



DOI:10.12404/j.issn.1671-1815.2407065

引用格式:唐凯,李忠慧,曹天宝,等.基于 CNN-Attn 神经网络的孔隙压力预测[J].科学技术与工程,2025,25(22):9335-9341.

Tang Kai, Li Zhonghui, Cao Tianbao, et al. Pore pressure prediction model based on CNN-Attn neural network[J]. Science Technology and Engineering, 2025, 25(22): 9335-9341.

石油、天然气工业

基于 CNN-Attn 神经网络的孔隙压力预测

唐凯^{1,2}, 李忠慧^{1,2*}, 曹天宝^{1,2}, 胡棚杰^{1,2}

(1. 油气钻采工程湖北省重点实验室, 武汉 430100; 2. 长江大学石油工程学院油气钻完井技术国家工程研究中心, 武汉 430100)

摘要 在石油和天然气的勘探开发中,人工智能模型被广泛应用于地层孔隙压力的预测。其中单一模型容易出现过拟合或预测结果不稳定的问题,在预测精度和泛化能力方面仍有提升空间。为了提高地层孔隙压力预测精度,基于深度学习技术,建立了 CNN-Attn 神经网络地层孔隙压力预测模型。优选了 5 种测井和随钻数据,使用 Pearson 相关系数法验证数据与地层孔隙压力的线性相关性。通过对一维 CNN 的结构进行优化,使模型能够有效捕捉数据的局部特征,并与自注意力机制结合,增强模型对全局依赖关系的捕捉能力,从而提高模型的表现力和理解能力。为了验证该模型的预测精度,对巴彦区块两口井进行预测,预测结果的平均绝对误差均小于 1 MPa,均方根误差均小于 1 MPa,平均相对误差均小于 1.3%,决定系数均大于 0.9,比 BP、CNN 和 LSTM 模型精度高。该模型提升了地层孔隙压力预测精度,并为钻井安全性提供了数据支持。

关键词 地层孔隙压力; 智能预测; 深度学习; 卷积神经网络; 自注意力机制

中图分类号 TE242;

文献标志码 A

Pore Pressure Prediction Model Based on CNN-Attn Neural Network

TANG Kai^{1,2}, LI Zhong-hui^{1,2*}, CAO Tian-bao^{1,2}, HU Peng-jie^{1,2}

(1. Key Laboratory of Drilling and Production Engineering for Oil and Gas, Wuhan 430100, China; 2. School of Petroleum Engineering, Yangtze University, National Engineering Research Center for Oil & Gas Drilling and Completion Technology, Wuhan 430100, China)

[Abstract] In the exploration and exploitation of oil and gas, artificial intelligence models are extensively employed in the prediction of formation pore pressure. Among them, single models tend to encounter problems such as overfitting or unstable prediction outcomes, leaving room for improvement in aspects like prediction accuracy and generalization ability. To enhance the prediction accuracy of formation pore pressure, a CNN-Attn neural network-based formation pore pressure prediction model was established by virtue of deep learning technology. In this research, five types of logging and while-drilling data were optimally selected, and the linear correlation between the data and formation pore pressure was verified using the Pearson correlation coefficient method. Through the optimization of the structure of the one-dimensional CNN, the model can effectively capture the local characteristics of the data and, when combined with the self-attention mechanism, strengthen the model's ability to capture global dependencies, thereby elevating the model's expressiveness and comprehension. To validate the prediction accuracy of this model, two wells in the Bayan block were subjected to prediction. The average absolute errors of the prediction results were both less than 1 MPa, the root mean square errors were both less than 1 MPa, the average relative errors were both less than 1.3%, and the determination coefficients were both greater than 0.9, with higher accuracy compared to the BP, CNN, and LSTM models. This model has improved the prediction accuracy of formation pore pressure and provided data support for drilling safety.

[Keywords] formation pore pressure; intelligent prediction; deep learning; convolutional neural network; self-attention mechanism

在石油和天然气勘探开发中,准确预测地层孔隙压力对于钻井作业的成功至关重要。地层孔隙压力能够有效指导泥浆密度和套管程序的设计,提高钻井时效性^[1]。随着向更深的地层钻进,地下环境变得更加复杂,钻井难度随之增大,未能准确预

测地层孔隙压力可能导致井壁坍塌、井漏或井喷等井壁稳定问题,加大泥浆设计难度,威胁钻井作业的安全性和增加钻井成本。

当前的孔隙压力预测方法主要包括有效应力法、Eaton 法和等效深度法^[2]。但由于对经验参数

收稿日期: 2024-09-21; 修订日期: 2025-05-13

第一作者: 唐凯(2001—),男,汉族,湖北仙桃人,硕士研究生。研究方向:人工智能技术与钻井工程。E-mail:1430600329@qq.com。

*通信作者: 李忠慧(1977—),男,汉族,吉林公主岭人,博士,教授,研究方向:岩石力学与钻完井工程。E-mail:lizhonghui@yangtzeu.edu.cn。

投稿网址:www.stae.com.cn

的依赖,逐渐难以满足复杂地层的变化,亟需新的方法予以应对。人工智能技术可以构建出高度智能化的模型,这些模型能够从大数据中自主学习并深入理解相关参数与预测值之间复杂的关系,具有高效性和精准性。例如,毕臣臣^[3]针对仅考虑单因素线性关系导致预测结果误差大的问题,提出了基于深度学习的 TOC (total organic carbon) 含量预测方法,提高了页岩储层 TOC 含量的预测精度及分辨率。马陇飞等^[4]针对钻井取心成本大的问题,建立了测井数据与岩性数据的神经网络模型,准确率达到了 71%。杨琨等^[5]针对目前缺乏有效预测玛湖砾岩油藏压裂甜点方法的问题和提高水平井压裂改造效果的迫切需求,建立了基于机器学习的致密砾岩油藏压裂甜点预测模型,表现出较好的性能。因此,深度学习等前沿技术已广泛应用于测井、物探和钻完井等领域^[6],并在钻井和地层参数预测中展现出巨大潜力^[7-9]。近年来,人工智能技术的崛起为地层孔隙压力预测带来了新的可能。研究人员已尝试采用多种人工智能模型来预测孔隙压力,并取得了显著成果。例如,李萍等^[10]采用随机森林、XGBoost (eXtreme gradient boosting) 和 LightGBM (light gradient boosting machine) 3 种机器学习模型进行预测,结果显示 XGBoost 和 LightGBM 的预测趋势更加稳定,而随机森林模型则存在过拟合,使得实际孔隙压力预测过程中误差较大。Karmakar 等^[11]采用贝叶斯神经网络,考虑了前序地层孔隙压力与当前地层压力之间的联系。Keshavarzi 等^[12]利用误差反向传播神经网络 (back propagation, BP) 预测伊朗 Asmari 油田的孔隙压力梯度,结果显示其预测精度优于 Eaton 法,但 BP 神经网络在长序列数据中容易出现梯度消失或梯度爆炸的问题,这会导致地层孔隙压力预测结果偏差大。罗发强等^[13]研究了长短期记忆神经网络模型 (long short-term memory, LSTM) 在地层孔隙压力预测中的表现,发现 LSTM 模型相较于 BP 模型具有更好的记忆能力和预测效果。宋先知等^[14]将 LSTM 模型与自适应学习能力的 BP 模型结合形成的 LSTM-BP 模型,优于单独的 BP、LSTM 和 SVM 模型,提高了地层孔隙压力预测的准确度,表明融合模型是提高预测准确度的一种途径。另一方面,Ahmed 等^[15]采用支持向量机 (support vector machine, SVM) 及其他人工智能工具进行地层孔隙压力预测。这些方法无需依赖正常压力趋势,即可直接预测地层孔隙压力,并且 SVM 具有预测时间短、效率高的特点。Matinkia 等^[16]对比了 9 种人工智能模型,结果显示卷积神经网络 (convolutional neural network, CNN) 的表现优于

SVM 等其他模型,突显出 CNN 在数据研究范围内的高度泛化能力。

尽管 BP 神经网络、LSTM 神经网络和 SVM 等多种人工智能方法已被广泛应用于地层压力预测,在智能钻井的发展方面有重要作用,但仍存在梯度爆炸的问题、模型的理解能力和泛化能力相对有限,难以精准关注预测中最关键的区域。此外,这些模型对数据的前后波动感知能力不足,难以全面捕捉地层压力的动态变化特征,从而影响预测的精度和可靠性。

针对以上问题,为了在多维度特征数据中构建出稳定的地层孔隙压力预测模型,现通过分析将 CNN 模型参数进行特定优化,并将 CNN 捕捉局部信息的能力与自注意力机制相结合,增强模型对数据的理解能力和泛化能力,建立 CNN-Attn 神经网络的地层孔隙压力预测模型。动态地关注对预测最为关键的区域和特征,增强对全局信息的理解。以期为井壁稳定性分析提供关键数据,帮助预测钻井过程中可能遇到的异常压力,防止井漏、井喷等事故的发生,确保勘探作业的安全性和稳定性。

1 相关原理

1.1 CNN 卷积神经网络模型

卷积神经网络 CNN 是一种具有代表性的深度学习模型,其基本结构包括卷积层、池化层和全连接层。在一维卷积神经网络中^[17],卷积层通过卷积核来识别局部模式和特征,卷积核沿输入序列滑动,执行逐元素相乘并求和的操作,生成卷积特征,这有助于网络捕捉输入序列中的时序模式。池化层的池化操作有助于降低卷积层输出的维度,减小计算负担,同时保留关键的特征。

1.2 自注意力机制

自注意力机制是一种用于神经网络模型中的技术,主要用于捕捉输入数据中不同部分之间的依赖关系。它通过为每个输入元素分配一个权重,以决定该元素在输出中的重要性,从而增强模型的精度和鲁棒性。这些权重是通过计算查询 (query)、键 (key) 和值 (value) 之间的相似性得出的。具体来说,输入数据被投影到查询、键和值的空间中,然后计算查询与键的点积来获得注意力得分。注意力得分经过 softmax 归一化后,与值相乘并求和,得到最终的注意力输出。自注意力机制在处理长序列数据时非常有效,因为它能够在一步骤中考虑到序列中的所有元素之间的关系,避免了传统序列模型中的信息传递瓶颈。其公式为

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

式(1)中: Q 、 K 和 V 为输入矩阵,分别代表查询矩阵、键矩阵和值矩阵; d_k 为向量维度。

Attention 公式的作用是通过将 Q 和 K 的相似度进行加权,来得到对应于输入的 V 的加权和。

2 数据处理

在人工智能应用中,数据处理是一个不可或缺的环节。为了提高地层孔隙压力模型的计算精度和效率,必须对原始的测井数据进行处理,因为这些数据可能由于各种因素出现异常值。通过适当的数据处理,可以有效地去除噪声和异常值,从而为模型提供更准确、更可靠的输入数据。结合钻井领域的专业经验,本文中选用伊顿指数法、有效应力法和 D_e 指数法中用于计算地层孔隙压力的井深、岩石密度、声波时差、自然伽马和钻压 5 种参数作为输入数据,这些数据与地层孔隙压力相关,并且容易获取、相对完整。首先,对原数据采用滑动平均滤波技术处理;接着,进行相关性分析,计算出各参数与地层孔隙压力之间的 Pearson 相关系数;最后,通过归一化处理,将数据范围调整到一个统一标准,避免由于特征范围差异带来的偏差,从而进一步提高地层孔隙压力模型的质量和计算效率。

2.1 数据清洗

采用滑动平均滤波技术进行数据处理,通过设定窗口阈值对数据点进行比较,若超过阈值则用窗口内的平均值替换数据点。这种方法有效平滑数据,减小波动,便于观察和分析,同时增强数据的趋势和模式,其算法简单、计算效率高,适用于多种数据类型。以巴彦区块 A 井数据为例,A 井部分数据如表 1 所示,声波时差处理结果如图 1 所示,滑动平均滤波技术有效去除了数据中的噪声。

2.2 相关性分析

采用 Pearson 相关系数来评估井深、岩石密度、声波时差、自然伽马和钻压 5 种参数与地层孔隙压力之间的线性关联性。Pearson 相关系数是一种最常用的线性相关系数,它可以反映两个随机变量之间的线性相关程度。Pearson 相关系数计算公式为

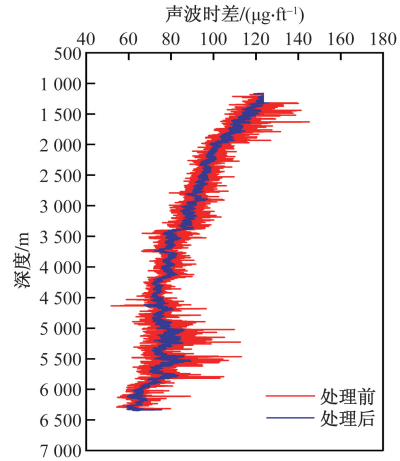


图 1 数据处理图

Fig. 1 Data processing diagram

$$\rho_{x,y} = \frac{\text{cov}(x,y)}{\sigma_x \sigma_y} \quad (2)$$

式(2)中: $\rho_{x,y}$ 为 x, y 的 Pearson 相关系数; $\text{cov}(x, y)$ 为 x, y 的协方差; σ_x 为 x 的标准差; σ_y 为 y 的协方差。

计算结果如图 2 所示,由统计学知识可知,相关系数为 0.4 ~ 0.6 为中等程度相关,0.6 ~ 0.8 为强相关,0.8 ~ 1.0 为极强相关。井深、声波时差、自然伽马和岩石密度 4 种参数都与地层孔隙压力存在中等及以上的线性相关关系。虽然钻压的相关系数小于 0.4,但不可忽略钻压与地层孔隙压力之间的物理联系。




图 2 Pearson 相关系数

Fig. 2 Pearson correlation coefficient

2.3 数据规范化处理

为了减少计算复杂度,提高模型的训练速度,考虑钻井的各个参数是与深度值有很大关系的序列化数据,且不符合正态分布,所以使用最小-最大规范化处理数据。

$$x' = \frac{x - \min(x)}{\max(x) - \min(x)} \quad (3)$$

式(3)中: x 为原始数据; $\min(x)$ 为数据中的最小值; $\max(x)$ 为数据中的最大值; x' 为标准化后的结果。

表 1 巴彦区块数据

Table 1 Data of Bayan block

井深/m	钻压/kN	声波时差/ ($\mu\text{s}\cdot\text{ft}^{-1}$)	自然伽马/ API	岩石密度/ ($\text{g}\cdot\text{cm}^{-3}$)	地层压力/ ($\text{g}\cdot\text{cm}^{-3}$)
1 154	52	139.9	52.85	2.005	1.042
1 156	63	143.0	50.25	1.994	1.045
1 158	95	142.7	64.54	2.069	1.045
1 160	56	144.2	86.37	2.208	1.047
1 162	87	151.6	87.67	2.090	1.036

注: 1 $\mu\text{s}/\text{ft} = 3.28 \mu\text{s}/\text{m}$ 。

3 CNN-Attn 组合模型

针对使用多维度的测井数据预测地层孔隙压力的问题,提出了 CNN-Attn 组合模型。

3.1 模型分析

一维卷积能够自动从输入数据中提取特征,无需手动设计特征,这使得它在处理复杂的、非线性的地层序列数据时尤为有效。通过卷积操作,1D-CNN 能够检测到局部模式和趋势,如短期的变化和周期性特征,这对于预测地层孔隙压力非常有效。卷积核在整个输入序列上共享参数,这减少了模型参数的数量,从而降低了过拟合的风险,并提高了训练效率。因此,CNN 可以有效地从这些以深度为序的测井数据中捕获局部信息,如数据变化的趋势或波动。自注意力机制则通过计算特征间的相关性,对特征进行重新加权,使模型能够聚焦于全局信息。对于泛化能力而言,它可以动态调整模型对不同特征的关注度,从而根据输入的变化自动识别最相关的特征,而非依赖所有输入特征,这意味着模型能够更有效地适应多样化的数据。尤其是在预测地层孔隙压力的任务中,数据往往存在不确定性和噪声,自注意力机制可以通过衡量不同特征之间的相关性,过滤掉不相关或噪声特征,让模型更加专注于对预测有用的信息,使模型在不确定或噪声数据的干扰下保持稳健。结合 1D-CNN 和自注意力机制,模型不仅能捕捉局部特征,还能整合全局依赖关系,显著提升了泛化能力和预测准确性。此外,这种结合使模型在应对复杂、多变的测井数据参数数据时展现出更强的鲁棒性。

3.2 模型结构

CNN-BP 组合模型的结构如图 3 所示,由输入层、1D-CNN 层、自注意力机制层和输出层构成。

地层孔隙压力与地层结构有很大关系,即当前井深的测井数据与前序的测井数据有一定的内在联系。故采用多对一的方式预测,在输入层将数据处理成[步长,特征维度],预测示意图如图 4 所示。

在 1D-CNN 层中,卷积核大小的选择对于模型性能至关重要。选择合适的卷积核大小能够有效地捕捉输入数据中的特征和模式。考虑到地质分层和前序地层测井数据与地层孔隙压力之间的短期依赖关系,较小的卷积核更为合适。较小的卷积核能够捕捉局部的细节特征,同时减少计算资源和时间的消耗。步幅决定了卷积核在输入数据上移动的步长,其选择对模型的性能和计算效率有重要影响。由于模型使用的数据维度为 5,属于小维度数据,步幅为 1 可以确保卷积核在输入数据的每个




图 3 CNN-Attn 网络结构

Fig. 3 CNN-Attn network structure




图 4 预测示意图

Fig. 4 Forecast diagram

位置都进行计算,从而不遗漏任何细节信息。

在自注意力机制层中,自注意力机制可以帮助模型更好地捕捉输入数据中的长期依赖关系,通过全连接的方式将信息综合,输出预测结果。

3.3 参数设置

在训练过程中需要调整的参数主要有:卷积核大小、单元数、学习率、批量大小、步长、优化器和损失函数。

卷积核大小则影响卷积操作捕捉的特征尺寸,适当的大小有助于更好地理解数据的局部结构,通过控制变量法,当卷积核大小设置为 2、3、4 时,均方根误差会逐步增大,因此选用 2。

适当的单元数可以提高模型容量和表达能力,有助于捕捉复杂的数据模式,本文使用随机搜索的方法确定单元数的值。

学习率设置过大可能导致训练过程不稳定,而设置过小可能使训练过程过于缓慢;批量大小是每次更新权重时使用的样本数,它直接影响训练的稳定性,根据调参经验分别设置为 10^{-4} 、64。

步长是指使用多少条数据预测一条数据,它影响模型对序列数据的理解程度。为更好地学习局部特征和模式,使用控制变量法得出步长为 12、15、18 时,均方根误差先减小后增大,因此设置为 15。

优化器是用于更新权重的算法,选择适当的优化器有助于提高模型的收敛性和泛化能力,因此选择能自适应调整学习率的 Adam 优化器。

损失函数用于衡量模型的预测结果与实际结果的差距,选择适当的损失函数能够引导模型更好地学习任务目标,预测地层孔隙压力属于回归任务,故损失函数选用均方根误差。

4 模型应用与分析

为了验证本文的 CNN-Attn 组合模型预测地层孔隙压力的性能,将该模型与 BP、CNN 和 LSTM 模型进行对比,使用模型评价指标进行验证。

4.1 模型评价指标

模型评价指标可以用来衡量模型是否有效,可以用来调整模型的参数。本文所研究的地层孔隙压力预测属于回归问题,评价指标用来衡量预测值与真实值之间的误差,故采用的模型评价指标为平均绝对误差(mean absolute error, MAE)、均方根误差(root mean squared error, RMSE)、平均相对误差(mean relative error, MRE)和决定系数(determination coefficient, R^2),其中 MAE、RMSE 和 MRE 越小, R^2 越大,模型预测能力越强。

平均绝对误差(MAE)是实测值与预测值之间绝对误差的平均值,为预测值误差的体现,其计算公式为

$$MAE = \frac{1}{N} \sum_{i=1}^N |\hat{y}_i - y_i| \quad (4)$$

式(4)中: \hat{y}_i 为参数数据的实测值; y_i 为模型预测值; N 为数据数量。

均方根误差(RMSE)为实测值与真实值之间偏差的体现,计算公式为

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (\hat{y}_i - y_i)^2} \quad (5)$$

平均相对误差指真实值与预测值的相对误差的平均值,其计算公式为

$$MRE = \frac{1}{N} \sum_{i=1}^N \frac{|\hat{y}_i - y_i|}{y_i} \times 100\% \quad (6)$$

决定系数(R^2)为衡量预测模型能力的指标。其计算公式为

$$R^2 = 1 - \frac{\sum_{i=1}^N (\hat{y}_i - y_i)^2}{\sum_{i=1}^N (y_i - \bar{y})^2} \quad (7)$$

4.2 单井预测模型

使用巴彦区块 A 井和 B 井的数据进行实验, A 井数据涵盖井深 1 154 ~ 6 344 m, B 井数据涵盖井深 1 007 ~ 4 289 m。实验采用留出法,前 80% 的数据用于训练模型,其余 20% 用于测试。经过对数据进行预处理和模型超参数优选,使用 CNN-Attn 模型

进行预测,并与 BP、CNN 和 LSTM 模型进行比较。

A、B 两口井按经验设定和随机搜索得出最优模型参数,如表 2 所示。

使用上述优选的模型参数进行地层孔隙压力预测, A、B 两口井评价指标结果如表 3 和表 4 所示,预测结果如图 5 和图 6 所示。

表 2 A 井和 B 井超参数优选结果

Table 2 Superparameter optimization results for wells A and B

模型	A 井单元数	模型	B 井单元数
BP	120	BP	300
CNN	70	CNN	70
LSTM	50	LSTM	80
CNN-Attn	CNN 层 70、 全连接层 70	CNN-Attn	CNN 层 60、 全连接层 80

表 3 A 井的 4 种模型评价指标结果

Table 3 Results of four model evaluation indexes of well A

模型	MAE/MPa	RMSE/MPa	MRE/%	R^2
BP	2.32	2.64	3.29	0.55
CNN	1.38	1.67	1.97	0.82
LSTM	1.34	1.71	1.95	0.81
CNN-Attn	0.78	0.97	1.13	0.94

表 4 B 井的 4 种模型评价指标结果

Table 4 Results of four model evaluation indexes of well B

模型	MAE/MPa	RMSE/MPa	MRE/%	R^2
BP	3.46	3.88	7.81	-1.49
CNN	1.10	1.29	2.48	0.72
LSTM	2.06	2.72	4.71	-0.23
CNN-Attn	0.53	0.65	1.20	0.93

结果显示 CNN-Attn 模型的 MAE 均小于 1 MPa, RMSE 均小于 1 MPa, MRE 均小于 1.3%, 决定系数均大于 0.9, 其评价指标数据均优于 BP 神经网络模型、CNN 神经网络模型和 LSTM 神经网络模型, 表明 CNN-Attn 模型能更好地处理测井的序列性数据, 且预测的准确度更高。由图 5 和图 6 可知, BP 神经网络的预测结果在整体上有所偏差, 可能由于无法保留和利用序列中的信息, 所以预测效果相比于 LSTM 神经网络较差。CNN 神经网络模型预测结果相对较好。CNN 神经网络模型与自注意力机制结合后, 可以根据特征的重要性动态调整权重, 并有效捕捉短期和长期趋势, 提高预测准确性。

4.3 泛化能力检验

单井模型以巴彦区块 A 井自身的数据训练, 并预测自身的后序深度的地层孔隙压力。在实际钻井中, 更希望能通过打一口井或若干口井对同一区块的地层孔隙压力进行预测, 故将巴彦区块 A 井训练好的模型用来预测 B 井的地层孔隙压力, 以测试




图5 4种模型在A井的预测值与实际值对比

Fig. 5 Comparison of predicted and actual values of the four models for Well A




图6 4种模型在B井的预测值与实际值对比

Fig. 6 Comparison of predicted and actual values of the four models for Well B

模型的泛化能力。预测的结果如图7所示,其MAE为0.523 MPa, RMSE为0.628 MPa, MRE为1.208%, 决定系数为0.935。由此可以得出 CNN-Attn 模型具有良好的泛化能力,在实际钻井中,可以为现场提供更多的数据参考。

5 结论

(1) 选定井深、岩石密度、声波时差、自然伽马和钻压5种数据作为输入参数并进行相关性分析,利用CNN发卷积操作提取特征并检测局部模式和趋势,结合自注意力机制擅长捕捉全局依赖关系,从而创建出CNN-Attn地层孔隙压力预测模型。

(2) 使用巴彦区块两口井的数据验证模型的性能,对比BP、CNN和LSTM模型的结果显示,CNN-Attn模型能够有效地预测地层孔隙压力。使用当前井数据建立模型时,两口井的MAE均小于1 MPa,




图7 泛化预测结果

Fig. 7 Generalized prediction results

RMSE均小于1 MPa, MRE均小于1.3%, 决定系数均大于0.9,说明模型具有较高的精度和稳定性;泛

化能力较强,检验结果平均绝对误差小于 1 MPa、决定系数大于 0.9。综上所述,本文研究采用人工智能技术提供了一种新的方法来预测地层孔隙压力,为钻井安全提供了有力的数据参考。

(3)在后续的研究中,将考虑设计更合适的模型结构,多通道挖掘序列特征,以及更全面地考虑浅层和深层的地层信息,融合环境因素(如地质结构、岩性等)作为额外输入,进一步提高预测精度。

参 考 文 献

- [1] Zhao Y, Sun T, Yang J, et al. Combining drilling big data and machine learning method to improve the timeliness of drilling [C]// SPE/IADC Drilling Conference and Exhibition. Hague: SPE, 2019: 194111-MS.
- [2] 余金秋,孙夕平,于永才,等. 深层地层压力预测技术研究进展[J]. 海相油气地质, 2024, 29(4): 337-347.
Yu Jinqiu, Sun Xiping, Yu Yongcai, et al. Research progress on deep formation pressure prediction technology [J]. Marine Origin Petroleum Geology, 2024, 29(4): 337-347.
- [3] 毕臣臣. 基于深度学习的页岩储层总有机碳含量预测方法[J]. 科学技术与工程, 2023, 23(2): 494-501.
Bi Chenchen. Total organic carbon content prediction method of shale reservoir based on deep learning [J]. Science Technology and Engineering, 2023, 23(2): 494-501.
- [4] 马陇飞,萧汉敏,陶敬伟,等. 基于深度学习岩性分类的研究与应用[J]. 科学技术与工程, 2022, 22(7): 2609-2617.
Ma Longfei, Xiao Hanmin, Tao Jingwei, et al. Research and application of lithology classification based on deep learning [J]. Science Technology and Engineering, 2022, 22(7): 2609-2617.
- [5] 杨琨,罗山贵,花凌旭,等. 致密砾岩油藏压裂甜点预测研究——以玛 18 井区为例[J]. 科学技术与工程, 2022, 22(32): 14174-14183.
Yang Kun, Luo Shangui, Hua Lingxu, et al. Investigation on the fracturing sweet spot prediction of conglomerate tight oil reservoir: a case study of the Ma18 Well Block [J]. Science Technology and Engineering, 2022, 22(32): 14174-14183.
- [6] 匡立春,刘合,任义丽,等. 人工智能在石油勘探开发领域的应用现状与发展趋势[J]. 石油勘探与开发, 2021, 48(1): 1-11.
Kuang Lichun, Liu He, Ren Yili, et al. Application and development trend of artificial intelligence in petroleum exploration and development [J]. Petroleum Exploration and Development, 2021, 48(1): 1-11.
- [7] 李根生,宋先知,祝兆鹏,等. 智能钻完井技术研究进展与前景展望[J]. 石油钻探技术, 2023, 51(4): 35-47.
Li Gensheng, Song Xianzhi, Zhu Zhaopeng, et al. Research progress and the prospect of intelligent drilling and completion technologies [J]. Petroleum Drilling Techniques, 2023, 51(4): 35-47.
- [8] 张瑞,祝兆鹏,李大钰,等. 基于改进时序网络的钻进参数可解释实时预测[J]. 石油机械, 2024, 52(4): 1-10.
Zhang Rui, Zhu Zhaopeng, Li Dayu, et al. Interpretable real-time prediction of drilling parameters based on improved sequential network [J]. China Petroleum Machinery, 2024, 52(4): 1-10.
- [9] 陈凯枫,杨学文,宋先知,等. 基于工程录井数据的井漏智能诊断方法[J]. 石油机械, 2022, 50(11): 16-22.
Chen KaiFeng, Yang Xuewen, Song Xianzhi, et al. An intelligent diagnosis method for lost circulation based on engineering logging data [J]. China Petroleum Machinery, 2022, 50(11): 16-22.
- [10] 李萍,于琛,王建龙,等. 基于实时钻进参数的孔隙压力智能预测技术[J]. 石油机械, 2024, 52(5): 1-8.
Li Ping, Yu Chen, Wang Jianlong, et al. Intelligent prediction of pore pressure using real-time drilling parameters [J]. China Petroleum Machinery, 2024, 52(5): 1-8.
- [11] Karmakar M, Maiti S, Short term memory efficient pore pressure prediction via Bayesian neural networks at Bering Sea slope of IODP expedition 323 [J]. Measurement, 2019(135): 852-868.
- [12] Keshavarzi R, Jahanbakhshi R. Real-time prediction of pore pressure gradient through an artificial intelligence approach: a case study from one of middle east oil fields [J]. European Journal of Environmental and Civil Engineering, 2013, 17: 675-686.
- [13] 罗发强,刘景涛,陈修平,等. 基于 BP 和 LSTM 神经网络的顺北油田 5 号断裂带地层孔隙压力智能预测方法[J]. 石油钻采工艺, 2022, 44(4): 506-514.
Luo Faqiang, Liu Jingtao, Chen Xiuping, et al. Intelligent method for predicting formation pore pressure in No. 5 fault zone in Shunbei oilfield based on BP and LSTM neural network [J]. Oil Drilling & Production Technology, 2022, 44(4): 506-514.
- [14] 宋先知,姚学喆,李根生,等. 基于 LSTM-BP 神经网络的地层孔隙压力计算方法[J]. 石油科学通报, 2022(1): 12-23.
Song Xianzhi, Yao Xuezhe, Li Gensheng, et al. A novel method to calculate formation pressure based on the LSTM-BP neural network [J]. Petroleum Science Bulletin, 2022(1): 12-23.
- [15] Ahmed A, Elkatatny S, Ali A, et al. Comparative analysis of artificial intelligence techniques for formation pressure prediction while drilling [J]. Arabian Journal of Geosciences, 2019, 12(592). DOI: 10.1007/s12517-019-4800-7.
- [16] Matinkia M, Amraeiniya A, Behboud M M, et al. A novel approach to pore pressure modeling based on conventional well logs using convolutional neural network [J]. Journal of Petroleum Science and Engineering, 211, 2022. DOI: 10.1016/j.petrol.2022.110156.
- [17] Kiranyaz S, Avci O, Abdeljaber O, et al. 1D convolutional neural networks and applications: a survey [J]. Mechanical Systems and Signal Processing, 2021, 151. DOI: 10.1016/j.ymssp.2020.107398.