

DOI: 10.13382/j.jemi.B2508501

融合岩性信息的 CNN-LSTM-GAT 深度网络孔隙压力预测方法*

邹佳玲¹ 秦长春¹ 梁海波¹ 韩毅辉² 习国江²

(1. 西南石油大学机电工程学院 成都 610500; 2. 西南电子技术研究所敏捷智能计算四川省重点实验室 成都 610500)

摘要: 地层孔隙压力是油气勘探与开发中的关键参数, 精准预测对保障钻井安全与提升作业效率具有重要意义。针对传统模型和浅层机器学习模型缺乏对岩性空间信息的有效融合, 导致模型泛化性能受限等问题, 提出一种融合岩性信息的深度图注意力网络孔隙压力预测方法 (CLG)。模型以井深、当量循环密度、机械钻速与钻压、自然伽马、孔隙度及岩性编码等多源参数为输入, 相关数据主要来源于随钻测量 (LWD) 系统, 采用箱型图清洗、滤波、归一化处理提升数据质量。通过 CNN 提取局部特征, LSTM 捕捉时序依赖, 图注意力机制融合岩性结构信息。在渤海某勘探区应用结果表明, CLG 模型在多个井位均取得优异性能 ($R^2=0.9979$, $MSE=0.0035$, $RMSE=0.0596$, $MAE=0.0481$), 在盲井预测中, 预测精度提升 15% 左右, 泛化能力得到加强。该方法有效提升了岩性感知下的地层孔隙压力建模水平, 为复杂地质条件下的油气钻井提供可靠支持。

关键词: 孔隙压力预测; 石油钻井; 特征提取; CNN-LSTM-GAT; 深度学习

中图分类号: TE1; TN98 **文献标识码:** A **国家标准学科分类代码:** 440.5

Deep CNN-LSTM-GAT network for pore pressure prediction incorporating lithology information

Zou Jialing¹ Qin Changchun¹ Liang Haibo¹ Han Yihui² Xi Guojiang²

(1. School of Mechanical and Electrical Engineering, Southwest Petroleum University, Chengdu 610500, China; 2. Sichuan Provincial Key Laboratory of Agile Intelligent Computing, Southwest Institute of Electronic Technology, Chengdu 610500, China)

Abstract: Pore pressure is a key parameter in oil and gas exploration and development. Accurate prediction is crucial for ensuring drilling safety and improving operational efficiency. Traditional models and shallow machine learning methods often lack effective integration of lithological spatial information, which limits their generalization performance. This paper proposes a deep graph attention network method (CLG) that incorporates lithology information for pore pressure prediction. The model takes multiple inputs including well depth, equivalent circulating density (ECD), mechanical drilling parameters (rate of penetration and weight on bit), natural gamma ray, porosity, and lithology encoding. Most data are obtained from the logging while drilling (LWD) system, and are processed by boxplot cleaning and normalization to improve quality. CNN extracts local features, LSTM captures temporal dependencies, and the graph attention mechanism integrates lithological structural information. Application in a Bohai exploration area shows that the CLG model achieves excellent performance across multiple wells ($R^2=0.9979$, $MSE=0.0035$, $RMSE=0.0596$, $MAE=0.0481$), improving accuracy by about 15% and 7.4% compared to the Eaton method and various shallow models, respectively, with enhanced generalization ability. This method effectively advances pore pressure modeling with lithology awareness, providing reliable support for oil and gas drilling under complex geological conditions.

Keywords: pore pressure prediction; petroleum drilling; feature extraction; CNN-LSTM-GAT; deep learning

0 引言

地层孔隙压力是控制油气勘探开发过程中重要的储层参数^[1-3]可以反映地下岩石性质、孔隙度和流体等特征^[4],为钻井计划和性能分析提供了有关井下地质环境的深刻信息^[5]。地层孔隙压力分布复杂且变化多端,受地质结构、岩石特性和流体流动等因素,从而导致建模精度受限制。地层孔隙压力不仅影响钻井液密度的设计,还直接关系到井眼稳定性、井筒安全以及钻井作业的风险控制^[6-7],准确的地层孔隙压力预测对减少钻井事故发生几率、保证地质稳定、降低钻井成本、缩短勘探周期、保证钻井作业安全、有序、高效具有关键作用^[8-11]。

对于地层孔隙压力预测的研究方法,大致分两类,包括基于物理模型的传统预测方法和机器学习模型预测方法^[12-13]。传统的地层孔隙压力预测方法主要使用了钻井参数(如钻速、转速、钻压)、测井(如电阻率、电导率、声波时间和伽马射线)和地层性质(如孔隙度、密度、上覆岩层应力、泊松比)、应力条件(如有效应力、上覆岩层)以及流体性质等关键因素,以更准确地描述地层孔隙压力的变化规律^[14-15]。主要方法包括 Bowers 法^[16]、等效深度法^[17]、Eaton 法^[18]、Fillippone 法^[19]、有效应力法^[20]等。每种方法都有其优点,适合特定的地质条件。例如 Bowers 定律适用于更深的地层,考虑了压实对孔隙度的影响。等效深度法主要用于砂岩、砾岩等孔隙度和渗透率较高的岩石^[21],考虑了不同岩石的地层孔隙压力差异,适用于那些孔隙度和渗透率变化较大的岩石类型。Eaton 法通过分析实际测得的地层孔隙压力与预测地层孔隙压力的关系,计算出岩石的应力和压力。这些方法的应用依赖简化的假设和模型,需要计算压实趋势和估计一些系数且需要通过现场数据来验证^[22]。

近年来,机器学习发展迅速,在解决复杂的非线性问题方面具有很大的优势,已被广泛用于解决石油科学中的各种复杂问题,具有前所未有的高精度^[23]。这些方法可以从大量的测井数据、地震属性、岩心分析和其余地质参数中自动提取与地层孔隙压力相关的特征,建立复杂的非线性映射关系,而不依赖于传统方法中使用的简化假设。例如 Huang 等^[24]建立了包括纵向速度、孔隙度、泥浆含量和密度 4 个输入变量的组合来准确预测有效应力,实现了对地层孔隙压力的准确预测,并且建立了评价指标和对比分析,对预测模型和结果进行了评价分析。Reza 等^[25]通过人工神经网络(artificial neural network, ANN)和多目标优化技术相结合的方法找出最佳特征,采用 ML 方法进行地层孔隙压力预测。Sun 等^[26]建立的页岩含量多机制预测模型与传统模型比较,最大预测误差

减少约 20%,显著提高了地层孔隙压力预测精度。机器学习模型在特征提取上存在局限性,且模型泛化能力不足。Zhang 等^[27]采用 1DCPP 对参数特征进行提取,选取一种自适应物理信息深度学习模型 CGP-NN 进行地层孔隙压力预测,同时提出了一种结合 Eaton 和 Bowers 方法的混合方法来构建机器可学习的标签,以解决标签少的问题。Matinkia 等^[28]建立一种基于常规测井曲线的卷积神经网络地层孔隙压力建模新方法反映了该模型在研究数据范围内的高精度性。

但是传统浅层机器学习方法在地层孔隙压力预测中难以建模复杂岩性结构,存在特征表达有限、泛化能力不足等问题。针对这一挑战,本文提出了一种融合岩性信息的深度图注意力网络地层孔隙压力预测方法。该方法以多源钻井数据为基础,结合录井、测井等信息构建多维度特征体系,并通过岩性编码引入图注意力机制,增强模型对井段间地质关系的建模能力。

1 方案设计

1.1 总体设计

在本研究中,首先对收集的多源数据进行预处理,采用箱型图识别并剔除异常值,随后进行数据平滑、最大最小归一化处理。通过构建融合卷积神经网络(convolutional neural network, CNN)、长短期记忆网络(long short-term memory, LSTM)与图注意力机制(graph attention network, GAT)的 CLG 深度学习模型,有效捕捉空间局部特征、压力演化趋势及岩性结构依赖关系。最后,通过一系列评价指标对比,CLG 模型与传统方法及典型浅层机器学习模型的预测性能,全面验证所提方法在精度与稳健性方面的优势。

在模型设计过程中, CNN 具有强大的特征提取能力,能够从多维输入中提取最具代表性的局部特征^[29]。其基本结构大致包括卷积层、激活函数、池化层、输出层等^[30]。

LSTM 模型的核心在于其引入的“门”机制,这些门结构允许网络在信息传递过程中进行精细的控制^[31-32],具体结构如图 1 所示。

图注意力网络^[33]通过引入注意力机制,为每个相邻节点分配不同的权重,依据其对目标节点的重要性进行加权聚合,从而实现更精细的信息融合与结构建模,因而适用于处理地层孔隙压力预测中岩性信息。

在整个模型构建中, CNN 模块用于识别局部深度内的细尺度特征变化, LSTM 进一步对经 CNN 提取的序列信息进行建模,用于刻画压力随井深演化的趋势, GAT 则用于融合岩性特征和节点间的地质结构依赖关系。3 层结构的设计旨在最大化提升预测精度和稳健




图 1 LSTM 结构

Fig. 1 Structure of the LSTM network

性,有效解决复杂岩性条件下传统方法泛化能力不足的问题。

最后,通过多项评价指标,将 CLG 模型与传统方法及典型浅层机器学习模型进行对比,全面验证了所提方法在预测精度与稳健性方面的优势。

1.2 预测流程

所提方法的地层孔隙压力预测流程如图 2 所示。




图 2 地层孔隙压力预测流程

Fig. 2 Workflow of pore pressure prediction

步骤 1) 数据预处理,对选取数据进行清洗、滤波、归一化处理;

步骤 2) CNN 特征提取使用 1D CNN 网络提取局部地层特征,通过卷积运算捕捉地层孔隙压力的变化规律;

步骤 3) LSTM 时序建模采用双向 LSTM 网络分析压力随井深变化的趋势,正向学习沉积压实作用,反向识别

构造异常;

步骤 4) GAT 图网络分析基于岩性关系和空间位置构建图结构,利用注意力机制学习区域压力分布特征;

步骤 5) 地层孔隙压力预测融合多尺度特征,通过回归网络输出地层孔隙压力值预测结果,采用 MAE 作为评估指标进行模型优化。

2 数据来源和预处理

2.1 数据来源

X 区块是渤海钻探的一个勘探区块。本研究所用数据主要来源于随钻测量 (logging while drilling, LWD) 系统,图 3 为 LWD 测量短节图,涵盖声波时差、电阻率、密度、伽马等测井曲线,以及钻井过程中实时采集的钻速、泵压、泥浆性能等录井参数。LWD 技术可在钻进过程中实时获取地层物性信息,为建立高时效性、高精度的地层孔隙压力预测模型提供了可靠的数据支撑。




图 3 LWD 测量短节图

Fig. 3 LWD measurement sub illustration

选用 3 口井的压力测试数据和测井数据,分别为 A、B、C 井。同时,选取 D 井作为盲井,完全未参与模型训练,用于独立测试模型在未知井上的预测性能,模拟实际工程中模型应用于新井的场景。

所选输入参数基于地质与钻井机理筛选,旨在为融合岩性信息的图注意力网络提供有效的结构表征与预测支撑,各参数在孔隙度预测中的重要性如下。

井深 (depth): 压力演化的主轴变量,刻画地层随深度的压力变化趋势。

当量循环密度 (ECD): 表征井底实际压力环境,是压力预测的直接指标。

机械钻速 (ROP) 与钻压 (WOB): 分别反映钻遇地层的力学响应与压实状态,揭示岩性变化过程。

自然伽马 (GR): 用于识别泥质层和致压层,辅助建立岩性判别基础。

孔隙度(POR):表征地层致密性和异常压力潜势。

岩性(lithology):通过独热编码形式嵌入图结构,作为节点属性参与 GAT 建模,支持岩性关系的结构化表达与信息聚合。

本研究所使用的岩性信息主要包括 3 类:首先,岩性采用独热编码方式来表征不同岩性类型与地质特征;其次,自然伽马能够识别地层的压实程度,从而为岩性判别提供参考依据;最后,孔隙度通过反映地层的致密性来区分储集层与致密层。通过融合这 3 类岩性信息,能够更全面地刻画储层特征,从而提高地层压力预测模型的准确性和地质合理性。

整体参数体系融合了静态岩性特征与动态钻井数据,为精确感知复杂地层结构、提升预测精度提供了坚实基础。

2.2 数据预处理

首先,采用箱型图对采集的数据进行了异常值筛选。其原理如图 4 所示,数据的分布特征,包括中位数、四分位数以及数据的正常范围,帮助识别和去除离群值。具体说明如表 1 所示。




图4 箱型图原理
Fig. 4 Boxplot diagram

表1 箱型图原理说明

箱型图位点	描述
下四分位数(Q1)	表示数据的第 25%位置
中位数(Q2)	表示数据的第 50%位置
上四分位数(Q3)	表示数据的第 75%位置
上限	$Q3+1.5(Q3-Q1)$
下限	$Q1-1.5(Q3-Q1)$
异常值	$X>Q3+1.5(Q3-Q1)$ 或 $X<Q1-1.5(Q3-Q1)$

其次,需要对数据进行去噪处理,Savitzky-Golay 滤波器是一种通过多项式拟合进行数据平滑的方法^[34],能够有效抑制高频噪声,同时也能将数据的峰形、极值等关键特征保留下来。这种特性使其在处理地层参数和压力曲线往往包含重要的局部变化信息,采用 Savitzky-Golay 滤波能避免过度平滑而损失关键的地质特征,因此适用于本研究所涉及的数据处理需求。

最后,对数据进行了最大最小归一化处理,将不同量纲的数据转化到相同尺度,消除量纲差异。采将数据缩放到[0,1]的范围,公式如下:

$$X_{norm} = \frac{X - X_{min}}{X_{max} - X_{min}}$$

(1)

式中: X 是原始数据; X_{min} 和 X_{max} 分别为数据中的最小值和最大值; X_{norm} 是归一化后的数据。

2.3 评价指标

为了评价模型的性能情况,采用误差函数作为评估指标评价预测结果,选取均方误差(mean squared error, MSE)、决定系数(coefficient of determination, R^2)、均方根误差(root mean squared error, RMSE)、平均绝对误差(mean absolute error, MAE)作为评价指标,其计算公式如下:

$$MSE = \frac{1}{n} \sum_{i=1}^n (\hat{y}_i - y_i)^2$$

(2)

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

(3)

$$MAE = \frac{1}{n} \sum_{i=1}^n |\hat{y}_i - y_i|$$

(4)

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

(5)

式中: $\hat{y}$ 表示模型的预测值; y_i 表示实验数据的真实值; $\bar{y}_i$ 表示实验数据的真实值的平均值; n 表示样本数目。 R^2 越接近 1, MSE、RMSE、MAE 的值越小表明模型的预测效果越好。

3 实验及结果分析

本研究在 AMD Ryzen 7 6800H 处理器(3.20 GHz)、NVIDIA RTX 3060 显卡(6 GB GDDR6)、16 GB DDR4 内存和 1 TB NVMe SSD 的硬件环境下,基于 Windows 11 Pro 系统,采用 TensorFlow-GPU 2.9.1 (CUDA 11.7/cuDNN 8.5)框架和 Python 3.9.13 (Anaconda) 进行模型训练与验证。

3.1 数据处理流程

如图 5 所示,原始测井数据是基于不同深度记录的,这些原始数据需要经过异常值剔除、滤波、归

一化系列处理,以便提高数据分析的准确性和有效性。




图 5 原始数据
Fig. 5 Plot of the original data

以 GR 为例,如图 6 所示,通过数据处理流程,从原始数据中先去除了异常值,用 Savitky-Golay 滤波平滑了数据,最终将其归一化,确保数据更具有可比性。在去除异常值和进行平滑处理后,数据展示出了更加平缓稳定的趋势,而归一化处理实现了对不同深度的数据进行统一尺度的比较。




图 6 数据处理流程
Fig. 6 Data processing process

3.2 模型参数设置

模型参数设置包括结构参数与训练参数两部分,如表 2、3 所示,涵盖 CNN、LSTM 与 GAT 的关键配置,以及优化器、学习率、损失函数等训练策略,旨在提升模型的特征提取能力与预测稳定性。

3.3 消融实验

根据所选输入特征,结合先前优化确定的超参数,对深度学习模型进行了有效构建。随后,将测试集输入数据导入训练完成的模型中,实现了对地层孔隙压力的预测。预测结果如图 7 所示。结果显示,四口井的预测效果良好,能够反映地层孔隙压力变化规律。本文提出的 CLG 模型在四口测试井(含一口盲井)上的预测曲线表现最为优异,展示了其卓越的拟合能力和稳定性。

表 2 结构参数设置

Table 2 Model architecture parameters		
参数名称	参数值	说明
卷积核数量	64	CNN 层提取局部空间特征
卷积核尺寸	2	卷积窗口大小
池化尺寸	2	最大池化窗口大小
LSTM 隐藏单元数	100	LSTM 层的隐藏神经元数
LSTM 层数	2	堆叠的 LSTM 层数
时间步长	30	输入序列时间窗口
注意力头数	4	GAT 层的多头注意力机制数
输入激活函数	ReLU	CNN 和 LSTM 隐藏层激活函数
输出激活函数	Linear	用于回归输出的线性激活

表 3 训练参数设置

Table 3 Training parameters		
参数名称	参数值	说明
学习率	0.001	初始学习率
优化器	Adam	训练优化算法
批大小	32	每次训练的样本数
训练轮数	100	模型训练总轮数
权重衰减	0.000 1	L2 正则化项,用于防止过拟合
梯度裁剪阈值	5	限制梯度大小,防止梯度爆炸
学习率调度策略	ReduceLROnPlateau	动态调整学习率,提升收敛效果
损失函数	MSE	均方误差作为模型优化目标

进一步通过评价指标对比,CLG 模型在 MSE、MAE、RMSE 和 R² 方面均显著优于传统 Eaton 方法、LSTM 模型,具体指标如图 8 和表 4 所示。以 A 井为例,CLG 模型 MSE 仅为 0.003 6,远低于 Eaton 的 0.225 6、LSTM 的 0.196 9 和 CL 的更高数值,R² 高达 0.997 9,拟合效果极佳。在盲井 D 上,尽管该井并未参与训练,CLG 依然实现了最低 MSE (2.415 3)、MAE (0.452 1) 和 RMSE (1.021 4),R² 达到 0.974 3,显著优于其他方法,充分体




图7 地层孔隙压力预测

Fig.7 Formation pressure prediction chart




图8 模型评估指标比较

Fig.8 Model evaluation metrics comparison chart

现了其卓越的泛化能力和工程适应性。

同时,模型通过综合多种特征信息,能够有效捕捉地质变化规律,并提供稳定且可靠的预测结果。相较于传统方法,模型能够显著减少常见的波动和偏移现象。通过引入深度学习框架,模型能够在多维度上自动学习和

优化特征,改善测井参数存在误差和不稳定性等问题。因此,该方法不仅在地质环境复杂、参数多样的情况下表现出更好的预测精度,还能有效提高模型的泛化能力,减少对数据质量的敏感度,从而在实际工程应用中具有较高的可靠性和实用价值。

表 4 模型评价指标参数表

Table 4 Model evaluation metrics table

井名	指标	Eaton	LSTM	CL	CLG
A 井	MSE	0.225 6	0.196 9	0.010 8	0.003 6
	MAE	0.362 4	0.371 6	0.053 2	0.048 1
	RMSE	0.542 9	0.443 7	0.103 8	0.059 6
	R ²	0.861 7	0.884 9	0.993 7	0.997 9
B 井	MSE	0.186 4	0.129 3	0.112 1	0.069 1
	MAE	0.351 1	0.274 5	0.232 3	0.181 4
	RMSE	0.569 3	0.359 6	0.334 9	0.262 9
	R ²	0.922 7	0.964 3	0.969 0	0.980 9
C 井	MSE	0.319 5	0.458 0	0.369 3	0.176 3
	MAE	0.442 5	0.337 6	0.325 8	0.207 7
	RMSE	0.642 7	0.676 8	0.607 7	0.419 9
	R ²	0.942 2	0.974 8	0.979 7	0.990 3
D 井(盲井)	MSE	4.214 8	3.424 3	3.190 5	2.415 3
	MAE	1.569 8	1.029 4	0.782 0	0.452 1
	RMSE	2.419 6	1.850 5	1.786 2	1.021 4

3.4 模型特征贡献分析

在地层孔隙压力预测中加入模型可解释性,能够增强模型的透明度与可信度,通过分析模型对各输入特征的响应,能识别关键影响因素,为参数选取与模型优化提供支持。解释性人工智能(interpretable AI)方法主要包括 SHAP、LIME 和特征排列重要性等^[35-36]。本研究采用 SHAP 法来分析各输入特征对地层孔隙压力预测的影响。SHAP 通过计算 Shapley 值量化每个特征对预测结果的贡献。结果如图 9 所示,从上述 SHAP 分析结果来看,模型在预测过程中更依赖地质与应力相关的特征。岩性、孔隙度是对模型预测影响最大的两个特征,说明岩性和孔隙度是影响地层孔隙压力的关键因素。其次,井深、ECD 的重要性也较为显著,显示出压力环境对预测目标也有着不可忽视的作用。而自然伽马、钻压、机械钻速的 SHAP 平均值相对较小,说明这些机械参数对模型的影响较弱,但它们仍提供了一定的补充信息。




图 9 特征重要性分布

Fig.9 SHAP feature importance plot

4 结 论

本研究基于井深、当量循环密度、机械钻速、钻压、自然伽马、岩性编码与孔隙度七项参数,构建融合 CNN、LSTM 与 GAT 的 CLG 深度学习模型,实现对孔隙压力的精准预测。通过对数据进行清洗与归一化处理,提升数据质量与模型训练效率;在此基础上,模型利用 CNN 提

取空间局部特征,LSTM 捕捉深度序列中的时间依赖关系,GAT 引入岩性图结构增强模型对地质空间分布与岩性变化的感知能力,提升了结构建模精度与特征表达能力。经验证与盲井法评估,CLG 模型在四口测试井中均表现出优异的预测效果,特别是在盲井测试中依然保持较高的预测精度,充分验证其强泛化能力与工程适应性。

参考文献

[1] RADWAN A E. Modeling pore pressure and fracture

- pressure using integrated well logging, drilling-based interpretations and reservoir data in the giant El Morgan oil field, Gulf of Suez, Egypt [J]. *Journal of African Earth Sciences*, 2021, 178: 104165.
- [2] 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 P, YU CH, WANG J L, et al. Intelligent pore pressure prediction technology based on real-time drilling parameters[J]. *Petroleum Machinery*, 2024, 52(5): 1-8.
- [3] 张冰, 王晓婷, 徐福颖, 等. 基于 XGBoost 的孔隙压力预测方法研究[J]. *地球物理学进展*, 2025, 40(2): 541-555.
- ZHANG B, WANG X T, XU F Y, et al. Study on pore pressure prediction method based on XGBoost [J]. *Progress in Geophysics*, 2025, 40(2): 541-555.
- [4] SUN X, LIAO Y, WANG Z, et al. Modelling of formation pore pressure inversion during tight reservoir drilling [J]. *Geofluids*, 2021: 1-11. <https://doi.org/10.1155/2021/6626381>.
- [5] DOU F, WANG J, LEUNG C F, et al. The alterations of critical pore water pressure and micro-cracking morphology with near-wellbore fractures in hydraulic fracturing of shale reservoirs [J]. *Engineering Fracture Mechanics*, 2021, 242: 107481.
- [6] ORUN C B, AKPABIO J U, AGWU O E, et al. Drilling fluid design for depleted zone drilling: An integrated review of laboratory, field, modelling and cost studies [J]. *Geoenergy Science and Engineering*, 2023, 211: 10706.
- [7] LI W, CAO L, LIU X, et al. Study on the effects of changes in pore pressure on wellbore stability [J]. *Journal of Southwest Petroleum University*, 2017, 39(6): 63-68.
- [8] KRISHNA S, IRFAN A S, KESHAVARZ S, et al. Smart predictions of petrophysical formation pore pressure via robust data-driven intelligent models[J]. *Multiscale and Multidisciplinary Modeling, Experiments and Design*, 2024(7): 5611-5630.
- [9] WANG H, MA J, LI L. Pore pressure prediction based on rock physics theory and its application in seismic inversion [J]. *Journal of Applied Geophysics*, 2024, 229: 105494.
- [10] ZHANG P, LIU H, SU Q, et al. Study on faults instability law in hydraulic fracturing based on fluid-solid coupling method [J]. *Journal of Engineering Geology*, 2024, 32(4): 1439-1446.
- [11] ETMINAN M, JAMALI J, RIAHI M A. Formation pore pressure prediction using velocity inversion in southwest Iran [J]. *Petroleum Science and Technology*, 2012, 30(1): 28-34.
- [12] FENG H. Estimating sand-shale formation pore pressure[J]. *Petroleum Science and Technology*, 2011, 29 (22): 2338-2345.
- [13] KHALED S, SOLIMAN AA, MOHAMED A, et al. New models for predicting pore pressure and fracture pressure while drilling in mixed lithologies using artificial neural networks [J]. *ACS Omega*, 2022, 7 (36): 31691-31699.
- [14] CAO S, WANG C, NIU Q, et al. Enhancing pore pressure prediction accuracy: A knowledge-driven approach with temporal fusion transformer[J]. *Geoenergy Science and Engineering*, 2024, 238: 212839.
- [15] KARMARKAR 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.
- [16] BOWERS GL. Pore pressure estimation from velocity data: Accounting for overpressure mechanisms besides undercompaction[J]. *SPE Drilling & Completion*, 1995, 10(2): 89-95.
- [17] HOTTMAN CE, JOHNSON RK. Estimation of formation pressures from log-derived shale properties [J]. *AAPG Bulletin*, 1965, 49(10): 1754.
- [18] EATON BA. The effect of overburden stress on geopressure prediction from well logs [J]. *Journal of Petroleum Technology*, 1972, 24(8): 929-934.
- [19] FILLIPPONE WR. Estimation of formation parameters and the prediction of overpressures from seismic data[C]. *SEG Annual Meeting*. 1982.
- [20] TARANTINO A, DI DONNA A. Mechanics of unsaturated soils: Simple approaches for routine engineering practice[J]. *Rivista Italiana di Geotecnica*, 2019 (4): 5-46.
- [21] YANG W, FENG Y, YANG J, et al. New insights into the pore pressure estimation from sonic velocity data—application of the equivalent depth method in Chinese basins [J]. *IOP Conference Series: Earth and Environmental Science*, 2021, 769(3): 032042.
- [22] DAS G, MAITI S. A machine learning approach for the

- prediction of pore pressure using well log data of Hikurangi Tuaheni Zone of IODP Expedition 372, New Zealand [J]. *Energy Geoscience*, 2023. <https://doi.org/10.1016/j.engeos.2023.100227>.
- [23] DAS G, MAITI S. Ensemble learning-based interpretable method for pore pressure prediction using multivariate well logging data of IODP site U1517[J]. *Earth Science Informatics*, 2025, 18: 206.
- [24] HUANG H, JUN L, HONGWEI Y, et al. Research on prediction methods of formation pore pressure based on machine learning [J]. *Energy Science & Engineering*, 2022, 10(6): 1886-1901.
- [25] REZA MD, AHMAD R. Pore pressure prediction by empirical and machine learning methods using conventional and drilling logs in carbonate rocks [J]. *Rock Mechanics and Rock Engineering*, 2022, 56(1): 535-564.
- [26] SUN B, CHENG Y, HAN Z, et al. Experimental study of a multimer mechanism formation pressure prediction model influenced by shale content [J]. *Geoenergy Science and Engineering*, 2024, 233: 212486.
- [27] ZHANG X, LU Y H, JIN Y, et al. An adaptive physics-informed deep learning method for pore pressure prediction using seismic data [J]. *Petroleum Science*, 2024, 21(2): 885-902.
- [28] 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 & Engineering*, 2022, 211: 110156.
- [29] ANDRIANOV N. Machine-learning upscales realistic discrete fracture simulations [J]. *Journal of Petroleum Technology*, 2021, 73(11): 67-68.
- [30] 苏斌, 侯思祖, 郭威. 基于图像融合和双通道卷积神经网络的配电网故障选线方法研究[J]. *电子测量与仪器学报*, 2024, 38(9): 54-66.
- SU B, HOU S Z, GUO W. Fault line selection method for distribution network based on image fusion and dual-channel convolutional neural network [J]. *Journal of Electronic Measurement and Instrumentation*, 2024, 38(9): 54-66.
- [31] 张国静, 李承家, 韩敬伟, 等. 基于深度学习的多帧瞳孔检测算法 [J]. *电子测量技术*, 2025, 48(9): 168-176.
- ZHANG G J, LI CH J, HAN J W, et al. Multi-frame pupil detection algorithm based on deep learning [J]. *Electronic Measurement Technology*, 2025, 48(9): 168-176.
- [32] 李导, 黄锐, 周雨, 等. 基于改进长短期记忆网络的飞控系统飞参数据异常检测方法[J]. *国外电子测量技术*, 2024, 43(12): 53-61.
- LI D, HUANG R, ZHOU Y, et al. Abnormal flight parameter data detection method for flight control system based on improved long short-term memory network[J]. *Foreign Electronic Measurement Technology*, 2024, 43(12): 53-61.
- [33] DONG Y, LIU Q, DU B, et al. Weighted feature fusion of convolutional neural network and graph attention network for hyperspectral image classification [J]. *IEEE Transactions on Image Processing*, 2022, 31: 1559-1572.
- [34] YANG Y, FENG L, JIAN N, et al. Video stabilization algorithm based on Savitzky-Golay filtering and L1 norm optimization [J]. *Journal of Signal Processing*, 2020, 36(11): 1829-1837.
- [35] CONTRERAS J, WINTERFELD A, POPP J, et al. Spectral zones-based SHAP/LIME: Enhancing interpretability in spectral deep learning models through grouped feature analysis [J]. *Analytical Chemistry*, 2024, Vol. 96(39): 15588-15597.
- [36] ZHAO X, CHEN X, et al. Pore pressure prediction assisted by machine learning models combined with interpretations: A case study of an HTHP gas field, Yinggehai Basin [J]. *Geoenergy Science and Engineering*, 2023, 229: 212114.

作者简介



邹佳玲(通信作者), 2022年6月毕业与西南石油大学机械工程专业, 获博士学位。2022年7月至今任西南石油大学机电工程学院讲师, 主要从事钻井复杂事故智能预警与安全评价、数据挖掘、智能系统、流体智能感知等方向的研究。

E-mail: zoujialing@swpu.edu.cn

Zou Jialing (Corresponding author) received her Ph. D. degree in Mechanical Engineering from Southwest Petroleum University in 2022. Since July 2022, she has been serving as a lecturer at the School of Mechanical and Electrical Engineering, Southwest Petroleum University. Her main research interests include intelligent early warning and safety evaluation of complex drilling accidents, data mining, intelligent systems, and fluid intelligent sensing.



秦长春, 2023 年于西南石油大学获得学士学位, 现为西南石油大学硕士研究生, 主要研究方向为钻井复杂事故智能预警与安全评价。

E-mail: 3172138421@qq.com

Qin Changchun received his B. Sc. degree from Southwest Petroleum University in 2023. He is currently a M. Sc. candidate at the same university. His main research interests include intelligent early warning and safety evaluation of complex drilling accidents.



梁海波, 2008 年于西南石油大学获得博士学位, 现为西南石油大学教授, 主要研究方向为油气井随钻测量新装备、智能测控系统、油气地质导向分析和信息交互分析。

E-mail: secondbo@swpu.edu.cn

Liang Haibo received his Ph. D. from Southwest Petroleum University in 2008. He is currently a professor at Southwest Petroleum University. His main research interests include new equipment for measuring oil and gas wells while drilling,

intelligent measurement and control system, oil and gas geological guidance analysis, and information exchange analysis.



韩毅辉, 博士, 现任西南电子技术研究所敏捷智能计算四川省重点实验室工程师, 主要从事智能计算、特征提取方向的研究。

E-mail: yghan7@163.com

Han Yihui received a Ph. D. degree. He is currently an engineer at the Agile Intelligence Computing Key Laboratory of Sichuan Province, Southwest Institute of Electronic Technology. His main research interests include intelligent computing and feature extraction.



习国江, 博士, 现任西南电子技术研究所敏捷智能计算四川省重点实验室工程师, 主要从事高性能计算方向的研究。

E-mail: xigj11@163.com

Xi Guojiang received a Ph. D. degree. He is currently an engineer at the Agile Intelligence Computing Key Laboratory of Sichuan Province, Southwest Institute of Electronic Technology. His main research interests include high-performance computing.