

超深缝洞型油气藏孔隙度智能学习预测模型

康志江^{1,2}, 邓紫妍³, 杨帆^{1,2}, 周东升³

[1. 中国石化石油勘探开发研究院, 北京 102206; 2. 国家能源碳酸盐岩油气重点实验室, 北京 102206;
3. 中国地质大学(北京), 北京 100083]

摘要: 构建超深层碳酸盐岩油气藏孔隙度的预测模型在勘探开发中具有重要意义。超深缝洞型油气藏埋藏深度超过7 500 m, 地震信噪比偏低, 缝洞非均质性极为显著, 地震波阻抗的缝洞孔隙度模型与测井解释结果相比偏差较大。为此提出了基于深度学习的多地震属性非线性关系孔隙度模型预测方法, 选取与孔隙度相关的8类地震属性, 构建与测井解释孔隙度相匹配的地震属性训练集。通过Box-Cox变换方式对数据集的偏态分布予以改善, 运用地震相约束的深度学习模型以及贝叶斯算法加以优化, 建立了多地震属性与孔隙度非线性关系数学模型。与常用的地震波阻抗预测模型方法相比, 新模型验证井吻合度由24%提高至92%, 孔隙度模型预测精度大幅提升。

关键词: 深度学习; 孔隙度; 碳酸盐岩; 超深层油气; 缝洞型油气藏

中图分类号: TE122.3 **文献标识码:** A

A deep learning-based model for predicting porosity of ultra-deep fractured-vuggy hydrocarbon reservoirs

KANG Zhijiang^{1,2}, DENG Ziyan³, YANG Fan^{1,2}, ZHOU Dongsheng³

[1. Petroleum Exploration and Production Research Institute, SINOPEC, Beijing 102206, China; 2. State Energy Key Laboratory for Carbonate Oil and Gas, Beijing 102206, China; 3. China University of Geosciences (Beijing), Beijing 100083, China]

Abstract: Constructing a porosity prediction model for ultra-deep fractured-vuggy hydrocarbon reservoirs holds great significance for their exploration and exploitation. These reservoirs, with burial depths exceeding 7 500 m, exhibit relatively low signal-to-noise ratios (SNRs) and extremely significant heterogeneity in fractures and vugs. These factors lead to major deviations between the porosity predicted using seismic wave impedance-based models and well log interpretation results for fractured-vuggy reservoirs. In this study, we propose a deep learning-based model for predicting the reservoir porosity involving the nonlinear relationships among multiple seismic attributes. Specifically, eight seismic attributes related to reservoir porosity are selected to construct a seismic attribute training set that matches log-derived porosity. Then, the skewed distribution of seismic attributes in the training set is corrected using the Box-Cox transformation, and then optimized with the seismic facies-constrained deep learning model as well as the Bayesian algorithms. A mathematical model is thereby established illustrating the nonlinear relationships between multiple seismic attributes and reservoir porosity. Compared to the commonly used seismic wave impedance-based prediction model, the newly proposed model can increase the goodness of fit of validation wells from 24% to 92%, substantially enhancing the prediction accuracy.

Key words: deep learning, porosity, carbonate rock, ultra-deep oil and gas, fractured-vuggy hydrocarbon reservoir

引用格式: 康志江, 邓紫妍, 杨帆, 等. 超深缝洞型油气藏孔隙度智能学习预测模型[J]. 石油与天然气地质, 2025, 46(2): 567-574. DOI: 10.11743/ogg20250215.

KANG Zhijiang, DENG Ziyan, YANG Fan, et al. A deep learning-based model for predicting porosity of ultra-deep fractured-vuggy hydrocarbon reservoirs[J]. Oil & Gas Geology, 2025, 46(2): 567-574. DOI: 10.11743/ogg20250215.

收稿日期: 2024-10-20; 修回日期: 2025-01-02。

第一作者简介: 康志江(1969—), 男, 教授级高级工程师, 深层-超深层碳酸盐岩油气藏开发。E-mail: kangzj_syky@sinopec.com。

通信作者简介: 邓紫妍(1999—), 女, 硕士研究生, 大数据和油藏工程。E-mail: 2111210013@email.cugb.edu.cn。

基金项目: 国家自然科学基金企业创新发展联合基金项目(U24B6001, U19B6003)。

中国深-超深层碳酸盐岩油气资源量丰富,油气资源量为 671×10^8 t 油当量, 占中国油气资源总量的 34%, 已经成为中国油气增储上产的关键领域与全新增长点。超深断控缝洞型油气藏属于新发现的一种超深层储层^[1-5], 具有埋藏深(埋深 $> 7\,500$ m)、地震信噪比低、缝洞体结构复杂以及非均质性极强的特点, 传统孔隙度模型预测方法难以满足该类油气藏开发需求。

孔隙度预测模型一般包括 2 大类: ①测井曲线与孔隙度的关系模型, 目的是通过不同类型的测井曲线来综合解释孔隙度, 使解释孔隙度与岩心孔隙度结果相吻合; ②地震属性与测井孔隙度关系模型, 目的是建立预测油气藏孔隙度的地质模型(简称孔隙度模型)。本文研究的孔隙度模型预测方法通常依赖于传统的物理建模^[6-11], 多采用地震波阻抗体来预测。实践表明, 基于地震波阻抗体预测出的超深断控缝洞孔隙度存在较大误差, 其与地震波阻抗体呈非线性关系。

深度学习方法可以用于建立复杂因素的非线性关系模型。近年来深度学习在地球物理勘探领域的应用取得了一些进展^[12-13]; Saljooghi 提出将小波理论与多层感知机相结合的孔隙度预测方法, 以提高人工神经网络的收敛速度和泛化能力^[14]; Zhou 等通过多个个体学习器集成模型获得了比单一模型更好的预测结果^[15]; 魏国华等利用半监督高斯混合模型与梯度提升树实现了对砂岩储层相控孔隙度分布的高精度预测^[16]; 侯贤沐等应用机器学习技术, 结合密度和中子等测井数据实现井上孔隙度预测^[17]; Amirreza 等使用测井数据作为输入, 包括自然伽马(GR)、声波时差(DT)和密度(RHOB)测井等, 而将岩心数据用于模型验证, 提出一种混合卷积循环神经网络(CRNN)深度学习模型来改进复杂碳酸盐岩储层的孔隙度估计^[18]。由此看来, 目前深层碳酸盐岩缝洞型油气藏孔隙度的研究主要聚焦于测井解释孔隙度, 而基于深度学习的孔隙度模型预测方法研究未见报道。

本文依托深度学习对复杂非线性关系的拟合能力以及地震相的先验知识, 构建了一种针对超深多尺度缝洞体油气藏的孔隙度预测模型。此方法基于相干体、相位蚂蚁体、波阻抗和能量梯度等多类地震属性, 建立训练数据集, 构建多类地震属性与孔隙度非线性关系的深度学习模型, 与常用地震波阻抗体预测方法相比, 验证井均方根误差(MSE)降低了 0.73, 吻合度由 63% 提高至 92%, 孔隙度模型预测精度明显提高, 为超深断控缝洞体油气藏孔隙度模型预测提供了新的方法和思路。

1 孔隙度智能学习预测模型构建方法

多类地震属性与同一深度的测井孔隙度进行匹配, 基于皮尔逊相关系数方法, 检测不同地震属性与测井孔隙度之间线性相关的程度; 之后创建机器学习训练集, 将每个地震属性作为一个特征变量, 对特征变量的偏态分布进行正态分布优化, 以解决少数样本学习能力欠佳的问题; 基于贝叶斯算法, 对深度学习模型的神经元和网络层数等参数进行优化, 得到多元地震属性与测井非线性关系模型; 最后进行预测模型的评估。关键技术方法与流程包括: 构建训练数据集, 对地震属性进行 Cox-Box 变换, 依据贝叶斯算法优化神经元和网络层数等参数, 以及构建多元地震属性与测井非线性关系模型(图 1)。

1.1 地震属性优选

1.1.1 收集与测井孔隙度相关的地震属性

断控缝洞储集体孔隙度与缝洞类型、断裂和多尺度裂缝等地质参数有关, 通常相干能量梯度、波相位蚂蚁体、阻抗、张量蚂蚁体和张量本征值等反映了缝洞体孔隙度地质参数。①蚂蚁类属性体体现了中-小尺度裂缝的地质信息, 能够捕捉地下岩石结构微小变化等细微特征, 不同尺度的裂缝与孔隙度直接相关; ②相干类属性体呈现了断裂及断控缝洞体的地质信息, 通过地震数据体中相邻地震道信号的相似性来展现地层的横向非均质性, 进而确定地层中的断层或缝洞体; ③波阻抗属性体反映了地层中孔隙度的变化, 是介质密度与波速的乘积, 波阻抗的变化主要由孔隙或者裂隙所致, 与孔隙度曲线呈显著




图1 基于机器学习的孔隙度模型预测流程

Fig. 1 Flow chart of machine learning-based model for porosity prediction

的镜像对称关系;④张量类属性体展现了地震数据中杂乱反射的结构特征,是将地震数据构建成二维或三维图像数据属性,进而基于局部的构造张量特征值相对大小及组合参数确定地震图像数据中的地质结构属性,能够定性、定量地描述断层和小型缝洞地质体所引发的不连续反射特征。不同地震属性反映了不同储集体地质信息,是孔隙度预测的有效关联参数集。地震属性筛选要基于储集体地质特征,全面、系统地利用各类型地震属性。

1.1.2 井-震数据匹配

测井解释的精度达0.125 m,地震采样预测精度一般为15~25 m,针对地震属性进行数据加密重采样,使地震属性与测井解释数据在同一深度相互匹配得到数据集,实现单井测井与地震数据的对应。测井解释孔隙度更为精确,被视作地震预测孔隙度的目标值(标签)。

1.1.3 地震属性相关性评价与优选

利用皮尔逊相关系数对不同地震属性与测井孔隙度之间线性相关的程度进行定量评价。皮尔逊相关系数是指两个变量之间的协方差和标准差的商,反映两个变量间的线性相关性,其绝对值介于0~1:数值为1时表明具有良好的线性关系,可以用线性方程予以描述;数值为0时则表明不存在线性关系;数值小于0.2被认定为相关性较弱。通过逐一地震属性与测井孔隙度的相关性评价,优选相关性较强的地震属性构建预测训练数据集。

1.2 地震属性训练集预处理

训练集预处理目的是提高数据预测质量,除了常规的缺失值和异常值处理之外,还需要对地震数据进行分布调整。地震属性大多呈现偏态分布,存在显著的偏斜或集中态势,致使深度学习模型在提取属性特征时出现偏差,原因在于深度学习模型更易于学习到地震属性数据的主导趋势,而忽略分布的偏斜部分,导致偏斜部分的地震属性特征更难以被学习,需要进行偏态分布的矫正。矫正方法为Box-Cox变换方法^[1],表达式如下:

$$y(\lambda) = \begin{cases} \frac{(y+c)^\lambda - 1}{\lambda}, & \lambda \neq 0 \\ \ln(1 + \lambda \cdot x), & \lambda = 0 \end{cases} \quad (1)$$

式中: y 是原始数据; $y(\lambda)$ 是变换后的参数; c 是常数; λ 是变换参数。

1.3 基于深度学习的孔隙度模型训练

使用处理好的数据集训练深度学习模型。深度学

习模型的训练一般是通过最小化损失函数的值来实现的,损失函数用于衡量地震属性预测模型值与测井孔隙度值之间的差异,优化的目标是调整模型的参数,以最小化差异,从而提升模型的预测精度。

针对孔隙度大值偏少的问题,本文提出了新的损失函数。损失函数不仅包含孔隙度预测误差,还包括地震相损失项,用于加强模型对地震属性一致性的约束,提高了孔隙度大值的预测精度。具体操作步骤如下:设置损失函数 L_{total} ,计算预测孔隙度($\hat{y}$)与实际孔隙度(y)均方根误差得到深度学习模型预测误差($L_{regression}$),并引入地震相数据损失项($L_{nearest_neighbor}$)来约束深度学习模型孔隙度输出值,使得深度学习模型输出结果不偏离地震相的控制。引入一个参数(λ)来调整两者的相对权重,通过梯度下降算法反向传播更新模型参数,以得到最小总损失值(L_{total})。

$$L_{total} = L_{regression} + \lambda L_{nearest_neighbor} \quad (2)$$

$$L_{regression} = \frac{1}{N} \sum_{i=1}^N (\hat{y}_i - y_i)^2 \quad (3)$$

$$L_{nearest_neighbor} = \frac{1}{N} \sum_{i=1}^N d(\hat{y}_i, \text{center}(\theta_i)) \quad (4)$$

式中: L_{total} 表示总损失函数; $L_{regression}$ 表示回归任务的损失函数; $L_{nearest_neighbor}$ 表示地震相损失函数; N 表示样本个数; $\hat{y}_i$ 是第 i 个样本的孔隙度预测值; y_i 表示第 i 个样本的孔隙度真实值; θ_i 是对应的地震相; $\text{center}(\theta_i)$ 表示地震相 θ_i 对应的孔隙度中心值; $d(\hat{y}_i, \text{center}(\theta_i))$ 为预测值 $\hat{y}_i$ 与地震相 θ_i 的孔隙度中心值之间的距离度量。

预测模型主要包括2个部分:特征提取和回归。特征提取部分承担从多元地震属性中学习与孔隙度相关特征的任务,而回归部分负责将提取到的特征映射至孔隙度值。输入多元地震属性数据(seismic_data),经过特征提取与回归得到模型的预测孔隙度 $\hat{y}$ 。

$$\hat{y} = \text{fc2}(\text{fc1}(\text{flatten}(\text{pool1}(\text{conv1}(\text{seismic_data})))))) \quad (5)$$

其中卷积层 conv1 是第一层卷积操作,提取局部特征。

$$\text{conv1}[i] =$$

$$\text{relu}\left(\sum_{k=0}^{k-1} \text{seismic_data}[i+k] \cdot \text{weight}[k] + \text{bias}\right) \quad (6)$$

relu 是激活函数,表达式为:

$$\text{relu}(x) = \max(0, x) \quad (7)$$

式中: $\text{seismic_data}[i]$ 是输入数据的第 i 个元素; k 表示卷积核的滑动位置; $\text{weight}[k]$ 表示卷积核的权重; bias 表示偏置项。

池化操作 pool1 是在每个滑动窗口上取最大值或平均值。池化操作的数学表达式为:

$$\text{pool1}[i] = \max(\text{conv1}[i], \text{conv1}[i+1]) \quad (8)$$

flatten 将池化后的多维特征图转换为一维向量,

全连接层学表达式为:

$$fc1[i] = \sigma \left(\sum_{j=0}^{M-1} flattened[j] \cdot weight[j, i] + bias[i] \right) \quad (9)$$

$$fc2[i] = \sum_{j=0}^{N-1} fc1[j] \cdot weight[j, i] + bias[i] \quad (10)$$

式中: $fc1[i]$ 和 $fc2[i]$ 分别表示全连接层第 i 个神经元的输出; M 表示第一层全连接层的输入特征数量; N 表示第二层输入特征数量; σ 表示激活函数; $flattened[j]$ 表示输入层或上一层神经元输出经过拉平 (flatten) 处理后的第 j 个元素的值; $weight[j, i]$ 表示连接第 j 个输入到第 i 个神经元的权重; $bias[i]$ 表示第 i 个神经元的偏置项。

在完成特征提取和回归后,模型的训练通过不断优化损失函数进行迭代。采用贝叶斯优化算法优化这些用于构建模型的参数。贝叶斯优化通过动态选择可能提升模型性能的参数组合,逐步找到最优的超参数设置,包括网络层数、神经元个数、迭代次数,以及地震相损失项的权重等,确保模型的预测误差最小化。根据先前试验的结果动态选择下一个可能提升性能的参数组合,找到最优的一组参数取值,使得预测的误差最小。

$$x^* = \operatorname{argmin}_f(x), x \in X \quad (11)$$

式中: x 表示一组超参数组合; X 表示参数组合空间; argmin 是一个数学专用符号,指 $f(x)$ 最小的 x 取值,本文中 $f(x)$ 指地震多属性预测结果与测井解释结果误差最小; x^* 表示 X 中的一组 x ,使得 $f(x)$ 取得最优解。

1.4 模型预测效果评估

抽取多口有测井孔隙度曲线的井不参与深度学习的样本,构建深度学习预测模型,通过多地震属性预测验证井孔隙度曲线,对比预测曲线与测井解释孔隙率曲线,评价预测效果。评价指标为均方根误差 (MSE) 和吻合度 (皮尔逊相关系数 R^2): 均方误差 (MSE) 是指模型预测值与测井解释值之间误差平方的平均值,反映预测结果误差的大小;吻合度 (R^2) 用每个样本预测值与实际值的误差小于 1% 的占比来表示,越接近于 1 表明吻合度越高。

2 超深断控缝洞型油气藏应用

2.1 超深断控缝洞储集体地质特征

顺北 4 号走滑断裂带油气藏是典型的超深断控缝洞型油气藏,位于塔里木盆地顺北油气田,埋深大于 7 500 m,主要产层为中-下奥陶统鹰山组 (O_{1-2y}) 和中奥陶统一间房组 (O_{2yj}),油气藏储层厚度可达 1 000 m,受

大型走滑断裂控制,沿断裂带分布。

断裂带内部地质结构复杂 (图 2),受控于大型走滑断裂带内部差异活动,具有分段成藏、纵向穿层和张扭压扭断续分布特点。以走滑断裂多期活动产生的构造破裂带缝洞储集体为主,其上部被致密碳酸盐岩侧封和上覆巨厚泥岩盖层顶封遮挡,形成断控缝洞型油气藏。缝洞储集体主要由断裂带与破碎体组成,断裂带可分为主、次断裂带,主断裂带多为钻井过程中的漏失点;破碎体可分为 3 类:一类破碎体以洞穴为主;二类破碎体以孔洞为主;三类破碎体以裂缝为主 (图 2)。

由于油气藏埋藏深,地震信噪比偏低,缝洞破碎体的非均质性极强,常规波阻抗反演孔隙度预测值与测井解释孔隙度吻合度低 (图 3),波阻抗反演孔隙度整体大于测井解释孔隙度。




图 2 超深层断控缝洞体单井模型

Fig. 2 Model of fault-controlled fractured-vuggy reservoirs of ultradeep formation from a single well




图 3 超深层油气藏波阻抗预测孔隙度与测井孔隙度对比

Fig. 3 Porosity prediction based on seismic wave impedance vs. well log-derived porosity for ultradeep hydrocarbon reservoirs

2.2 孔隙度预测模型构建

优选出相干能量、增强相干能量、相蚂蚁体、波阻抗、张量蚂蚁体、二特征张量和三特征张量等8种与孔隙度相关的地震属性,这些属性从不同维度表征了超深层断控缝洞型油气藏的孔隙、缝洞、断裂和多尺度裂缝等特征。选取顺北4号断裂带6口井的13 000个测井点与地震数据匹配,该区测井解释的精度达0.125 m,地震采样预测精度为25 m,对地震属性进行数据加密重采样,使地震属性与测井解释数据在同一深度相互匹配,得到以地震属性为特征变量、测井解释孔隙度为标签的数据集。

接下来使用皮尔逊相关系数对数据集进行相关性分析,每个地震属性与测井解释孔隙度之间的线性相关程度(皮尔逊相关系数 R^2)均低于0.1(图4),这表明单一地震属性与测井孔隙度之间不存在线性关系,需要借助深度学习建模技术来构建多元地震属性与孔隙度之间的非线性关系。

对数据集进行缺失值和异常值处理后,对具有偏态分布的地震属性进行Box-Cox变换。某地震属性描述如表1所示,经过Box-Cox变换后,孔隙度数据的均值从原始的孔隙度大幅集中到2.48,标准差为0.75,最大值为4.48,远小于原始数据中的极端值,表明数据分布更加紧凑且波动性显著减小。如图5所示,该属性分布呈现0~20占优并向高值区逐步减小的偏态分布,经过变换优化后,数据分布更为合理,呈多源分布的特点,有效改善了原数据偏移,数据分布更均匀,解决了偏态分布导致的不可预测性。

使用处理好的数据集训练深度学习模型。对搭建好的深度学习模型,设置地震相损失项权重、批处理大




图4 地震属性与孔隙度皮尔逊相关程度热力图

Fig. 4 Heatmap showing Pearson correlation coefficients between seismic attributes and reservoir porosity

表1 广义对数变换前、后某地震属性数据描述

Table 1 Statistics for certain seismic attribute before and after generalized logarithmic transformation

参数	变换前	变换后
统计数量/个	13 000	13 000
平均值	15.288	2.482
方差	15.567	0.748
最小值	1.943	1.079
最大值	87.242	4.480

小、神经网络层数、学习率、迭代训练轮数和丢失率等参数的初始值,以损失函数最小值为目标。通过贝叶斯优化得到最优参数取值,最终得到一个误差最低、预测精度最优的深度学习模型。得到的模型部分参数最优取值见表2。




图5 Box-Cox变换前、后地震属性值频数分布直方图

Fig. 5 Frequency histograms showing the distributions of seismic attribute values before and after Box-Cox transformation

a. 原始地震属性分布;b. 交换后地震属性分布

表2 深度学习模型参数最优取值统计

Table 2 Statistics of optimal parameter values of the deep learning-based model

参数	取值
地震相损失项的权重	1.100
批处理大小	32.000
网络层数	3.000
学习率	0.016
训练轮数	348.000
丢失率	0.180

2.3 预测效果评估

采用均方根误差(MSE)与吻合度(皮尔逊相关系数 R^2)评估模型效果,并与传统波阻抗反演孔隙度方法对比(表3)。 MSE 指标显示深度学习模型的误差显著低于传统模型(比传统方法降低了19.43); R^2 值由0.24提升至0.92,显示深度学习模型在预测孔隙度时表现出更高的精度和更强的预测能力。

从3口井的测井曲线来看(图6),深度学习模型提供了更准确和稳定的预测,从曲线形态上来看,深度学习模型在捕捉细节、处理噪声、反映地质层界限以及适应复杂地质条件方面具有显著优势,能够更好地反映

表3 3口检验井传统模型和深度学习预测孔隙度效果对比

Table 3 Comparison of porosity in three test wells predicted using traditional and deep learning-based models

井号	MSE		R^2	
	传统模型	深度学习	传统模型	深度学习
1	6.70	0.40	0.19	0.89
2	9.60	0.15	0.24	0.94
3	42.80	0.25	0.29	0.93
平均值	19.70	0.27	0.24	0.92

实际数据的波动。

与传统物理方法波阻抗反演的预测结果对比发现(图7),传统方法所预测出的孔隙度总体均在10%以上,且高孔隙度分布于较宽的区域,与实际井测试结果不符;而通过深度学习方法所获得的预测结果,孔隙度总体约为5%,高孔隙度主要分布于主断裂带上,高孔隙度分布区显著减小,与实际井测试结果相吻合。

从孔隙度剖面模型来看,预测结果与单井解释结果颇为一致,然而传统波阻抗反演的预测结果明显偏大(图8),同时其预测孔隙度具有层状特征,与断控储集体的地质认识不相符。在4#井中,深度8330 m处测




图6 3口检验井测井孔隙度预测值与实际测量值对比

Fig. 6 Comparison between predicted and well log-derived porosity of three test wells




图7 传统物理方法(a)与深度学习方法(b)预测孔隙度平面对比

Fig. 7 Comparison of the plan views of porosity predicted using the conventional physical method (a) and the deep learning-based method (b)




图8 传统物理方法(a)与深度学习方法(b)预测孔隙度剖面对比

Fig. 8 Comparison of the profiles of porosity predicted using the conventional physical method (a) and the deep learning-based method (b)

井解释孔隙度为11%,传统波阻抗反演预测的孔隙度值大于20%,深度学习方法预测为10%,可见深度学习预测结果与测井解释孔隙度更贴近。

综合平面和剖面的预测结果,深度学习方法由于融入了丰富的表征超深缝洞型油气藏的地震属性特征,借助深度学习强大的非线性关系拟合能力,更全面地反映了超深断控缝洞型油气藏的结构复杂性,从而使得对

于断控缝洞型储层的孔隙度预测更为准确,为实现油气资源的高效开发和合理利用奠定良好地质基础。

3 结论

1) 深入剖析相干能量梯度、波相位蚂蚁体、波阻抗、张量蚂蚁体和张量本征值等地震属性,构建了多元地震

属性与孔隙度之间的深度学习非线性关系模型。这一多属性融合策略充分运用了地震属性所蕴含的丰富地下结构信息,以及深度学习强大的非线性关系拟合能力。

2) 提出了新的损失函数,损失函数不仅包含孔隙度预测误差,还增加了地震相损失项,加强了模型对地震属性一致性的约束,提升了深度学习模型对高孔样本的学习与预测能力。

参 考 文 献

- [1] 马永生,蔡勋育,云露,等. 塔里木盆地顺北超深层碳酸盐岩油气田勘探开发实践与理论技术进展[J]. 石油勘探与开发, 2022, 49(1): 1-17.
MA Yongsheng, CAI Xunyu, YUN Lu, et al. Practice and theoretical and technical progress in exploration and development of Shunbei ultra-deep carbonate oil and gas field, Tarim Basin, NW China [J]. Petroleum Exploration and Development, 2022, 49(1): 1-17.
- [2] 康志江,张冬梅,张振坤,等. 深层缝洞型油藏井间连通路径智能预测技术[J]. 石油与天然气地质, 2023, 44(5): 1290-1299.
KANG Zhijiang, ZHANG Dongmei, ZHANG Zhenkun, et al. Intelligent prediction of inter-well connectivity path in deep fractured-vuggy reservoirs [J]. Oil & Gas Geology, 2023, 44(5): 1290-1299.
- [3] 李阳,康志江,薛兆杰,等. 中国碳酸盐岩油气藏开发理论与实践[J]. 石油勘探与开发, 2018, 45(4): 669-678.
LI Yang, KANG Zhijiang, XUE Zhaojie, et al. Theories and practices of carbonate reservoirs development in China [J]. Petroleum Exploration and Development, 2018, 45(4): 669-678.
- [4] 康志江,李阳,计秉玉,等. 碳酸盐岩缝洞型油藏提高采收率关键技术[J]. 石油与天然气地质, 2020, 41(2): 434-441.
KANG Zhijiang, LI Yang, JI Bingyu, et al. Key technologies for EOR in fractured-vuggy carbonate reservoirs [J]. Oil & Gas Geology, 2020, 41(2): 434-441.
- [5] 张煜,李海英,陈修平,等. 塔里木盆地顺北地区超深断控缝洞型油气藏地质-工程一体化实践与成效[J]. 石油与天然气地质, 2022, 43(6): 1466-1480.
ZHANG Yu, LI Haiying, CHEN Xiuping, et al. Practice and effect of geology-engineering integration in the development of ultra-deep fault-controlled fractured-vuggy oil/gas reservoirs, Shunbei area, Tarim Basin [J]. Oil & Gas Geology, 2022, 43(6): 1466-1480.
- [6] MIAH M I. Porosity assessment of gas reservoir using wireline log data: A case study of Bokabil Formation, Bangladesh [J]. Procedia Engineering, 2014, 90: 663-668.
- [7] 申波,王刚,樊海涛,等. 一种基于变骨架参数的孔隙度预测新方法[J]. 石油与天然气地质, 2022, 43(3): 711-716.
SHEN Bo, WANG Gang, FAN Haitao, et al. A new method for porosity prediction based on variable matrix parameters [J]. Oil & Gas Geology, 2022, 43(3): 711-716.
- [8] 王西文,石兰亭,雍学善,等. 地震波阻抗反演方法研究[J]. 岩性油气藏, 2007, 19(3): 80-88, 100.
WANG Xiwen, SHI Lanting, YONG Xueshan, et al. Study on seismic impedance inversion [J]. Lithologic Reservoirs, 2007, 19(3): 80-88, 100.
- [9] 邹冠贵,彭苏萍,张辉,等. 地震波阻抗反演预测采区孔隙度方法[J]. 煤炭学报, 2009, 34(11): 1507-1511.
ZOU Guangui, PENG Suping, ZHANG Hui, et al. Predicting aquifer porosity of coal mine by impedance inversion [J]. Journal of China Coal Society, 2009, 34(11): 1507-1511.
- [10] 张秉铭,刘致水,刘俊州,等. 基于多边形孔隙结构模型的砂岩储层总孔隙度预测方法[J]. 西安石油大学学报(自然科学版), 2023, 38(5): 12-19.
ZHANG Bingming, LIU Zhishui, LIU Junzhou, et al. A porosity prediction method for sandstone reservoir based on polygonal pore structure model [J]. Journal of Xi'an Shiyu University (Natural Science Edition), 2023, 38(5): 12-19.
- [11] 段友祥,柳璠,孙歧峰,等. 基于相带划分的孔隙度预测[J]. 南京大学学报(自然科学), 2019, 55(6): 934-941.
DUAN Youxiang, LIU Fan, SUN Qifeng, et al. Porosity prediction based on sedimentary facies [J]. Journal of Nanjing University (Natural Sciences), 2019, 55(6): 934-941.
- [12] 李阳,廉培庆,薛兆杰,等. 大数据及人工智能在油气田开发中的应用现状及展望[J]. 中国石油大学学报(自然科学版), 2020, 44(4): 1-11.
LI Yang, LIAN Peiqing, XUE Zhaojie, et al. Application status and prospect of big data and artificial intelligence in oil and gas field development [J]. Journal of China University of Petroleum (Edition of Natural Science), 2020, 44(4): 1-11.
- [13] ELKATATNY S, MAHMOUD M, TARIQ Z, et al. New insights into the prediction of heterogeneous carbonate reservoir permeability from well logs using artificial intelligence network [J]. Neural Computing and Applications, 2018, 30(9): 2673-2683.
- [14] SALJOOGHI B S, HEZARKHANI A. Comparison of WAVENET and ANN for predicting the porosity obtained from well log data [J]. Journal of Petroleum Science and Engineering, 2014, 123: 172-182.
- [15] ZHOU Zhihua, WU Jianxin, TANG Wei. Ensembling neural networks: Many could be better than all [J]. Artificial Intelligence, 2002, 137(1/2): 239-263.
- [16] 魏国华,韩宏伟,刘浩杰,等. 基于半监督高斯混合模型与梯度提升树的砂岩储层相控孔隙度预测[J]. 石油地球物理勘探, 2023, 58(1): 46-55.
WEI Guohua, HAN Hongwei, LIU Haojie, et al. Facies-controlled porosity prediction of sandstone reservoirs based on semi-supervised Gaussian mixture model and gradient boosting tree [J]. Oil Geophysical Prospecting, 2023, 58(1): 46-55.
- [17] 侯贤沐,王付勇,宰芸,等. 基于机器学习和测井数据的碳酸盐岩孔隙度与渗透率预测[J]. 吉林大学学报(地球科学版), 2022, 52(2): 644-653.
HOU Xianmu, WANG Fuyong, ZAI Yun, et al. Prediction of carbonate porosity and permeability based on machine learning and logging data [J]. Journal of Jilin University (Earth Science Edition), 2022, 52(2): 644-653.
- [18] MEHRABI A, BAGHERI M, BIDHENDI M N, et al. Improved porosity estimation in complex carbonate reservoirs using hybrid CRNN deep learning model [J]. Earth Science Informatics, 2024, 17(5): 4773-4790.

(编辑 张 晟)