

# 基于机器学习的数字岩心孔渗预测方法研究

王依诚, 姜汉桥, 于馥玮, 成宝洋, 徐飞, 李俊键\*

中国石油大学(北京)油气探测与工程国家重点实验室, 北京 102249

\* 通信作者, junjian@cup.edu.cn

收稿日期: 2019-07-26

国家重大专项课题(2017ZX05009-005)、中国石油大学(北京)优秀青年学者基金(2462019QNXZ04)资助

**摘要** 岩石孔渗特征是影响储层流体储集及渗流能力的主要因素。目前数字岩心孔渗参数计算通常采用孔隙尺度建模并进行数值模拟, 具有建模复杂、耗时长的缺点。为此, 本文根据天然岩心CT扫描结果, 运用OpenFOAM生成654组训练样本, 并通过机器学习算法建立数字岩心孔渗快速预测模型, 并对模型超参数进行敏感性分析。当学习率为0.003时, 模型具有较强的泛化能力, 孔渗预测结果误差小于10%的占比90%以上, 且能够在1s内完成。研究结果实现了数字岩心孔渗高效率、高精度预测, 能够有效降低生产成本, 提高工作效率。

**关键词** 机器学习; 数字岩心; 渗透率预测; CT扫描

## Researches on the pore permeability prediction method of 3D digital cores based on machine learning

WANG Yicheng, JIANG Hanqiao, YU Fuwei, CHENG Baoyang, XU Fei, LI Junjian

State Key Laboratory of Petroleum Resources and Engineering, China University of Petroleum-Beijing, Beijing 102249, China

**Abstract** Rock porosity and permeability are the main factors affecting fluid storage and flow capacity in reservoirs. At present, pore scale modeling and numerical simulation are usually adopted in the estimation of properties of digital cores where modeling is complex and time-consuming. Therefore, based on the CT scanning results of natural cores, 654 sets of training samples were generated using OpenFOAM, and a fast prediction model was established by a machine learning algorithm. Sensitivity analysis was further conducted for model hyperparameters. When the learning rate is 0.003, the model displays strong generalization ability and prediction accuracy is above 90%. The time of prediction is reduced from more than one hour to less than one second. We propose a high efficiency and high-precision pore permeability prediction method of 3D digital cores based on machine learning, which can effectively reduce cost and improve work efficiency.

**Keywords** machine learning; digital cores; permeability prediction; CT scanning

doi: 10.3969/j.issn.2096-1693.2019.04.032

引用格式: 王依诚, 姜汉桥, 于馥玮, 成宝洋, 徐飞, 李俊键. 基于机器学习的数字岩心孔渗预测方法研究. 石油科学通报, 2019, 04: 354-363  
WANG Yicheng, JIANG Hanqiao, YU Fuwei, CHENG Baoyang, XU Fei, LI Junjian. Researches on the pore permeability prediction method of 3D digital cores based on machine learning. Petroleum Science Bulletin, 2019, 04: 354-363. doi: 10.3969/j.issn.2096-1693.2019.04.032

## 0 引言

岩心数字化是智能油田发展的重要一环,国内各大油田都在进行建设自动化的立体岩心库,岩心数字化后,研究人员不受时间、地域限制,随时对岩心进行分析,提高了生产决策效率<sup>[1-2]</sup>。孔隙度及渗透率是研究流体岩石渗流规律的主要表征参数,也是储集层产能挖潜和提高采收率的关键<sup>[3-6]</sup>,在岩心数字化建设过程中具有重要意义。

岩心孔渗参数获取主要有两个手段:(1)通过岩心驱替实验测定,此类方法需要特定的实验条件和手段,且对岩心有一定的损伤;(2)通过数字岩心建模并进行数值模拟,目前主要以X射线CT扫描为结果,建立真实三维多孔介质模型,并通过格子玻尔兹曼方法或者有限元模拟方法进行模拟求解。2008年朱益华等<sup>[7]</sup>从现场采集的彩色铸体剖面图中提取孔隙信息重构了一种接近真实岩石的3D孔隙介质数字岩心并用格子玻尔兹曼方法研究孔隙岩石的渗流特性。2015年宋睿等<sup>[8]</sup>基于CT图像通过有限元方法建立了原始岩样孔隙形态的结构化网络模型,并求解了岩样渗透率数据。数值模拟方法受到计算资源的限制,其模拟尺寸一般小于 $500 \times 500 \times 500$ 网格,且计算非常耗时。2013年Amabeoku等<sup>[9]</sup>采用并行运算机制,利用有限元方法将碳酸盐岩数字岩心的模拟尺寸做到 $2000 \times 2000 \times 2000$ 网格,将模拟运算时间从两周缩减为一天。

目前,缺少一种对于岩心孔隙度及渗透率的快速预测方法,这严重阻碍了数字化岩心库的建设过程,机器学习算法是一类从数据中自动分析获得规律,并利用规律对未知数据进行预测的算法,已广泛应用于数据挖掘、计算机视觉、自然语言处理、生物特征识别等领域。而岩心孔隙度及渗透率参数本质上是表征岩心多孔介质的流动规律的特征,因此在问题类型上与机器学习算法的应用领域一致。近年已有学者将机器学习应用到流体力学领域,2002年Milano等<sup>[10]</sup>通过神经网络预测湍流过程中近壁速度场;2019年Rahman等<sup>[11]</sup>基于LSTM(长短期记忆模型)提高湍流流动模拟中的数值模拟质量。

本文主要通过建立实际岩心CT扫描结果建立数字岩心孔渗特征对应数据库,通过机器学习算法对数据库进行训练,实现数字岩心孔渗参数的快速预测,为油田数字化建设提供有效的指导作用。

## 1 基于机器学习的数字岩心孔渗预测方法

基于机器学习的数字岩心的孔渗预测方法以历史数据为基础,通过实验测定方法、测井结果、三维孔隙网络数值模拟结果等为数字岩心添加上数据标签,形成孔隙预测学习数据库,通过模型对数据库的学习,当再有新的数据时,只需要通过CT扫描,生成原始CT扫描数据,即可快速完成岩心的孔渗参数预测,无需再进行实验测定或者数值模拟,能够极大提高参数获取效率,具体工作流程如图1所示。

### 1.1 卷积神经网络

岩心通过X射线CT扫描获取的数据为岩心二维灰度图像序列,通过选取合适的尺寸将二维切片图像序列通过重建算法重构得到最终的三维数字岩心体,即为机器学习的输入数据,而输出数据则为岩心的孔隙度及渗透率参数,为一组连续数值结果。根据输入输出数据特性,本文主要通过三维卷积神经网络构建数字岩心孔渗预测模型。卷积神经网络(Convolutional Neural Network, CNN)是一种前馈神经网络,它的人工神经元可以响应一部分覆盖范围内的周围单元,对于大型图像处理有出色表现。1998年LeCun等<sup>[12-14]</sup>人确立了CNN的现代结构,CNN能够得出原始图像的有效表征,这使得CNN能够直接从原始像素中,经过极少的预处理,识别视觉上的规律。典型的卷积神经网络包括输入层、卷积层、池化层、全连接层和输出层(如图2)。

#### 1.1.1 卷积层

卷积层主要作用是识别输入数据的特征,一个卷积核可以提取一个特征,不同卷积核可以提取图像的不同特征。CNN的最大特点是局部感知和权值共享<sup>[15-18]</sup>。一般认为人对外界的认知是从局部到全局的,而图像的空间联系也是局部的像素联系较为紧密,而距离较远的像素相关性则较弱。因而,每个神经元其实没有必要对全局图像进行感知,只需要对局部进行感知,然后在更高层将局部的信息综合起来就得到了全局的信息。为了检测图像不同位置的同一特征,某个局部区域的权值可以共享用于另一个区域(即权值共享性)。局部感知和权值共享保证模型准确提取特征的同时,减少权值参数的个数,从而大幅度减少计算复杂度。卷积层的计算公式为:

$$C = \sigma(I \circ \omega + b) \quad (1)$$

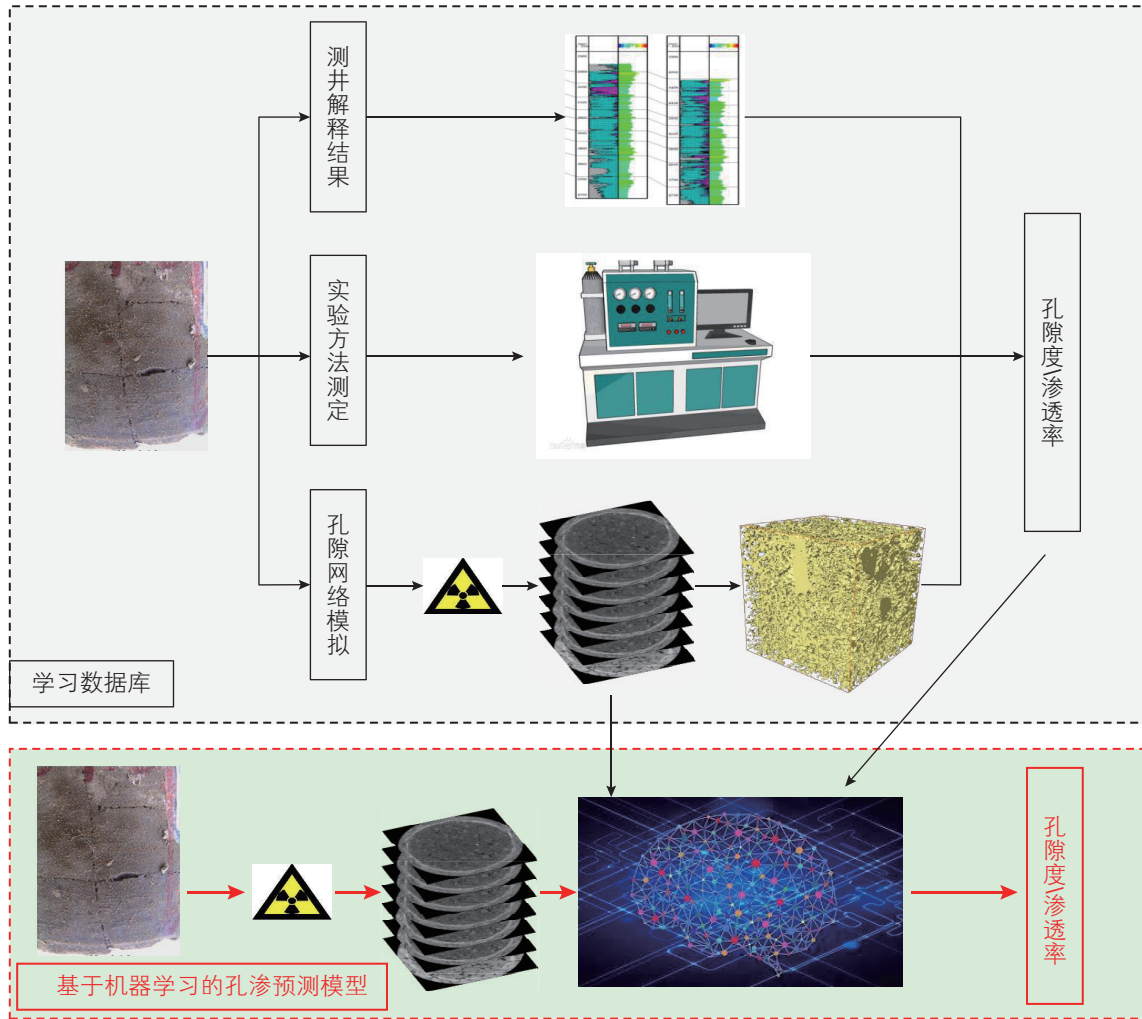


图1 基于机器学习的数字岩心孔渗预测流程

Fig. 1 The workflow of digital core pore permeability prediction based on machine learning




图2 卷积神经网络模型的基本结构

Fig. 2 Architecture for convolutional neural network

其中， $\sigma$ 表示激活函数， $I$ 表示输入图像灰度矩阵， $\omega$ 表示卷积核， $\circ$ 表示卷积操作， $b$ 表示偏置项。

卷积层提取特征的过程如图3所示，原始输入像素为 $10 \times 10$ ，选择 $5 \times 5$ 卷积核，进行卷积运算，最终得到 $(10-5+1) \times (10-5+1)=6 \times 6$ 特征图。

### 1.1.2 池化层

池化层主要是在卷积后来简化卷积层输出维度来降低计算复杂度，是一种统计聚合操作，常见的池化方法有最大值池化和平均池化。以最大池化为例，图4左图所展示的池化前特征图，选择池化过滤器为




图3 二维卷积操作过程

Fig. 3 Architecture for convolutional neural network

2×2, 步长为2, 其左边部分中左上角 2×2 的矩阵中 6 最大, 右上角 2×2 的矩阵中 8 最大, 左下角 2×2 的矩阵中 3 最大, 右下角 2×2 的矩阵中 4 最大, 所以其池化结果如图 4 右所示。

1.1.3 全连接层

区别于上述局部连接的概念, 全连接表示每个神经元都与相邻层的所有神经元互相连接。全连接层实质上就是一个多层感知器, 根据研究目的可选择不同的感知器。如需要进行分类, 则输出层使用 Softmax 激励函数; 如果任务是回归, 则输出层不需要使用 Softmax 函数, 直接对前一层进行累加即可。对于整个 CNN 模型来说, 卷积层和池化层称为特征提取器, 全连接层就是目标转换函数。

1.2 三维卷积神经网络

二维卷积在图像处理有着不凡的效果, 然而在处理视频、CT 数据上无法反应时间、空间上的特征信息<sup>[19]</sup>, 需要通过三维卷积神经网络 (3D CNN) 来完成此类任务。三维卷积与二维卷积主要在卷积、池化时多了一个维度, 具体区别见图 5。




图4 池化过程示意图

Fig. 4 Architecture for Convolutional Neural Network




图5 三维卷积示意图

Fig. 5 Architecture for Convolutional Neural Network



## 2 实例应用

### 2.1 学习数据库建立

机器学习训练数据库是本文建立网络的重要组成部分,为了验证模型的预测能力,本文对具有不同渗透率的天然岩心的CT扫描结果进行提取分割,并采用OpenFOAM开源框架建立三维孔隙网络模型,计算每个样本的孔渗参数,形成训练数据库。

实验岩心选择江苏油田3块砂岩油藏天然岩心,基本参数见表1。对3块岩心进行Micro-CT扫描,CT扫描分辨率为 $2.98\ \mu\text{m}$ ,扫描后尺寸原始尺寸为 $1920 \times 1920 \times 1536$ 像素,考虑到岩心扫描边缘效应,每块岩心扫描结果将截取 $1200 \times 1200 \times 1200$ 像素作为基础数据,图像二值化算法主要采用孔隙度校正方法保证图像分割的正确性,二值化结果见图6。

考虑到计算机运算能力,对每个基础数据进行下向采样完成分割数据,每组基础数据的采样数为:

表1 实验岩心基本参数

Table 1 Parameters of experimental core

岩心编号	孔隙度/%	渗透率/mD
#1	20.36	84.48
#2	22.41	238.64
#3	26.33	568.47

$$N_{\text{sub}} = \left( \frac{I_{\text{ori}}}{I_{\text{stride}} + I_{\text{sub}}} \right)^3 \quad (2)$$

式中, $I_{\text{ori}}$ 为原始数据像素尺寸, $I_{\text{sub}}$ 为采样子块像素尺寸, $I_{\text{stride}}$ 为采样间隔像素,考虑到计算资源, $I_{\text{sub}}$ 取200, $I_{\text{stride}}$ 取0,每块岩心原始数据能够获得218个子块数据3块岩心共生成654个子块数据,训练数据流程见图7。

岩石的绝对渗透率是岩石的固有属性,其大小仅仅取决于岩石的孔隙结构,是用来表征油藏的非均质性和各向异性的重要参数,利用达西定律(公式3)可计算岩石单相绝对渗透率。




图6 岩心二维切片

Fig. 6 Two-dimensional cross-sectional images of cores




图 7 训练数据生成流程图

Fig. 7 Workflow of training data generation

$$v = \frac{k\Delta P}{\mu L} \quad (3)$$

式中， $v$  表示达西速度； $k$  为绝对渗透率； $\Delta P$  为驱替压差； $\mu$  为流体黏度； $L$  为岩样的长度。

当考虑到所通过岩石的流体为不可压缩流体，密度为定常数；流体为牛顿流体，其动态黏度为常数；流动过程为稳定流，流体流速不会随时间变化；流速较小，流动过程为层流。可以将Navier-Stokes方程简化为：

$$\begin{cases} \nabla \cdot v = 0 \\ \mu \nabla^2 v - \nabla p = 0 \end{cases} \quad (4)$$

式中， $\nabla \cdot$  表示散度算子， $\nabla^2$  表示梯度算子， $v$  为介质中流相的流体速度， $\nabla$  为拉普拉斯算符， $p$  表示介质中流相流体的压力。

对于每个子块，其数据维度为  $200 \times 200 \times 200$  的二值化三维数据体，通过开源软件OpenFoam建立三维单相流模型，通过求解Navier-Stokes方程，能够对稳定状态的压力及流速进行求取，模型压差设置为 1 Pa，模拟时间总时间为 1 s，时间步长为 0.1 s，计算结果如图 8、图 9 所示。

根据模型求得的稳定状态下的截面流速，通过

式(3)获取到每个数字岩心子块的渗透率，654 组样本计算结果如图 10 所示。样本有效孔隙度分布范围为 0.05~0.35，平均孔隙度为 0.21，渗透率分布范围为 5~4042 mD，平均渗透率为 616 mD，有效孔隙度与渗透率在对数坐标上呈明显的直线关系，因此在设计训练样本时，选择有效孔隙度和渗透率的对数值作为预测结果。

## 2.2 卷积神经网络设计

模型每个样本的输入数据为三维数字岩心数据体，维度为  $200 \times 200 \times 200$ ，输出维度为  $2 \times 1$ ，分别代表孔隙度的大小和渗透率的对数，根据训练数据输入输出维度，3D CNN 模型的网络结构设计参数如表 2 所示。

模型主要由卷积层、池化层、激活层和全连接层




图 8 三维单相流模型压力分布 (1 s)

Fig. 8 Pressure distribution of three-dimensional single-phase flow model (1 s)




图 9 三维单相流模型流速分布 (1 s)

Fig. 9 Velocity distribution of three-dimensional single-phase flow model (1 s)




图 10 训练样本孔隙度渗透率分布

Fig. 10 Porosity and permeability distribution of training data

表 2 3D CNN 模型参数设置

Table 2 The parameter of 3D CNN

编号	层名	输入	核尺寸	步长	填充	输出
1	Conv1	1@200×200×200	5	1	2	4@200×200×200
2	Pooling1	4@200×200×200	2	1	—	4@100×100×100
3	Conv2	4@100×100×100	5	1	2	8@100×100×100
4	Pooling2	8@100×100×100	2	1	—	8@50×50×50
5	Conv3	8@50×50×50	5	1	2	16@50×50×50
6	Pooling3	16@50×50×50	2	1	—	16@25×25×25
7	Conv4	16@25×25×25	5	1	2	32@25×25×25
8	Pooling4	32@25×25×25	2	1	—	32@12×12×12
9	Conv5	32@12×12×12	5	1	2	64@12×12×12
10	Pooling5	64@12×12×12	2	1	—	64@6×6×6
11	FC6	64@6×6×6	—	—	—	13824@1
12	FC7	13 824@1	—	—	—	2@1

注: Conv 为卷积层, Pooling 为池化层, FC 为全连接层

构成。模型卷积核设置均为  $5 \times 5 \times 5$ , 激活函数均采用 ReLU 激活函数, 误差函数选择平方和误差函数。每层对应的特征图个数分别为 4, 4, 8, 8, 16, 16, 32, 32, 64, 64, 13 824, 2。对于全连接层, 运用一个 13 824 维的全连接层将分布式特征数据集集合到一个 13 824 维的样本空间中, 全连接层进行特征融合, 最后的二维结果分别代表预测的有效孔隙度和渗透率对数值。将 654 组三维 CT 数据分随机挑选 50 组作为

测试数据, 其余 604 组数据作为训练数据, 迭代次数设置为训练代数设置为 400。

### 2.3 损失函数

损失函数是模型对数据拟合程度的反映, 由于本次研究目的是预测, 所以选择最小平方误差判别 (Minimum Squared-Error, MSE) 作为损失函数。

$$MSE = \frac{1}{m} \sum_1^m (y_i - f(x_i))^2 \quad (5)$$

式中,  $y_i$  和  $f(x_i)$  分别表示第  $i$  个样本真实值和预测值,  $m$  为样本个数。训练的目标是使  $MSE$  变小, 因此训练过程就成为了一个无约束优化过程。

### 2.4 学习率

学习率是卷积神经网络中的一个重要的超参数, 合适的学习率是训练出好模型的关键要素之一, 本次模型学习率分别设置了 (0.001,0.003,0.005,0.01,0.03) 以研究不同学习率对模型训练结果的影响。

### 2.5 结果分析

图 11 展示了不同学习率下相同参数 3D CNN 模

型训练过程中训练误差的变化情况, 当学习率  $\alpha=0.03$  时, 由于学习率过大, 训练误差振荡严重, 训练一定代数误差曲线开始上扬;  $\alpha=0.001$  时, 由于学习率过小, 模型收敛速度慢, 在达到迭代次数后模型仍未达到较好的训练结果; 当  $\alpha=0.005$  和  $0.01$  时, 模型快速收敛, 在较小的迭代次数后即达到水平, 后期训练误差基本保持不变;  $\alpha=0.003$  时, 模型训练误差下降较为平稳, 在训练后期训练逐渐平稳且收敛速度较高, 因此本文选定  $\alpha=0.003$  训练 3D CNN 预测模型。

通过测试集 50 组数据对模型的泛化能力进行检测, 从图 12 中可以看出, 模型孔隙度预测误差小于 5% 的占 95.74%, 渗透率预测误差小于 10% 的占 91.49%, 并且在孔渗关系上与真实数据有着较强的符合关系 (如图 13), 说明基于此模型具有较强的泛化能力。




图 11 不同学习率 3D CNN 模型训练误差变化  
Fig. 11 Training error of 3D CNN model with different learning rates




图 12 测试数据累计误差分布  
Fig. 12 accumulative error of test data




图 13 测试数据孔隙度渗透率分布  
Fig. 13 Porosity and permeability distribution of test data



对于建立的预测模型,从训练数据中选取10个样本与OpenFOAM计算速度进行对比。OpenFOAM每次均需要进行建模及数模运算,数值模拟方法平均用时在1.58 h,而通过训练好的机器学习模型预测用时仅为0.03 s,为数字岩心渗透率的快速预测提供了有效的解决方案。

### 3 结论

(1)根据实际天然岩心CT扫描结果运用开源流体力学计算模块OpenFOAM生成了数字岩心孔渗预测数据库,通过三维卷积神经网络建立了数字岩心孔隙快速预测模型,并取得了较好的训练结果,说明机器学习在数字岩心特征提取上具有较大潜力。

(2)分析了学习率对模型训练效果的影响,学习率过大训练误差会发生大幅振荡且后期曲线上扬,学习率过小则收敛速度较慢,本次模型的最佳学习率为0.003,能够达到较快的收敛速度且能有效避免过拟合。

(3)分析预测结果与真实孔渗,预测误差小于10%的概率结果占90%以上,说明模型具有较强的泛化能力,能够对数字岩心进行快速孔渗预测,建立的预测模型与传统数值模拟方法在预测速度上具有数量级的提升,实现了数字岩心孔渗高效率、高精度预测,能

够有效降低生产成本,大幅度提高工作效率。

### 4 展望

目前,前人通过机器学习在图像、视频及语音领域进行了大量的研究,但对基于CT扫描结果建模的数字岩心孔渗参数预测还尚未有报道。本文提出了采用三维卷积神经网络进行的数字岩心孔渗参数预测方法,该方法通过三维卷积能够对数字岩心进行自动特征提取,并完成快速预测,训练好的模型预测耗时小于1 s,展示了三维卷积神经网络对于数字岩心特征提取的潜力。

然而,机器学习对于数字岩心更为复杂的特征提取是否具有同样的效果还需要进一步验证,需要在以下方面进行深入研究:

(1)数字岩心两相渗流特征。目前采用的训练样本是采用单相流模拟结果进行预测,可进一步选择两相流模拟生成训练样本,探索机器学习对数字岩心相渗的预测。

(2)对于孔喉的非均质性,可以通过对水驱后的数字岩心油水饱和度结果进行学习,预测数字岩心不同的孔喉动用的难易程度,为储层评价提供新思路。

### 参考文献

- [1] 刘锋,张红梅,秦恩鹏.吐哈油田网络数字化岩心库建设[J].新疆石油地质,2005,26(2):215-216.[LIU F,ZHANG H M,QIN E P.Establishment of the network digitalized core database system of Tuha oilfield[J].Xinjiang Petroleum Geology,2005,26(2):215-216.]
- [2] 张红强,贾朋涛,程玉群.延长石油页岩气数字化岩心库的建设及应用[J].中国石油石化,2017 9(1):144-145.[ZHANG H Q,JIA P T,CHENG Y Q.Construction and application shale digitalized core database system of Yanchang oilfield[J].China Petrochem,2017,9(1):144-145.]
- [3] 林承焰,吴玉其,任丽华,等.数字岩心建模方法研究现状及展望[J].地球物理学进展,2018,33(02):679-689.[LIN CH Y,WU Y Q,REN L H,et al.Review of digital core modeling methods[J].Progress in Geophysics,2018,33(2):679-689.]
- [4] 熊伟,刘华勋,高树生,等.低渗透储层特征研究[J].西南石油大学学报(自然科学版),2009,31(5):89-92.[XIONG W,LIU H X,GAO S S,et al.Low permeability formation characters[J].Journal of Southwest Petroleum University: Science & Technology Edition,2009,31(5):89-92.]
- [5] 况昊,瞿建华,王振奇,等.白家海凸起一阜北斜坡八道湾组储层特征研究[J].西南石油大学学报(自然科学版),2012,34(2):29-36.[KUANG H,QU J H,WANG ZH Q,et al.Study on reservoir characteristics in Badaowan Formation,Baijiahai uplift—Fubei slope[J].Journal of Southwest Petroleum University: Science & Technology Edition,2012,34(2):29-36.]
- [6] 王学武,杨正明,李海波,等.核磁共振研究低渗透储层孔隙结构方法[J].西南石油大学学报(自然科学版),2010,32(2):69-72+199.[WANG X W,YANG Z M,LI H B,et al.Experimental study on pore structure of low permeability core with NMR spectra[J].Journal of Southwest Petroleum University: Science & Technology Edition,2010,32(2):69-72+199.]
- [7] 朱益华,陶果,方伟,等.3D多孔介质渗透率的格子 Boltzman 模拟[J].测井技术,2008,32(1):25-28.[ZHU Y H,TAO G,FANG W,et al.,Lattice boltzmann simulation of permeability in 3D porous medium[J].Well Logging Technology,2008,32(1):25-28.]
- [8] 宋睿,刘建军,李光.基于CT图像及孔隙网络的岩芯孔渗参数研究[J].西南石油大学学报(自然科学版),2015,37(3):138-145.[SONG R,LIU J J,LI G.Researches on the pore permeability of core sample based on 3D Micro-CT images and pore-scale structured element models[J].Journal of Southwest Petroleum University: Science & Technology Edition,2015,37(3):138-145.]

- [9] AMABEOKU M O, AL-GHAMDI T M, MU Y, et al. Evaluation and application of digital rock physics (DRP) for special core analysis in carbonate formations[C]. IPTC: International Petroleum Technology Conference, Beijing, China, 2013.
- [10] MILANO M, KOUMOUTSAKOS P. Neural network modeling for near wall turbulent flow[J]. Journal of Computational Physics, 2002, 182(1): 1–26.
- [11] RAHMAN S, PAWAR S, SAN O, et al. A non-intrusive reduced order modeling framework for quasi-geostrophic turbulence[J]. arXiv preprint arXiv: 1906.11617, 2019.
- [12] LBRAGIMOV B, XING L. Segmentation of organs-at-risks in head and neck CT images using convolutional neural networks[J]. Medical physics, 2017, 44(2): 547–557.
- [13] LECUN Y, BOTTOU L, BENGIO Y, et al. Gradient-based learning applied to document recognition[J]. Proceedings of the IEEE, 1998, 86(11): 2278–2324.
- [14] KIM Y. Convolutional neural networks for sentence classification[J]. arXiv preprint arXiv: 1408.5882, 2014.
- [15] LECUN Y, BENGIO Y, HINTON G. Deep learning[J]. Nature, 2015, 521(7553): 436.
- [16] CASAMITJANA A, PUCH S, ADURIZ A, et al. 3D Convolutional neural networks for brain tumor segmentation: A comparison of multi-resolution architectures[C]. International Workshop on Brainlesion: Glioma, Multiple Sclerosis, Stroke and Traumatic Brain Injuries. Springer, Cham., 2016.
- [17] KAMNITSAS K, LEDIG C, NEWCOMBE V F J, et al. Efficient multi-scale 3D CNN with fully connected CRF for accurate brain lesion segmentation[J]. Medical image analysis, 2017, 36(1): 61–78.
- [18] CICEK Ö, ABDULKADIR A, LIENKAMP S S, et al. 3D U-Net: Learning dense volumetric segmentation from sparse annotation[C]. International conference on medical image computing and computer-assisted intervention. Springer, Cham., 2016.
- [19] RAEINI A Q, BLUNT M J, BIJELJIC B. Modelling two-phase flow in porous media at the pore scale using the volume-of-fluid method[J]. Journal of Computational Physics, 2012, 231(17): 5653–5668.

(责任编辑 林伯韬 编辑 付娟娟)