟合能力和处理复杂数据关系的优势^[1-2]。因此,机器学习方法在油气领域受到了广泛关注,尤其是在油气井产量预测方面。

现有的机器学习方法在油气井产量预测方面普遍存在对历史数据拟合效果好,但对未来数据预测效果差的问题。为此,国内外很多学者开展了广泛的研究,提出了循环神经网络(RNN)^[3]、果蝇算法优化的长短期记忆神经网络模型(LSTM)^[4-5]、基于卷积神经网络(CNN)和LSTM组合的混合模型(CNN-LSTM)^[6]、多层感知器(SVM)^[7]、人工神经网络方法模型^[8]、随机森林^[9]、门控循环网络(GRU)^[10]等产量预测方法。这些模型不断发展反映了人工智能在油气行业应用的创新和进步,但是改进十分有限。关键原因在于这些机器学习方法都基于平稳数据假设,即数据的分布具有稳定的期望和方差^[11],而实际上油气井产量受渗流规律控制,具有明显的趋势性和非平稳性,导致预测方法的原理与数据特征不匹配。

针对这些局限性,研究提出了压力、产水和产量的关

联对策,该对策的核心观点在于产量预测不依赖历史产量数据特征,仅受当前与历史时间步下的压力和产水的影响。同时为更有效地捕捉不同时间步下压力和产水对产量的影响,设计了一种基于时序注意力动态卷积(Temporal Attention and Dynamic Convolution,简称TADyC)的新方法,这是一种在时序卷积网络(TCN)的基础上结合了多头注意力机制和动态卷积机制的深度神经网络,能够根据不同开发阶段的压力、产水和产量的关系自适应地调整深度学习模型的结构和参数。时序注意力动态卷积的主要思想是利用多头注意力机制捕捉时序数据中不同变量之间的相关性和不同时间步间的依赖性,并利用动态卷积机制根据输入数据的特点自动调整卷积核的权重。这样,时序注意力动态卷积就可以有效地提取油气井不同开发阶段下压力、产水和产量的关系特征,从而提高油气井产量预测的准确性和鲁棒性。

1 基本理论

1.1 压力、产水和产量关联对策

传统的机器学习方法在油气井产量预测中效果不佳,主要原因在于这些方法依赖平衡假设,即未来的产量受到过去产量数据特征的影响。然而,产量数据通常具有趋势性和规律性,导致传统方法难以有效预测。现有的油气井产量预测模型虽然能得到高度相似的模拟结果,但预测结果更像是对过去片段的重组。如图1所示,




图1 基于产量数据特征的时序产量预测

Fig. 1 Time-series production prediction based on production data characteristics

虚线框内的预测结果与箭头所指的历史数据高度相似,表明模型更多地依赖于过去数据模式的重复,无法预测新的趋势,存在模拟效果好但预测效果差的问题。

在分析气井生产数据时,日产气量、井底流压和日产水量之间的相互依赖关系是关键因素。常规的基于产量特征时序性的机器学习方法无法准确预测非平稳产量的趋势性。对于非平稳油气井的产量预测,需要建立与压力和产水相关联的机器学习模型,而不能仅依赖产量随时间的变化规律。

1) 相关性分析

在机器学习的多维时间序列分析中,常用的方法包括皮尔逊相关系数^[12]和散点图来分析3列数据之间的相关性。皮尔逊相关系数用于衡量多个变量之间的线性相关性,值越接近1或-1,表示2个变量之间的线性关系越强。通过分析井底流压、日产气量和日产水量之间的相关系数(图2),可以发现存在显著的相关性。




图2 关联数据皮尔逊相关系数分析

Fig. 2 Pearson correlation analysis of related data

2) 物理关系分析

在油气藏开发过程中,气井产量与地层压力和流体特性密切相关。根据热力学定律,温度、压力和体积的变化直接影响流体的流动和产量。通过监测压力和产水量,可以推断出气液的分布与流动特性,从而更加精确地预测产量。同时,地质特征如岩石的孔隙度和渗透率也直接影响气井产量。井底流压与产水量的变化反映了储层地质特性,随着产水量增加,储层水相饱和度上升,气相流动能力降低(相对渗透率下降),导致产气量减少。

综上所述,建立压力、产水和产量的关联模型对于预测非平稳产量数据至关重要,该方法能够更准确地反映实际生产情况,并利用相关变量有效预测日产气量。

1.2 模型理论

1) 时域卷积神经网络

该模型是一种结合了因果卷积和膨胀卷积的序列预测模型,后来GUO等^[13]进一步完善了模型,引入了残

差链接。近年来,已有一些研究将TCN模型应用于油气井产量预测^[14],并取得了较好的效果,该模型能够处理长时间的依赖关系。与常规的RNN相比,TCN在捕捉长序列中远距离依赖特征方面表现更优,尤其是在油气井生产中,TCN模型能够捕捉生产参数对日产气量的累积影响,这种累积效应指的是生产参数对产量的影响不是立即显现,而是随着时间逐渐积累,进而影响日产气量的变化。

2) 多头注意力机制

多头注意力机制能够根据输入数据的变化趋势、周期性、异常值等,动态地分配不同的权重,从而使模型更加关注数据的关键部分。注意力函数对权重进行归一化处理,最后通过加权求和的方式得到最终的注意力输出^[15],公式如下:

$$\mathbf{A}_{\text{Attention}}(\mathbf{Q}, \mathbf{K}, \mathbf{V}) = \text{softmax}\left(\frac{\mathbf{Q}\mathbf{K}^T}{\sqrt{d_k}}\right)\mathbf{V} \quad (1)$$

式中: $\mathbf{A}_{\text{Attention}}$ 为注意力权重矩阵,表示查询矩阵与每个键矩阵的相关性; \mathbf{Q} 为查询矩阵,即当前时间步的压力和产水量等输入数据; \mathbf{K} 为键矩阵; \mathbf{V} 为数值矩阵,表示历史时间步的压力和产水量数据; T 为转置运算; d_k 为 $\mathbf{Q}, \mathbf{K}, \mathbf{V}$ 的维数。

多头自注意力机制将输入序列的表示分成多个子空间,每个子空间使用1个独立的自注意力头进行注意力权重和上下文向量的计算,最后将所有子空间的结果进行拼接或加权求和^[16]。

$$\mathbf{H}_{\text{Multihead}}(\mathbf{Q}, \mathbf{K}, \mathbf{V}) = \mathbf{C}_{\text{Concat}}(\mathbf{H}_1, \mathbf{H}_2, \dots, \mathbf{H}_i)\mathbf{W} \quad (2)$$

$$\mathbf{H}_i = \mathbf{A}_{\text{Attention}}(\mathbf{Q}\mathbf{W}_i^Q, \mathbf{K}\mathbf{W}_i^K, \mathbf{V}\mathbf{W}_i^V) \quad (3)$$

式中: $\mathbf{H}_{\text{Multihead}}$ 为多头注意力机制的整体输出; $\mathbf{C}_{\text{Concat}}$ 为将所有注意力头的输出按特征维度拼接; $\mathbf{H}_1, \mathbf{H}_2, \dots, \mathbf{H}_i$ 为第1到第 n 个注意力头的输出; \mathbf{W} 表示多头注意力机制的权重矩阵; $\mathbf{W}_i^Q, \mathbf{W}_i^K, \mathbf{W}_i^V$ 分别表示 $\mathbf{Q}, \mathbf{K}, \mathbf{V}$ 在第 i 个注意力头的权重矩阵。

3) 动态卷积机制

在传统的卷积网络中,卷积的形状和位置都是固定不变的,这限制了网络的灵活性,无法动态自适应地提取产量数据特征。而引入动态卷积,则可以根据输入数据的特征动态地调整卷积核参数。

动态卷积结构通过聚合 k 个线性函数($\tilde{\mathbf{W}}_k^T x + \tilde{b}$)构成^[17]。

$$y = g(\tilde{\mathbf{W}}^T x + \tilde{b}) \quad (4)$$

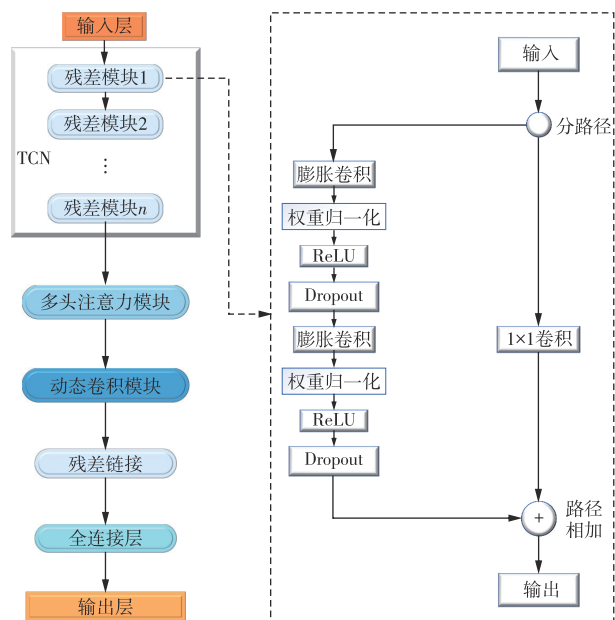
$$\tilde{\mathbf{W}} = \sum_{k=1}^K \pi_k(x) \tilde{\mathbf{W}}_k \quad (5)$$

$$\tilde{b} = \sum_{k=1}^K \pi_k(x) \tilde{b}_k \quad (6)$$

式中: g 为激活函数; \tilde{W}^T 为第 k 个静态卷积核的权重矩阵进行了转置运算; \tilde{b} 为偏置向量,由 k 个基础偏置向量 \tilde{b}_k 与 $\pi_k(x)$ 加权求和得到; \tilde{W} 为权重矩阵,由 k 个基础权重矩阵 \tilde{W}_k 按照输入相关的注意力权重 $\pi_k(x)$ 加权求和得到; K 为总数量; $\pi_k(x)$ 为 x 的注意力权重; k 为求和索引变量,用于遍历从1到 k 的所有项; \tilde{W}_k 为第 k 个静态卷积核的权重矩阵; \tilde{b}_k 为第 k 个静态卷积核的偏置向量。输入值 x 通过动态计算的权重 \tilde{W} 进行线性变换,再加上偏置向量 \tilde{b} ,最后通过激活函数 g ,得到最终的输出值 y ^[18]。

2 时序注意力动态卷积产量预测方法构建

TADyC 油气井产量预测模型是基于 Pytorch 框架实现的,其核心在于自适应调整卷积核参数以适应不同时间步下的输入特征。该模型主要由残差模块、多头注意力模块和动态卷积模块等组成(图3)。残差模块解决深层网络训练困难的问题,防止网络退化;多头注意力模块捕捉输入特征序列中不同时间步位置之间的长期依赖关系,并为每个位置分配不同权重^[13];动态卷积模块则根据多头注意力模块的输出动态生成卷积核参数,提取局部特征并适应不同长度的输入数据。



注:ReLU为激活函数;Dropout为正则化层。

图3 TADyC 油气井产量预测模型结构

Fig. 3 Structure of TADyC-based oil and gas well production prediction model

模型中多头注意力模块和动态卷积模块相互配合(图4),首先,多头注意力将上一层的输入数据分为多个子空间,每个子空间使用独立的自注意力头计算注意力权重,然后将每个自注意力头的输出向量拼接或加权求

和,得到新的序列,并将其输入到动态卷积模块,该模块根据输入序列为每个静态卷积核分配权重,再通过加权平均得到动态卷积核。

TADyC 模型的设计使其具备了强大的自适应能力,能够同时捕捉输入序列的多方面信息。在油气井产量预测中,需考虑压力和产水的变化趋势及其相互影响。单头注意力机制可能会忽略一些重要的信息,导致预测结果不准确,而多头注意力机制能够关注压力和产水的不同方面,比如均值、方差、峰值、周期等,并将这些特征融合,实现更全面的产量预测。此外,动态卷积机制的引入进一步增强了模型的自适应能力。当压力或产水发生突变时,模型可以通过调整卷积核参数来适应这些变化,以提高预测精度。

在资源需求方面,TADyC 模型的设计并未显著增加计算的复杂性,在此次研究应用案例中,训练集规模为几万到十几万条数据,训练时间为几天。以 GeForce GTX 3090Ti 24 GB 显存为例,其对安岳井区完整的训练过程需要4~5 d,而实现理想结果需要不断进行参数调优和测试指标记录,整个过程可能长达1个月。

3 应用实例

3.1 四川盆地安岳气田GS井区复杂案例分析

选取四川盆地安岳气田GS井区灯影组四段的气井作为研究对象,四川盆地安岳气田是中国古老的海相碳酸盐岩原生型气田^[19-21],其埋深介于4 500~6 000 m,经受了多期构造运动的影响。钻遇厚度介于150~380 m,主要发育丘滩相和滩间海沉积,岩性以砂屑云岩、藻凝块云岩、藻叠层云岩、泥晶云岩和泥质云岩为主,储层基质致密,储集空间以次生溶孔、溶洞为主,总体表现为低孔隙度、低渗透率^[22]。截至2020年底,GS井区灯影组碳酸盐岩储层探明地质储量近 $6\ 000 \times 10^8 \text{ m}^3$,有良好的勘探开发背景。但是开发实践表明:GS井区储层流体渗流规律复杂,气井产能差异明显,一定程度上制约了气藏的高效开发^[23]。

3.2 评价指标

为了评估和比较该模型与其他模型的性能,选取了3种评价指标: L_{MAPE} 、 L_{SMAPE} 和 R^2 ,计算如式(7)~式(9)所示。

$$L_{MAPE} = \frac{1}{n} \sum_{i=1}^n \left| \frac{\hat{y}_i - y_i}{y_i} \right| \times 100\% \quad (7)$$

$$L_{SMAPE} = \frac{1}{n} \sum_{i=1}^n \frac{|\hat{y}_i - y_i|}{(|\hat{y}_i| + |y_i|)/2} \times 100\% \quad (8)$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (9)$$

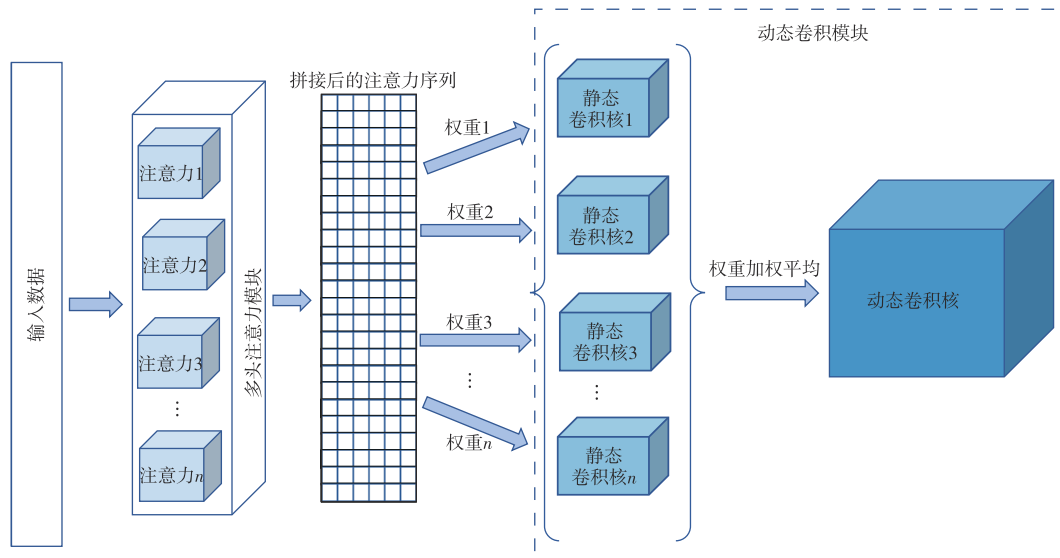


图4 多头注意力动态卷积结构

Fig. 4 Structure of multi-head attention dynamic convolution

式中： L_{MAPE} 为平均绝对百分比误差，衡量模型预测值与真实值的平均相对误差； L_{SMAPE} 为对称平均绝对百分比误差，相比 L_{MAPE} 考虑了预测值和真实值的对称差异； R^2 为决定系数，用于衡量模型预测效果的统计指标，取值0~1，数值越接近1表明模型的解释力越强； y_i 为样本*i*对应的实际值； \hat{y}_i 为样本*i*给出的预测值； \bar{y} 为样本的平均值； n 为样本的总量。

3.3 特征选取与数据预处理

完成数据采集后，首先对样本数据进行划分。将2012年9月22日至2018年4月8日期间的GS区块所有井数据作为训练集，随机选取4口井2018年4月9日至2020年9月24日期间的生产数据作为测试集，从训练集中随机抽取部分数据作为验证集，用于调整模型的超参数并选择最优模型。

通过分析产量的皮尔逊相关系数热力图(图5)，确定了日生产时间、井底流压、井口油压、日产水量、日产气量之间存在较强的相关性。因此，选取这些变量作为输入特征，日产气量作为输出特征。滑动时间窗口长度设定为30 d，以捕捉生产活动中的月度变化和趋势，并考虑压力在地层中传递的滞后性。

产量预测基于输入特征(如压力和产水量)，这些变量共同决定日产气量，而非直接依赖于历史产量数据。通过这种方法，可以建立1个更能反映实际生产情况的模型，利用这些相关变量有效预测日产气量。

在进行模型训练前，首先对数据进行单位根检验(ADF)，ADF是一种用于判断时间序列数据是否具有平稳性的统计检验方法。若*p*值(概率值)小于显著性水平(通常为0.05)，则拒绝原假设，认为时间序列是平稳的。

井口油压和井底流压是2个相关的变量，表1展示了井底流压、日产气量和日产水量的检验结果。所有变量的*p*值均高于0.05，表明这些时间序列是非平稳的。

传统的基于统计分析的产量预测方法不适用于非平稳数据，为消除数据中的趋势性，通常采用对数变换、差分、小波分解等平稳化方法。然而这些方法会忽略数据的重要信息，影响预测效果^[24]。时序注意力动态卷积新模型可以直接处理非平稳的数据，避免平稳化操作。为了去除数据中的噪声和异常值，设计了1个四阶低通




图5 变量间皮尔逊相关系数热力图

Fig. 5 Heatmap of Pearson correlation coefficients between variables

表1 数据的单位根检验
Table 1 Unit root test of data

分类	井底流压/ MPa	日产气量/ m ³	日产水量/ m ³
ADF平稳性检验	2.476 0	1.880 6	2.536 2
<i>p</i> 值(概率值)	0.121 4	0.341 2	0.106 8

滤波器进行数据平滑处理。该滤波器基于巴特沃斯滤波器设计原理,在截断频率以下提供平坦的频率响应,确保数据中的低频信息被保留,同时抑制高频噪声。通过设置截断频率为0.1,应用于归一化后的数据,然后进行反归一化,恢复原始数据的尺度。在保持原始数据的非平稳性和趋势性的前提下,实现了对数据的平滑处理。

3.4 模型参数设计

采用归一化方法将数据转换到[0, 1],减少数据的量纲和尺度差异。多头注意力头数设置为4,其他模型参数如表2所示。模型优化采用Adam算法,学习率设置为0.01。

3.5 模型对比分析

选取LSTM、TCN、SA-TCN(自注意力时间卷积网络)和SA-LSTM(自注意力长短时记忆网络)作为对比模型

表2 TADyC模型网络参数
Table 2 TADyC model network parameters

网络层	滤波器数量	卷积核大小	作用	相关参数
1	128	2	特征提取	in_channels =128, out_channels =128,
2	64	2	特征提取	in_channels =128, out_channels =64,
3	32	2	特征提取	in_channels =64, out_channels =32,
4	32	2	引入注意力机制	in_channels =32, out_channels =32, num_heads=4
5	16	2	引入注意力机制	in_channels =32, out_channels =16, num_heads=4
6	16	3	动态卷积层	in_channels=16, out_channels=16,
7	0	0	全连接层	in_features=16, out_features=1

进行训练和测试,通过评价指标评估各个模型在未知数据上的预测效果,实验结果见表3。图6展示了每个模型对GS1、GS2、GS3、GS7井的产量预测与实际产量的对比。

表3 四川盆地安岳气田GS井区4口井不同产量预测模型的评价指标值

Table 3 Evaluation indicators for different production prediction models of wells GS1, GS2, GS3, and GS7

模型	GS1井		GS2井		GS3井			GS7井		
	$L_{MAPE}/\%$	$L_{SMAPE}/\%$	$L_{MAPE}/\%$	$L_{SMAPE}/\%$	$L_{MAPE}/\%$	$L_{SMAPE}/\%$	R^2	$L_{MAPE}/\%$	$L_{SMAPE}/\%$	R^2
TADyC	3.882 8	3.949 8	7.968 1	7.206 9	9.358 5	9.500 2	0.984 9	6.978 9	6.715 9	0.984 6
TCN	5.093 3	5.083 8	12.614 3	9.962 0	8.001 8	8.781 6	0.974 2	9.947 9	9.159 0	0.961 5
LSTM	5.955 3	5.631 2	15.208 3	11.784 0	9.645 2	9.010 7	0.979 3	20.677 9	23.191 8	0.909 9
SA-TCN	4.433 6	4.428 4	8.726 0	7.883 2	8.501 1	8.398 1	0.980 3	12.824 9	13.531 0	0.957 4
SA-LSTM	5.086 0	5.116 9	14.925 6	9.816 6	11.382 4	13.733 54	0.970 9	16.735 9	18.221 7	0.941 1

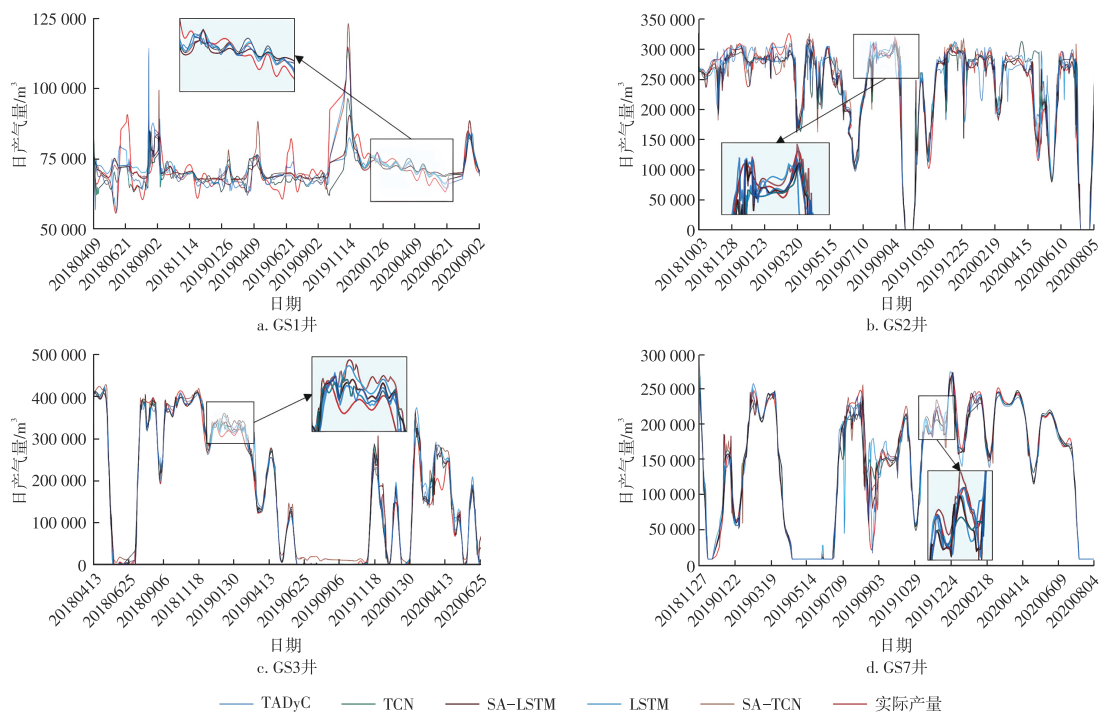


图6 四川盆地安岳气田GS井区4口气井的5个模型预测产量与实际产量局部放大对比分析

Fig. 6 Comparative analysis with local magnification of predicted and actual production by five models for four gas wells in GS well area, Anyue gasfield, Sichuan Basin

为了更清晰地观察不同模型的预测表现,图6对部分关键时间段的数据进行了局部放大。选取特定区域的数据,并用方框标注,同时通过箭头指向相应的放大部分。表3、图6显示TADyC模型在各项评价指标上均表现优异,预测效果最佳。TCN模型在基础模型中优于LSTM,而SA-TCN在注意力机制方面优于SA-LSTM,表明注意力机制与TCN的结合更有效。相比之下,TADyC模型在多井案例中的表现更为优异,进一步验证了其在处理实际油气田非平稳生产数据时的适应性。这种自适应能力确保了该模型在油气井产量预测任务中具有显著优势,能够根据油气井开发的不同阶段,自适应地调整深度学习模型的结构和参数,以准确预测产量,为未来的应用和研究提供了新的方向。

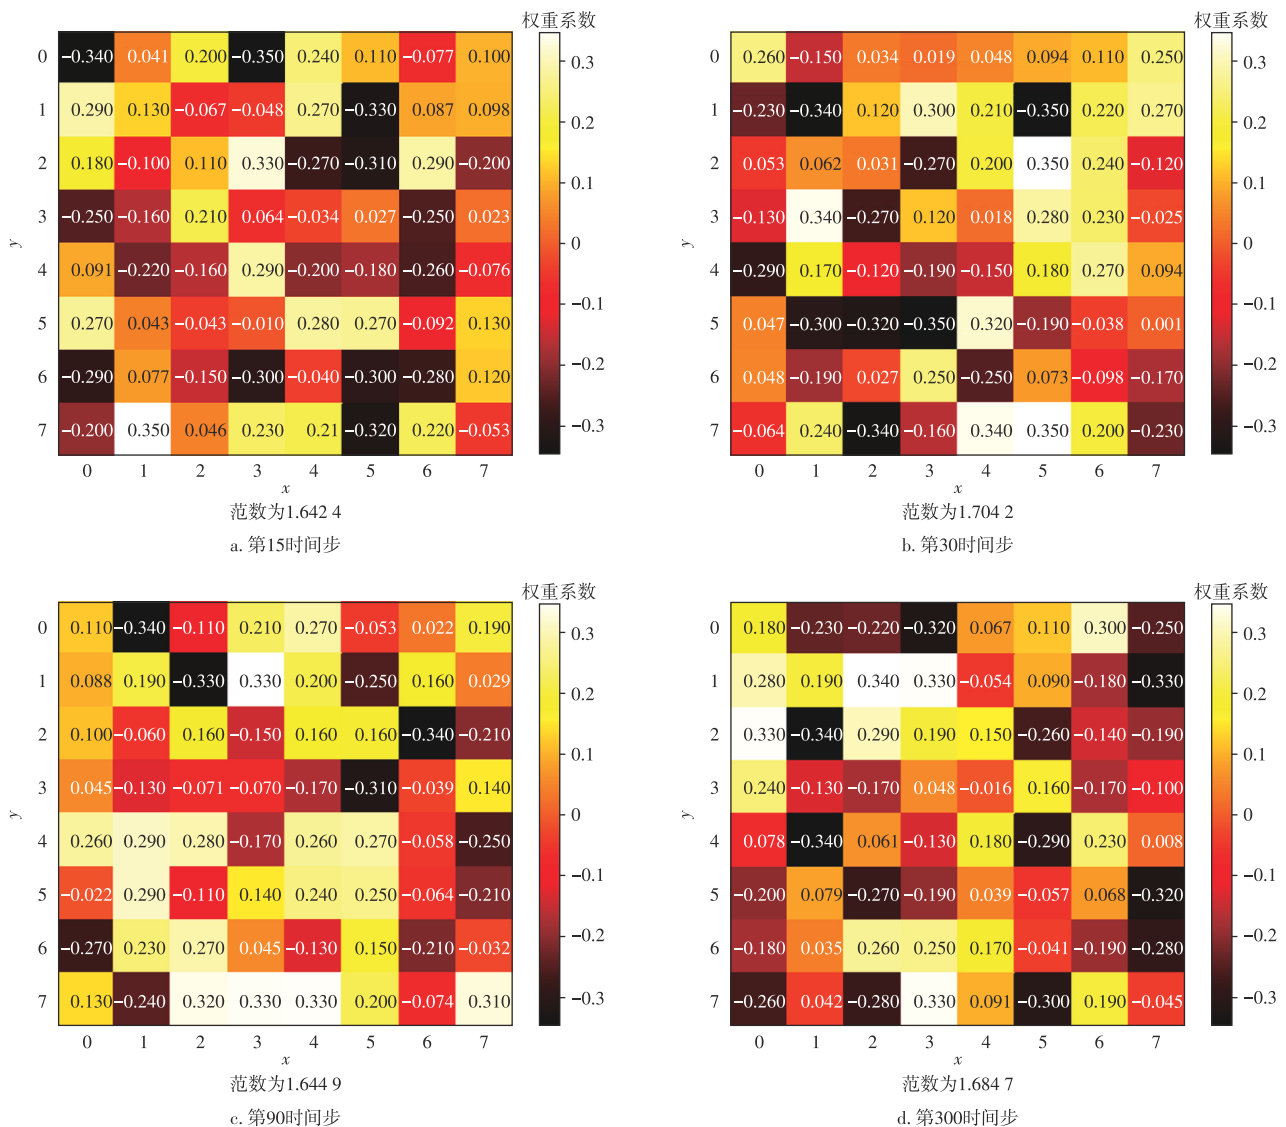
3.6 TADyC 动态性可视化分析

为了深入分析TADyC模型的内部机制和特征提取

能力,对其时序注意力机制和动态卷积机制的权重进行了可视化展示。选取GS1井的第15、第30、第90、第300时间步的输入特征作为测试数据,生成相应的时序注意力权重矩阵和动态卷积权重矩阵,并用热力图及其范数表示(图7、图8)。注意力权重矩阵反映了序列中不同时间步之间的相关性,该矩阵用于表示序列中各元素的关注程度(图7)。

动态卷积权重矩阵反映了模型对不同卷积核的调节性,权重系数越大,卷积核的特征提取能力越强。动态卷积权重矩阵是为当前时间步生成的,作用是对多个静态卷积核分配不同的权重系数(图8)。

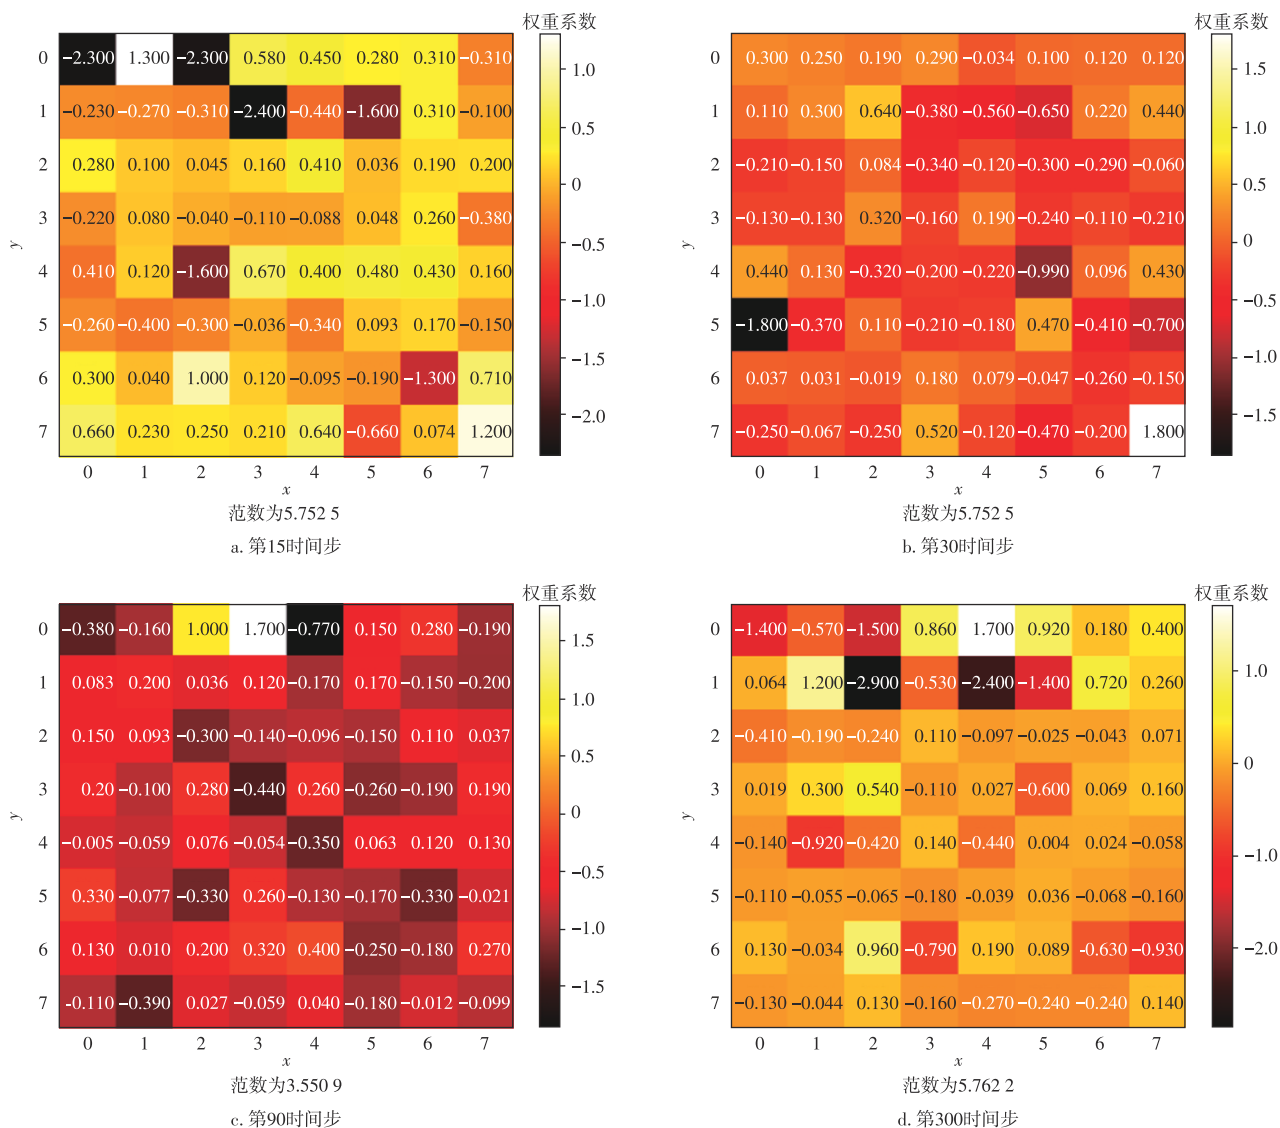
在第15时间步的动态卷积权重系数较大,表明气井的初始阶段气藏的驱动能量较高,流动性较好,压力和产水的变化对产量影响显著,所以模型需要更多的卷积核来捕捉这些变化的特征。在第90时间步的权重系数最



注: x 轴表示查询(Query)的索引; y 轴表示键(Key)的索引;矩阵中的数值表示查询对键的注意力权重值。

图7 不同时间步下的注意力权重矩阵

Fig. 7 Attention weight matrices at different time steps



注:x轴表示静态卷积核的索引;y轴表示通道的索引;矩阵中的数值表示各通道对不同卷积核的加权程度。

图8 不同时间步下的动态卷积权重矩阵

Fig. 8 Dynamic convolution weight matrices at different time steps

小,因为在气井的稳定阶段,气藏的驱动能量较低,变量变化对产量的影响减弱,需要更少的卷积核来捕捉这些变化的特征。第30时间步的权重系数较第15时间步有所减小,表明过渡阶段压力和产水变化趋于平缓,模型对压力和产水变化的敏感度有所降低。相反,在第300时间步的动态卷积权重系数有所增大,表明在气井的衰减阶段,压力和产水的变化较为剧烈,对于产量的影响也较为显著,模型对压力和产水变化的敏感度提升。

注意力权重系数的变化较为稳定,但动态卷积权重系数在不同时间步之间变化显著。由式(5)可知,不同时间步的注意力权重 $\pi_k(x)$ 可能相似,但也仅仅是固定的权重矩阵 \tilde{W}_k 加权求和的系数,只要 $\pi_k(x)$ 有细微变化,就会导致动态卷积权重 \tilde{W} 的显著差异。

这些结果表明:TADyC模型能够根据气井的不同开

发阶段动态地调整卷积核权重,对于压力和产水变化在不同时间步上具有一致的关注度,无论是在气井的初始阶段、过渡阶段还是衰减阶段,模型都能保持对这些变化的敏感性,并有效地捕捉压力和产水变化与产量变化之间的非线性关系。通过可视化分析展示了模型的内在逻辑和优越性,验证了模型的有效性。

4 结论

1) 鉴于当前深度学习模型在油气井产量预测中的局限性,提出了压力、产水和产量的关联对策,并建立了一种新的产量预测模型,即TADyC模型。该模型利用多头注意力机制来捕捉油气井输入特征在不同时间步下的相关性,根据输入数据调整注意力权重,并根据注意力模块的输出动态地调整卷积核的权重,从而实现模型的动

态性变化。

2) 通过安岳气田多井的复杂案例进行实验和对比分析,结果表明TADyC模型较其他对比模型具有更高的拟合度和泛化能力。为了深入探索模型中多头注意力模块和动态卷积模块的参数权重变化,对2个模块的不同时间步的权重变化进行可视化分析,通过热力图的形式展现出该模型可以实现根据不同的油气井开发阶段,动态地调整卷积核的权重。

3) TADyC模型能够自适应地调整网络结构和参数以适应不同开发阶段的压力和产水对产量的影响,为油气井的优化开发和管理提供了一种新的思路和方法。在未来的研究中,可以考虑引入更多的影响油气井产量的因素,如地质参数、工程参数等,进一步提高模型的性能和泛化能力。

参考文献

- [1] 林魂,孙新毅,宋西翔,等.基于改进人工神经网络的页岩气井产量预测模型研究[J].油气藏评价与开发,2023,13(4):467-473.
LIN Hun, SUN Xinyi, SONG Xixiang, et al. A model for shale gas well production prediction based on improved artificial neural network[J]. Petroleum Reservoir Evaluation and Development, 2023, 13(4): 467-473.
- [2] 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.
- [3] MAGNUSSON L V, OLSSON J R, TRAN C T T. Recurrent neural networks for oil well event prediction[J]. IEEE Intelligent Systems, 2023, 38(2): 73-80.
- [4] 任燕龙,谷建伟,崔文富,等.基于改进果蝇算法和长短期记忆神经网络的油田产量预测模型[J].科学技术与工程,2020,20(18):7245-7251.
REN Yanlong, GU Jianwei, CUI Wenfu, et al. Oilfield production prediction model based on improved fruit fly algorithm and long-short term memory neural network[J]. Science Technology and Engineering, 2020, 20(18): 7245-7251.
- [5] LU W J, MA L, CHEN H, et al. A clinical prediction model in health time series data based on long short-term memory network optimized by fruit fly optimization algorithm[J]. IEEE Access, 2020, 8: 136014-136023.
- [6] ABDULLAYEVA F, IMAMVERDIYEV Y. Development of oil production forecasting method based on deep learning[J]. Statistics, Optimization & Information Computing, 2019, 7(4): 826-839.
- [7] QIAO Y D, PENG J, GE L, et al. Application of PSO LS-SVM forecasting model in oil and gas production forecast[C]//2017 IEEE 16th International Conference on Cognitive Informatics & Cognitive Computing. Oxford, United Kingdom, 26-28 July, 2017.
- [8] 白蕾,王世玉,张璐,等.基于MAE神经网络的测井曲线地层自动识别方法[J].天然气勘探与开发,2024,47(4):63-71.
BAI Ru, WANG Shiyu, ZHANG Lu, et al. An automatic identifying method for strata via logging curves based on MAE neural network[J]. Natural Gas Exploration and Development, 2024, 47(4): 63-71.
- [9] XUE L L, YUE T, XIONG Y F, et al. A data-driven shale gas production forecasting method based on the multi-objective random forest regression(Article) [J]. Journal of Petroleum Science and Engineering, 2021, 196: 107801.
- [10] QIN X Z, HU X H, LIU H, et al. A combined gated recurrent unit and multi-layer perception neural network model for predicting shale gas production[J]. Processes, 2023, 11(3): 806.
- [11] 周道勇,汪小平,张娜,等.基于机器学习的气藏相对渗透率曲线确定方法[J].天然气勘探与开发,2024,47(4):89-98.
ZHOU Daoyong, WANG Xiaoping, ZHANG Na, et al. Determine relative permeability curves for gas reservoirs based on machine learning[J]. Natural Gas Exploration and Development, 2024, 47(4): 89-98.
- [12] 纪德洋,金锋,冬雷,等.基于皮尔逊相关系数的光伏电站数据修复[J].中国电机工程学报,2022,42(4):1514-1523.
JI Deyang, JIN Feng, DONG Lei, et al. Data repairing of photovoltaic power plant based on Pearson correlation coefficient[J]. Proceedings of the CSEE, 2022, 42(4): 1514-1523.
- [13] GUO C, KANG X M, XIONG J P, et al. A new time series forecasting model based on complete ensemble empirical mode decomposition with adaptive noise and temporal convolutional network[J]. Neural Processing Letters, 2023, 55(4): 4397-4417.
- [14] 张蕾,窦宏恩,王天智,等.基于集成时域卷积神经网络模型的水驱油田单井产量预测方法[J].石油勘探与开发,2022,49(5):996-1004.
ZHANG Lei, DOU Hongen, WANG Tianzhi, et al. A production prediction method of single well in water flooding oilfield based on integrated temporal convolutional network model[J]. Petroleum Exploration and Development, 2022, 49(5): 996-1004.
- [15] 王炼红,罗志辉,林飞鹏,等.采用多头注意力机制的C&RM-MAKT预测算法[J].电子学报,2023,51(5):1215-1222.
WANG Lianhong, LUO Zhihui, LIN Feipeng, et al. C & RM-MAKT prediction algorithm using multi-head attention mechanism[J]. Acta Electronica Sinica, 2023, 51(5): 1215-1222.
- [16] YU Kun, QIN Xizhong, JIA Zhenhong, et al. Cross-attention fusion based spatial-temporal multi-graph convolutional network for traffic flow prediction[J]. Sensors, 2021, 21(24): 8468.
- [17] 耿韶松,李晋国.基于动态卷积与注意力的多特征融合行人重识别[J].计算机工程与设计,2023,44(4):1228-1234.
GENG Shaosong, LI Jinguo. Person re-identification based on multi-feature fusion of dynamic convolution and attention[J]. Computer Engineering and Design, 2023, 44(4): 1228-1234.
- [18] QIAN J J, LIN J, BAI D, et al. Omni-dimensional dynamic convolution meets bottleneck transformer: A novel improved high accuracy forest fire smoke detection model[J]. Forests, 2023, 14(4): 838.
- [19] 徐睿,张飞,蔡珺君,等.基于储层发育主控因素的碳酸盐岩储层

- 定量分类评价:以四川盆地安岳气田台内带灯影组四段气藏为例[J]. 天然气勘探与开发, 2024, 47(6): 62-69.
- XU Rui, ZHANG Fei, CAI Junjun, et al. Quantitatively classifying and evaluating carbonate reservoirs based on main controls on reservoir development: An example from Dengying 4 Member in the intra-platform zone, Anyue gasfield, Sichuan Basin[J]. Natural Gas Exploration and Development, 2024, 47(6): 62-69.
- [20] 罗炫, 张文彪, 严鸿, 等. 高含水致密凝析气藏稳产技术应用: 以四川盆地安岳气田须家河组气藏为例[J]. 天然气勘探与开发, 2024, 47(1): 83-88.
- LUO Xuan, ZHANG Wenbiao, YAN Hong, et al. Production-stabilizing technologies for tight condensate gas reservoirs rich in water cut: An example from Xujiahe Formation, Anyue gasfield, Sichuan Basin[J]. Natural Gas Exploration and Development, 2024, 47(1): 83-88.
- [21] 彭越, 张满郎, 李明秋, 等. 基于图像识别技术的裂缝发育程度定量评价新方法: 以安岳气田须二气藏为例[J]. 非常规油气, 2024, 11(1): 12-21.
- PENG Yue, ZHANG Manlang, LI Mingqiu, et al. A new method for quantitative evaluation of fracture development degree based on image recognition technology: Take the Xu2 gas reservoir in the Anyue gas field as an example[J]. Unconventional Oil & Gas, 2024, 11(1):12-21.
- [22] 严鸿, 商绍芬, 张铭, 等. 安岳气田高石梯区块上震旦统灯四段气藏动态监测及认识[J]. 天然气技术与经济, 2020, 14(4): 5-11.
- YAN Hong, SHANG Shaofen, ZHANG Ming, et al. Performance monitoring and understandings on gas reservoirs of the Upper Sinian Dengying 4 Member, Gaoshiti block, Anyue gasfield, Sichuan Basin [J]. Natural Gas Technology and Economy, 2020, 14(4): 5-11.
- [23] 史今雄, 赵向原, 潘仁芳, 等. 川中地区震旦系灯影组碳酸盐岩天然裂缝特征及其对气井产能影响[J]. 石油与天然气地质, 2023, 44(2): 393-405.
- SHI Jinxiong, ZHAO Xiangyuan, PAN Renfang, et al. Characteristics of natural fractures in carbonate reservoirs and their impacts on well productivity in the Sinian Dengying Formation, central Sichuan Basin [J]. Oil & Gas Geology, 2023, 44(2): 393-405.
- [24] WAN J S, XIA N, YIN Y T, et al. TCD former: A transformer framework for non-stationary time series forecasting based on trend and change-point detection[J]. Neural Networks, 2024, 173: 106196.

(编辑 黄颖)