

数字岩心渗流物理特性智能预测研究进展^{*}

梁建勋^{1,2,3}, 贾宁洪^{2,3,4}, 吕伟峰^{2,3,4},
张青^{3,4}, 谢驰宇⁵

- (1. 中国科学院大学, 北京 100049;
2. 中国科学院 渗流流体力学研究所, 河北 廊坊 065007;
3. 提高油气采收率全国重点实验室, 北京 100083;
4. 中国石油勘探开发研究院, 北京 100083;
5. 北京航空航天大学 宇航学院, 北京 100191)

(本刊青年编委谢驰宇来稿)

摘要: 岩心分析是储层评价的基石, 数字岩心技术(digital rock physics, DRP)通过三维成像与数值模拟, 实现了对储层微观结构与渗流特性的定量表征。本文总结了数字岩心技术从“所见为所得”结构表征范式, 到“所算为所得”数值计算范式, 再到“所学为所得”智能预测范式的演进历程。前两代范式面临代表性单元体(representative elementary volume, REV)尺度难寻、数值计算成本高昂等核心瓶颈。本文从结构特性、单相渗流特性(渗透率)以及多相渗流特性(相对渗透率、毛管压力、润湿性)等方面着重梳理了“所学为所得”的数字岩心分析技术进展。该范式以深度学习为核心, 为突破传统瓶颈提供了革命性路径: 一方面, 利用生成对抗网络(generative adversarial networks, GANs)与超分辨率技术(super-resolution, SR), 通过数据驱动重建和增强数字岩心, 缓解了 REV 难题; 另一方面, 通过构建卷积神经网络(convolutional neural network, CNN)等高效代理模型, 将物性预测速度提升数个数量级, 有效解决了计算耗时问题。最后, 本文探讨了当前数字岩心智能预测技术在数据依赖、模型泛化与物理可解释性方面面临的挑战, 并展望了将物理机理深度融入 AI 模型、推动多尺度数据融合以及构建储层“数字孪生”等未来发展方向, 支撑我国智慧油田建设。

关键词: 数字岩心; 人工智能; 深度学习; 渗流物性; 参数预测

中图分类号: O357.3 **文献标志码:** A **DOI:** 10.21656/1000-0887.460219

Advances in Intelligent Prediction of the Percolation Properties of Digital Rocks

Liang Jianxun^{1,2,3}, Jia Ninghong^{2,3,4}, Lü Weifeng^{2,3,4},
Zhang Qing^{3,4}, Xie Chiyu⁵

- (1. University of Chinese Academy of Sciences, Beijing 100049, P.R. China;
2. Institute of Porous Flow & Fluid Mechanics, Chinese Academy of Sciences,

^{*} 收稿日期: 2025-12-02; 修订日期: 2025-12-24

基金项目: 中国石油天然气股份有限公司科技项目“油气勘探开发人工智能关键技术研究”(2023DJ84)

作者简介: 梁建勋(2001—), 男, 硕士生(E-mail: liangjianxun24@mailsucas.ac.cn);

贾宁洪(1981—), 男, 高级工程师(通信作者, E-mail: jianinghong@petrochina.com.cn);

谢驰宇(1990—), 男, 教授, 博士生导师(通信作者, E-mail: xiechiyu@buaa.edu.cn).

引用格式: 梁建勋, 贾宁洪, 吕伟峰, 张青, 谢驰宇. 数字岩心渗流物理特性智能预测研究进展[J]. 应用数学和力学, 2026, 47(7): 825-844.

Langfang, Hebei 065007, P.R. China;

3. *State Key Laboratory of Enhanced Oil and Gas Recovery,*

Beijing 100083, P.R. China;

4. *Research Institute of Petroleum Exploration and Development, PetroChina,*

Beijing 100083, P.R. China;

5. *School of Astronautics, Beihang University, Beijing 100191, P.R. China)*

(Contributed by Xie Chiyu, Member of the Youth Editorial Board of AMM)

Abstract: Core analysis is the cornerstone of reservoir evaluation. The digital rock physics (DRP) enables the quantitative characterization of reservoir microstructures and flow properties through 3D imaging and numerical simulation. The evolution of DRP paradigms was reviewed from the 1st-generation “What you see is what you get” (geometric characterization) and the 2nd-generation “What you calculate is what you get” (numerical simulation), to the emerging 3rd-generation “What you learn is what you get” (intelligent prediction). The 1st 2 paradigms face 2 core bottlenecks: the difficulty in determining the representative elementary volume (REV) and the prohibitive computational costs of numerical simulations. The progress of the 3rd-generation intelligent prediction paradigm was systematically summarized, with the focus on structural properties, single-phase permeability, and multiphase flow properties (relative permeability, capillary pressure, and wettability). Centered on deep learning, this paradigm offers revolutionary pathways to overcome traditional limitations: on one hand, the generative adversarial networks (GANs) and the super-resolution (SR) techniques were employed for data-driven reconstruction to mitigate REV challenges; on the other hand, the efficient surrogate models, such as the convolutional neural networks (CNNs), were constructed to accelerate property prediction by orders of magnitude. Finally, the current challenges regarding data dependence, model generalization, and physical interpretability were discussed to outlines future directions, including integrating physical mechanisms into AI models (physics-informed AI), promoting multi-scale data fusion, and constructing reservoir “digital twins” to support the development of smart oilfields.

Key words: digital core; artificial intelligence; deep learning; percolation properties; parameter prediction

0 引言

① 数字岩心及其渗流物性预测的重要性

岩心分析是储层评价与油气田合理开发的基础,是探索地下储层孔隙介质微结构及流体渗流过程最直接的途径.传统的物理岩心实验具有破坏性、成本高、实验耗时长等劣势^[1],这些劣势在处理孔隙结构复杂的储层时尤为突出,传统的实验方法并不能完全解释复杂油水相互作用和微观流动机制^[2],无法满足精细表征油藏尺度油水相互作用及微孔流动过程的需求.因此,地球物理学界一直在寻找一种无损、可重复表征储层特征的技术手段,数字岩心技术应运而生^[3].

数字岩心技术或数字岩石物理(digital rock physics, DRP)^[4]如图1所示,是通过微米/纳米计算机断层扫描(micro-computed tomography, micro-CT)^[5]等高分辨率成像技术获取岩石样品三维孔隙结构高保真数字模型,以此开展物性分析、流体流动模拟分析的新型技术^[3,6].数字岩心技术能够在不破坏岩心样品本身结构的前提下进行多次重复性虚拟实验,避免了传统物理实验中流体注入对孔隙结构的潜在不可逆改变^[7-8].三维图中的孔隙喉道、矿物组分等可借助先进图像处理和分割算法进行提取量化,获得与真岩心具有拓扑和几何一致性的数字模型^[9-10].这一技术进一步扩大了岩心分析的应用,已成为地球科学与能源工程中的重要分析技术.其可以用于常规油气勘探开发中剩余油微观赋存模式识别、方案优化和提升采收率^[2];页岩气等非常规油气领域的复杂基质多尺度流动预测^[11-13];二氧化碳地下埋存过程的安全性、有效性分析^[14-15];地下储氢(UHS)储层动态响应与密封能力评价^[7,16];天然气水合物储层研究^[1]以及煤层瓦斯开采^[15]等.数字岩心技术的最终目标不仅是静态描述孔隙结构,更重要的是预测储层的渗流物性.渗透率、相对渗透率和毛管压力等渗流物性是反映微观孔隙结构对储层宏观油藏动态响应的基石^[17-18],是表征流体通过孔隙介质流动能

力和流体分相特征的关键参数,对油藏产能和动态响应具有重要的影响^[19]。绝对渗透率是表征岩石允许单一相流体通过的能力^[20],相对渗透率和毛管压力曲线反映了油、气、水多相流体在孔隙内相互竞争、互相作用的复杂行为,对水驱油、气体注入过程和圈闭有效性至关重要^[15-16,21]。利用数字岩心模型,通过直接数值模拟方法(如有限差分、有限体积等经典计算流体力学(computational fluid dynamics, CFD)方法和格子 Boltzmann 方法(lattice boltzmann method, LBM)^[22]或简化的孔隙网络模型(pore-network models, PNM)^[21]等能够计算这些重要的渗流物性参数。从而在微观孔洞几何形状与宏观物理性质(如渗流规律)之间建立起确定性的联系,为油气田勘探开发、二氧化碳封存、地下储存等众多重大工程问题提供了科学依据^[23-24]。




图 1 数字岩石物理预测岩石物理特性的工作流程

Fig. 1 The workflow of digital petrophysics for predicting petrophysical properties

② 数字岩心分析技术的范式演进

数字岩心分析技术作为储层评价的核心手段,如图 2 所示,其发展历程体现了从几何表征到物理模拟,再到智能预测的认知深化。为了厘清技术脉络,本文将概括为三种主要范式:侧重几何拓扑表征的结构描述范式(即“所见为所得”)、基于物理方程求解的数值模拟范式(即“所算为所得”),以及新兴的数据驱动智能预测范式(即“所学为所得”)。需要特别说明的是,结构表征与数值模拟在发展历程上长期并行、互为支撑:高精度的三维成像为数值模拟提供了边界条件,而数值模拟反过来验证了结构表征的有效性。然而,随着人工智能技术的介入,分析方法正经历从算理驱动向数据驱动的深刻变革,以解决传统方法中存在的效率与尺度瓶颈^[25]。

“所见为所得”:这是数字岩心分析的基础,重点在于通过微/纳米 CT 或聚焦离子束扫描电子显微镜(FIB-SEM)^[26]等成像技术获取岩石内部结构,并利用图像处理算法定量表征其静态几何拓扑特征。在此范式下,孔隙度、比表面积、配位数等参数通过图像体素统计直接获取,属于对孔隙空间几何形态的直接描述。而随着高维成像技术和计算流体力学的发展出现了定量计算方法,其具体工作步骤是通过微/纳米 X 射线计算机断层扫描或 FIB-SEM 扫描设备获取岩样内部结构,建立数字化岩心模型^[27]。然而,此范式只描述岩心的结构,如孔隙度、迂曲度等结构特征,缺乏岩心的物理性质预测。另一个问题便是代表性单元体(representative elementary volume, REV)^[28]:高分辨扫描往往导致较小的视场(field of view, FOV)。这意味着生成的数字岩心样品并不能充分表征真实储层的非均质性,其计算结果能否代表真实情况存在争议^[27]。




图 2 核心分析技术从定性描述到智能预测的范式演变^[25]

Fig. 2 The paradigm evolution of the core analytics from qualitative description to intelligent prediction^[25]

“所算为所得”:随着计算流体力学的发展,研究重点转向在数字化岩心模型上进行直接数值模拟。该范式通过在孔隙空间内求解 Navier-Stokes 方程、格子 Boltzmann 方程或构建孔隙网络模型,基于物理守恒定律

计算绝对渗透率、相对渗透率及毛管压力曲线等动态渗流参数^[29]。此范式将分析从几何形态提升到了物理机理层面,在微观孔隙结构与宏观输运性质之间建立了确定性的物理联系。然而,其主要瓶颈在于计算成本极其高昂:对于复杂多相流问题,直接数值模拟通常需要消耗巨大的计算资源与时间,难以满足工业界大规模快速评价的需求^[30-31]。

“所学为所得”:这是出现在人工智能/大数据时代的一种颠覆式技术路线。核心原则是以深度学习为代表的机器学习技术,通过绕过求解复杂的物理过程,用模型直接自主学习和训练获得数据-模型的深层非线性对应关系(从岩心的微结构特征到渗流物性参数)。这是有望解决“所算为所得”技术瓶颈的一条强有力路径。一方面,学者们使用深度卷积神经网络(deep convolutional neural network,即 DCNN)^[32]等模型作为高代理模型(surrogate model, SM),可以实现从三维岩心图像到渗透率等物性参数的秒级预测,计算效率是传统数值模拟的数个数量级^[30,33]。另一方面,为了解决“视场与分辨率”之间的矛盾,以生成对抗网络(generative adversarial networks, GANs)^[34]和扩散模型为代表的深度生成模型既可以利用数量较少的高精度样本来学习大量虚拟数字岩心数据,从而丰富训练数据集^[31],又可以根据多尺度成像数据融合重建大视场、高分辨率多尺度数字岩心,显著提升模型的泛化性能和预测精度^[35]。然而,需要指出的是,当前深度学习模型的泛化能力仍主要局限于训练数据所覆盖的岩性范围。当面对训练集中未包含的复杂地质条件或差异显著的岩性结构时,模型的预测精度往往会出现不同程度的下降。如何通过迁移学习等手段提高模型在跨岩性、跨尺度场景下的鲁棒性,仍是当前研究的重点。

综上所述,对于岩心分析方法,已经从“计算”的时代步入到“认知”的时代,标志着以数据驱动的智能范式正引领着该领域的深刻变革。本文系统性地梳理了人工智能技术在数字岩心分析中的应用现状,旨在深入剖析当前所面临的关键科学问题与技术瓶颈,并对未来的发展方向进行了展望,以期为该领域的后续研究提供有益的参考与启示。

1 “所见为所得”:结构特征描述

1.1 物理表征与结构识别

数字岩心分析技术的核心,首先在于精确重建岩石内部孔隙空间的三维结构^[27]。当前,X射线计算机断层扫描技术(X-ray CT),尤其是微米/纳米CT,已成为应用最广泛的无损三维成像手段^[6]。通过该技术,可以获得直接反映岩心内部孔隙与矿物骨架空间分布的数字图像^[36]。这类孔隙尺度的成像数据,为我们揭示了岩石孔隙空间的拓扑几何形态、矿物组分、连通性等关键微观信息^[27,37]。例如,有研究借助micro-CT与特殊造影剂,成功实现了对煤岩中微米级裂纹系统的可视化^[38]。这些高精度的三维数字图像,构成了后续所有定量分析与数值模拟的几何基础^[6]。除三维CT外,高分辨率的二维成像(如岩石薄片扫描)同样是获取数字岩心数据的有效途径,尤其在处理岩屑等微小样品时更具优势^[39-40]。

1.2 图像处理与分割

从CT等设备获取的原始灰度图像并不能直接用于分析,必须经过一系列步骤处理,才能转化为可供计算的数字化模型。其中,图像分割(image segmentation, IS)^[41]是最为关键的一环。其目标是将图像中代表不同组分(如孔隙、各类矿物)的灰度值清晰地区分开,生成二值或多值的标签图像^[42-43]。分割结果的优劣,直接决定了后续所有物理参数计算的准确性^[44]。尽管基于阈值或分水岭等传统分割算法应用广泛,但它们通常需要研究者依据经验手动设定参数。这种人为介入很容易引入误差,即不同分析人员或参数设置,会从同一张原始图像中得出不同的分割结果,进而影响孔隙度、渗透率等关键参数的可靠性与可重复性^[44]。为了应对这一挑战,研究者们开始将机器学习,特别是卷积神经网络等方法,用于实现自动化、高精度的图像分割,旨在最大程度地减少人为干预,提升结果的客观性与一致性^[39]。

1.3 结构参数提取

在完成图像分割后,便可以从数字化的孔隙结构模型中,定量提取一系列关键的静态几何参数,这些参数是理解岩石宏观物理性质的基础。主要参数包括:

孔隙度:即孔隙体积在岩石总体积中所占的比例,是评价储层性质的基本指标^[40]。

孔喉尺寸分布:该参数描述了岩石中孔隙和连接它们的狭窄通道的尺寸分布规律,它直接控制着流体的渗流能力与毛管压力特性^[43]。

比表面积:单位体积岩石内孔隙的表面积大小,它影响着岩石-流体间的物理化学相互作用。

连通性:用于评价孔隙网络能否构成有效的流动路径,是判断岩石是否具有渗透性的前提。

迂曲度:流体在孔隙介质中流动的实际路径长度与直线距离的比值,它反映了流动通道的曲折程度,是影响渗透率和扩散系数的重要因素。

1.4 “所见为所得”的意义与局限

“所见为所得”的范式,借助先进的成像与图像分析技术,实现了对岩石微观孔隙结构的直接量化表征。它推动岩心分析从依赖经验的传统定性描述,迈入了基于精确三维模型的定量计算时代。通过这种方式获得的各类结构参数,为后续的渗流模拟和物性预测提供了不可或缺的数据基础。

“所见为所得”本身并不直接计算渗透率、相对渗透率这类对油气开发和储层评价至关重要的动态流动参数。正是为了解决这一问题,才催生了以物理驱动的数字模拟为核心的数字岩心技术。

2 “所算为所得”:基于物理模型的数值计算

2.1 核心技术

数字岩心技术是连接岩石微观孔隙结构与宏观渗流特性之间的桥梁,从结构表征到物性计算为基本工作流程,首先通过高分辨率三维成像无损获取岩石岩心孔洞结构,并在此基础上通过数值方法求解流动控制方程计算渗流物理特性^[45]。流动控制方程的基础是 Navier-Stokes 方程^[46],多孔介质内低 Reynolds 数蠕动流可由 Darcy 方程简化描述^[28]。

目前,基于数字岩心图像进行渗流模拟的主要方法分为直接数值模拟方法和简化的孔隙尺度模拟方法。

经典有限体积、有限差分等计算流体力学方法是直接在数字岩心的孔隙空间上进行流体流动模拟的常规手段,可用于计算多孔介质的渗透率等关键物理属性^[20,47]。例如,研究人员可以利用 CFD 对数字岩心模型进行单相流模拟,以生成用于机器学习模型训练的渗透率数据集^[20]。在一项对不同数值解法进行比较的研究中,计算流体力学被作为多种计算引擎之一,用于评估不同数字岩心模型的渗透率。该研究发现,尽管各种解法在处理简单理想化的孔隙几何形状时表现出良好的一致性,但随着孔隙空间复杂性的增加,不同解法计算出的渗透率值差异也随之增大^[47]。

格子 Boltzmann 方法作为一种介观模拟方法,已广泛应用于复杂多孔介质流体模拟^[48-49]。LBM 可以直接在三维像素网格上求解流场,精确设定固-液界面的无流边界条件,计算多孔介质的绝对渗透率等参数^[28,48]。例如,有研究便基于 CT 扫描构建的致密砂岩数字岩心,利用该方法成功模拟了高温高压下的渗透率变化^[50],还有研究人员利用该方法在扫描电镜或 CT 重建的页岩、致密砂岩数字岩心上模拟气体流动,以深入研究其纳米级的输运特性与表观渗透率^[51-52]。LBM 不仅可用于单相流模拟,还可被拓展用来研究孔隙尺度的多相流模型^[48,53],例如有研究就采用 LBM 详细探究了润湿性非均质对油水两相流相对渗透率的影响^[54]。此外,陈家豪和娄钦^[55]采用改进的伪势 LBM 模型,深入分析了接触角滞后性及毛细数对多孔介质内非混相驱替效率的影响,揭示了不同润湿窗口下的流体指进与突破机制。LBM 还可以用来研究非 Newton 流体(如 Bingham 流体)在复杂多孔介质中的流动规律^[56]。针对微观通道内复杂的相界面演化,丁弘毅等^[57]利用相场 LBM 模型模拟了含孔板微通道内的气泡运动,精细捕捉了气泡在受限空间内的变形、撕裂及速度场波动特征,进一步验证了介观模拟方法在处理复杂拓扑界面时的优势,但也侧面反映了高保真模拟对计算资源的巨大需求。在二氧化碳地质封存这类具体应用中,LBM 也可以模拟裂缝性多孔介质内的密度驱动对流等复杂问题^[58]。LBM 方法本质上仍然是一种直接数值模拟方法,计算量大,难以计算大尺寸岩心样品^[59]。

孔隙网络模型则是一种简化的计算方法,把岩石复杂的孔隙空间网络简化为孔隙体与连接两孔隙体喉道的网络^[17],为孔隙体和喉道的简化几何单元指定流体流动准则^[60]。PNM 的生成可直接从 CT 图像上抽取,具有等效的拓扑连接^[61],在计算速度和模拟区域大小方面都要比 LBM 等直接数值模拟方法快得多^[59]。但由于过度简化,往往丢失关键物理机制等,因此,可以采用直接数值模拟方法准确计算 PNM 网络中每个喉

道单元的流体传导系数,并代入原有 PNM 模型中,使整个计算过程在保证计算精度的同时大幅降低计算成本^[62]。

2.2 核心挑战

尽管基于 3D 图像和物理模型,数值计算模型已经成功实现定量计算岩心渗流特征,但由于其计算成本大以及样本尺寸难以具有代表性等问题,阻碍了其在工业中的广泛应用,促使研究人员寻求更加高效的预测模型。

2.2.1 代表性单元体的挑战

数字岩心分析的核心难点源于三维成像技术中视场和分辨率两者之间的矛盾^[63]。为了分辨岩石内部微米甚至纳米级别的孔喉结构,micro-CT 或 FIB-SEM 扫描视场需要足够小,以确保足够高的图像分辨率^[64],但牺牲视场的代价与样品代表性直接挂钩。

储层中的岩石通常是非均质的,其孔隙、矿物组成、物性等具有很大的尺度差异^[65]。为了对包含多尺度裂缝和溶洞等极端非均质特征的储层进行建模,研究者也发展了等效连续介质与嵌入式离散裂缝模型相结合的复杂数值方法,以研究其水力-力学耦合效应^[66]。此外,研究者针对特定岩石类型和流动问题,开展了确定代表性单元体所需临界尺寸的定量研究^[67],并进一步发现多相流动的 REV 尺寸要求通常比单相流更为严苛^[68]。一个分辨率很高但视场有限的数字岩心样可能只是一个宏观储层的切片,并不具有更宏观尺度的裂缝、溶洞或层理等其他结构信息^[18]。同样,对于不同成像系统获取的不同数量级尺度信息进行叠加,如何避免尺度放大过程中失真,是一个未解决的难题^[64]。

2.2.2 高昂的计算成本

直接数值模拟方法以孔隙尺度精确求解流体动力方程为基础,计算量巨大^[69-70]。求解复杂多孔介质流体时空演化的问题是计算量巨大的过程,所需计算资源量随模型精度增加而成倍增加。

处理多相流问题时,由于需要额外追踪相界面、处理毛管力和润湿等复杂物理过程^[71],这一挑战变得尤为严峻;当进一步考虑热流固耦合作用时,其计算的复杂度更是成倍增加^[72]。例如,通过原位 CT 成像来量化水驱过程中的动态润湿性演化,会进一步增加计算的复杂性和成本^[73]。这种巨大的计算开销体现在多个方面。Wang 等^[74]的研究显示,一次包含约 135 万个颗粒的气固反应流 CFD-DEM 模拟,就可能耗费“55 000 到 100 000 个 CPU 小时”。模拟一个仅持续 10 秒物理时长的颗粒冷却过程,也需耗费 27.76 小时的计算时间^[74]。为了降低计算规模,不得不对复杂的孔隙结构进行简化或等效处理,从而造成信息损失(如局部非均质性等)^[75]。

因此,尽管这些高保真模拟对于揭示微观机理至关重要,但其耗时费力的特点严重限制了它们在需要进行高通量筛选与评价的工业场景中应用。

2.3 “所算为所得”的意义与局限

“所算为所得”范式是数字岩心技术发展中的一次关键飞跃。它通过引入孔隙网络模型和直接数值模拟等方法,实现了从精确的数字岩心三维结构出发,定量计算绝对渗透率、相对渗透率等关键渗流物性参数。这一进步将岩心分析依赖经验的、定性的结构描述,提升到了一个遵循物理定律、可进行定量计算的科学新高度。通过求解流体力学控制方程,该范式在微观孔隙几何与宏观流动行为之间建立了确定性的物理桥梁,为理解复杂多孔介质中的渗流机理提供了强有力的计算工具。

正是为了系统性地解决 REV 和计算效率这两大难题,以数据驱动为核心的智能预测范式应运而生。

3 “所学为所得”:数据驱动的智能预测

3.1 核心理念:数据驱动的认知与预测

“所学为所得”的基本思想是不需要显式求解复杂过程,直接通过 AI 模型,通过人工智能学习建立从高维多尺度岩心结构到目标物性特征的回归函数,实现从“所算为所得”到“所学为所得”的跨越式学习^[76-77],直接将所预测渗流物性特征的求解偏微分方程数值问题转化为高维空间模式识别和回归问题,深度学习模型如 CNN 能从 3D 数字岩心图像中自动、快速提取与所预测目标相关的空间结构信息。

针对诸如绝对渗透率等宏观参数预测,已有研究证实,数据驱动模型可以从三维图像输入出发,直接进行高效率、高精度端到端预测。例如:Rabbani 等^[78]建立的 DeePore 工作流,Fu 等^[79]提出的 DDC 计算方法以及 Cawte 和 Bazylak^[80]关于气体扩散层的研究结论,均表明 3D CNN 模型对于渗透率预测具备相当大的潜力,较数值模拟方法快几个数量级。对于更加复杂的多相流问题,此范式同样得到了相当有力的支持。例如,Xie 等^[81]成功利用深度学习模型,对直接岩心图的相对渗透率曲线和相对毛管压力曲线进行了预测,解决了包含润湿、相界面等复杂机理导致的极高非线性问题。此外,该理念已延伸到页岩气储层、天然气水合物沉积物层等非常规、复杂多孔介质中,具备广阔的应用前景^[1,77]。

数据驱动的智能预测模式,它不仅是一个传统的计算工具,更是一个能够生成新知识和预测结果的智能模型。如表 1 所示,用“学习”取代了“计算”,给出了新的范式,已成为量化岩心微观结构特征与宏观渗流特性之间的关系的手段,为系统性地解决“所算为所得”时代的技术瓶颈奠定了基础。

表 1 计算驱动和数据驱动范式的比较

Table 1 Comparison of computation-driven and data-driven paradigms

dimension	computation-driven	data-driven
concept & technology	based on solving physical equations	learning structure-attribute relationship
core technology	LBM, PNM	CNN, GNN, PINN
key benefit	the physical mechanism is clear	high computational efficiency
bottleneck	computationally expensive, REV challenges	dependent on high quality data, weak interpretability
nature of the problem	numerical computation problems	pattern recognition/regression problems

3.2 AI 如何突破“所算为所得”范式瓶颈


对于“所算为所得”范式的数字成像“视场与分辨率”的矛盾和直接数值模拟计算量过大^[82]两大问题的挑战,以深度学习为代表的人工智能技术,为解决尺度矛盾提供了两条途径:其一是重建并增强生成模型,其二是采用代理模型解决计算耗时问题^[76]。

3.2.1 应对“视场与分辨率矛盾”:从生成到增强


为了解决成像的物理限制瓶颈,学术界此前已利用多尺度成像数据融合等传统算法开展了大量研究。在此基础上,人工智能技术为缓解这一矛盾提供了新的高效路径。相比于传统的图像插值或线性融合算法,基于深度学习的方法通过学习低分辨率与高分辨率图像之间的复杂非线性映射,致力于在保持大视场的同时恢复更多的纹理细节,重建一个既有代表性又包含微观结构的数字岩心模型。

一方面,用生成的岩心扩充高质量的样本库。为了采集足够多的高分辨率 3D 数字岩心,研究人员需要花费大量的时间去获取,通过生成的模型去学习已采集岩心的内部统计学分布特征,来生成大量具有相同统计学特征的虚拟数字岩心。GAN 是最早的生成模型方法之一,Mosser 等^[83]首先证实了 GAN 能够学习并复制岩心结构的关键特征——孔隙度、两点相关函数和 Euler 示性数,生成与原始岩心具有相同形状和单相渗透率的 3D 数字岩心,并被后续研究证明是一种强大的重建微观结构的方法^[77,84-85]。尽管 GAN 在数字岩心重建中表现出色,但其在应用中也面临挑战:生成器可能仅学习到训练数据中的部分模式,导致生成的孔隙结构多样性不足,难以完全覆盖真实储层的非均质性特征。针对这一局限,近年来以扩散模型为代表的新型生成式方法开始在岩心图像生成和超分辨率重建中崭露头角,它们在生成图像的质量、稳定性和多样性方面展现出超越传统 GAN 的潜力,为解决视场与分辨率矛盾提供了新的技术手段。这些生成模型通过学习训练数据中的概率分布,能够生成具有统计一致性的虚拟岩心,有效扩充数据集。例如,基于 GAN 的方法已被用于随机地质建模,并结合代理模型来整合静态和动态数据,实现高效的条件模拟^[86]。

另一方面,采用超分辨率重建,提升图像品质。这类方法的目标是从易获取的大视场图像和低分辨率图像中智能地重建高分辨率的孔隙结构细节,如图 3 所示。换句话说,在维持视场的同时以计算的方式“放大”图像的分辨率^[82]。例如,Ugolkov 等^[10]构建基于三维深度卷积 Wasserstein GAN 的超分辨率模型,将微米 CT 图像分辨率提升 8 倍。该模型提高了图像视觉质量以及后续矿物组分和孔隙空间分割的精度。这类方法通过学习低分辨率图像和高分辨率图像之间的复杂映射,缓解了“视场与分辨率”矛盾,为构建跨尺度数字岩心模型奠定了基础^[1,76]。



(a) 利用 GAN 生成三维数字核心
(a) The 3D digital core generation using GAN



(b) 超分辨率重建^[6]
(b) The super-resolution reconstruction^[6]

图3 克服成像限制的人工智能策略

Fig. 3 Artificial intelligence strategies to overcome imaging limitations

3.2.2 应对“计算耗时”瓶颈:构建智能代理模型

针对传统数值模拟方法计算速度慢的问题,一些学者通过深度学习的方法训练一个代理模型,从迭代运算中解放岩心结构及渗流属性预测,达到快速预测的目的^[87]。

一种是常用方法:端到端预测。普遍来说,CNNs 特别是编码器-解码器结构的 U-Net,将三维数字岩心图像直接作为输入,将三维渗流(渗透率、压力场、饱和度场)的复杂非线性关联模型直接作为从图像到图像的回归问题^[88]。例如,Mo 等^[89]采用深度卷积编码器-解码器网络,直接对高维随机渗流率场图像输入进行预测,得到动态多相流过程的压力和饱和度的时空演化。近期,更有研究结合了卷积长短期记忆网络与 Fourier 神经算子,提出混合模型来提升三维油水两相流的长期预测精度与泛化能力^[90],其速度远快于传统模拟器。再比如,Zhu 和 Zabaras^[88]将编码器-解码器网络嵌入到 Bayes 框架中,Bayes 框架可以提供快速的预测结果,且会量化预测结果的不确定性,对风险和决策评估具有重要意义。这些数据驱动的方法运算速度快,并且预测精度高达 95%^[91]以上。

这些数据驱动的方法在与训练数据同分布的测试集上往往能达到 95%以上的预测精度。但由于缺乏物理机理约束,当面对训练集中未包含的岩性或复杂工况时,纯数据驱动模型的泛化能力会显著下降^[92]。物理机理融合方法应运而生,物理信息神经网络(physics-informed neural networks, PINNs)便是很好的示例^[93]。PINNs 的核心思想是将物理控制方程引入训练过程。具体而言,其通过构造一个复合损失函数来实现:

$$f_{\text{Loss}} = f_{\text{Loss}_{\text{data}}} + \lambda f_{\text{Loss}_{\text{PDE}}},$$

其中, $f_{\text{Loss}_{\text{data}}}$ 用于拟合观测数据, $f_{\text{Loss}_{\text{PDE}}}$ 是将控制方程(如 Navier-Stokes 方程或 Darcy 定律)的残差作为正则化项,从而迫使神经网络的输出在逼近数据的同时,严格符合物理守恒律。为了进一步提升 AI 求解广域微分方程的精度与收敛速度,颜景越和苏欢^[94]提出了一种基于残差的 Fourier 神经网络,利用三角函数的周期性特征有效解决了传统 PINNs 在求解椭圆型微分方程时易陷入局部最优的问题,为构建高精度的流体力学代理模型提供了新的算法思路。Tartakovsky 等^[92]仅利用稀疏测量数据反演了非均质介质的水力传导率。He 等^[95]也用此方法实现了地下水流输运问题中参数和状态场的联合求解。PINNs 的框架也在不断拓宽,例如耦合真值数据的 MPINNs^[96]、能量不确定的对抗 PINNs^[97]等。最近,Kenzhebek 等^[98]的工作再次展示了此方法

的潜力,对于含有激波前后的(shock front)相流问题场景,通过引入人工扩散项等方法,提高模型对激波突变前后饱和度的敏感性,这种将数据和物理过程紧密联系的范式使得代理模型的预测能力得到很大提升。

3.3 渗流物理特性的智能预测

基于第 3.2 小节所述的智能代理模型架构,研究者已在从微观孔隙结构到宏观渗流物性的全链条预测中取得了显著进展。根据预测目标的不同,本小节将渗流物理特性的智能预测分为以下几个方面进行阐述:首先是储层的核心静态参数,即结构物理特性,如孔隙度和绝对渗透率;其次是描述流体在孔隙介质中运动规律的动态渗流特性,包括单相流与多相流过程;最后,还将探讨电学、弹性等其他重要物理性质的智能预测方法,如表 2 所示。

表 2 预测数字岩石渗流及其他物性的代表性人工智能模型
Table 2 Representative AI models for predicting numerical rock seepage and other physical properties

predictive attribute	AI model	core contribution
porosity, permeability	CNN, 3D-EmaSepNet,	end-to-end prediction to greatly improve computational efficiency;
	PINN-CNN	fusion of physical information (e.g., Darcy's law) to improve small-sample generalization
single-phase flow field	3D U-Net, PINN	an alternative to traditional simulations (e.g., LBM) for fast prediction of stable flow fields; embedding hydrodynamic equations (e.g., N-S equations) into the model to enhance physical realism
relative permeability, capillary pressure	3D-CNN, GNN, PINN	enabling end-to-end prediction from core images to key parameters of multiphase flow; GNN naturally characterizing complex networks such as cracks; physical constraints enhancing characterization of strongly non-linear features such as moving leading edges
elasticity	U-Net+CNN	segmentation results of U-Net used as physical constraints to improve the prediction accuracy of elastic parameters such as acoustic velocity V_p and V_s

3.3.1 结构物理特性预测

结构物理特性尤其是孔隙度等指标是储层物性最重要的参数,通常由实验室测量或直接数值模拟获得,但这两种方法耗时耗力。经研究,许多机器学习模型已成功应用于渗透率等复杂物性参数的快速预测。早期的工作证明 CNN 可以直接从 2D 和 3D 数字岩心图像预测渗透率,其计算速度比常规的流体动力学计算快几个数量级^[36];在模型架构上从经典的 CNN、DNN、梯度提升决策树 (gradient boosting decision tree, GB-DT)^[36],到复杂的 3D U-Net 架构和轻量级深度卷积网络^[99],都是将图像作为输入,直接输出物性预测值的高效智能代理模型。例如,Xiang 等^[99]提出的 3D-EmaSepNet 通过三维深度可分离卷积、多尺度注意力机制,在极大节约算力消耗的同时实现了对砂岩、碳酸盐岩的渗透率准确预测。

为了提高模型预测精度和物理合理性,一部分学者从特征工程和模型设计两方面进行了改善。在特征工程方面,Jamshidi 等将获取的具有物理意义的结构参数(如孔隙度、迂曲度、分形维数、平均孔喉直径、配位数等)作为机器学习模型的输入特征可以提高模型预测的性能^[100-101]。周济民等^[102]的研究也表明,在数据挖掘方法中综合考虑物理经验模型的约束,能够显著改善页岩油气开发指标的预测精度,这种将工程经验与神经网络相结合的思路对于提升数字岩心物性预测的可解释性具有重要参考价值。Wang 等^[103]通过分析发现水力半径是影响砂岩渗透率预测性能的关键结构特征参数。

数据稀缺是阻碍深度学习模型发展的重要瓶颈。为了解决高质量标注样本的稀缺问题,研究者们采用了数据增强和迁移学习等方法。在数据增强方面,研究者通过随机生成算法^[20]或 GAN、扩散模型等更高级的方法,生成大量具有统计相似性的合成数字岩心样品以扩充训练数据集^[31]。迁移学习是另一种有效途径,它将在通用数据集上预训练的模型迁移至特定的岩心物性预测任务,从而在少样本标注数据上获得较好的预测效果^[31,104]。

然而,上述方法仍需一定量的标注数据或依赖源域与目标域的分布一致性。为了进一步挖掘海量无标注数据的价值,自监督学习 (self-supervised learning, SSL) 与小样本学习 (few-shot learning, FSL) 正成为新的研究热点。自监督学习能够通过“前置任务”(如对岩心图像进行掩码重建或基于多视角切片的对比学习)迫使

模型在无物理参数标注的情况下,自主学习孔隙空间的拓扑结构与高阶特征表示,显著提升了模型在下游任务中的特征提取效率.与此同时,针对新开发区块岩心样本极少的困境,基于元学习的小样本学习策略被提出.该方法通过“学习如何学习”,从多个不同类型的历史储层数据中提取可迁移的“元知识”或构建度量空间,使得模型仅需依托目标储层的极少量支撑样本,即可快速收敛并实现精准的生产动态预测^[105].同时,Liu等^[106]引入PI3NN-CNN框架来解决模型的不确定性风险问题,该模型不仅提供准确的渗透率点估计,同时可以提供预测的不确定性估计,还可以准确地识别 out-of-distribution 样本,解决了过度自信地预测未知岩性的问题.

3.3.2 单相渗流物理特性预测

随着研究从宏观的静态物性过渡至微观上的渗流过程,智能预测的物理问题也更加复杂.以单相流系统作为原型,其本质是流体在孔隙中的稳定流态,而当系统为两相或多相流时,会引入润湿/毛管作用、相对界面等复杂物理机制,对预测模型以及物理统一性均提出了更高的要求.

单相流体系预测:在单相流方向,基于卷积神经网络的深度学习模型,已逐步替代格子 Boltzmann 方法等耗时模拟方法,旨在通过最小化建立代理模型,以规避迭代计算,从数字岩心 3D 图像中学习孔隙图像和稳定流场之间的映射关系.在应用方向^[24,107]上,有研究表明,基于 U-Net 的 3D CNN 模型能够提取孔隙空间几何结构,几秒内即可预测出速度场和高精度的压力场^[24,108].例如,Santos 等提出的 PoreFlow-Net 仅基于简单的几何信息,就能对真实砂岩、碳酸盐岩等多种岩石样本做出高精度快速流场预测.为了提高模型的物理真实性和泛化性,还有部分工作将物理约束也引入到了模型之中,如 Wang 等^[107]将不可压缩 Navier-Stokes 方程的有限差分解嵌入卷积层中,为网络提供了流体力学的先验信息.类似地,Ko 等^[109]通过在损失函数中强制执行质量守恒,确保模型在训练数据以外的真实网状泡沫材料上也预测了真实的三维速度场.此外,注意力模块^[110]和粗化流场信息^[111]等被用来增强模型处理非均匀孔隙结构中复杂流行为的能力,从而推动单相流代理模型更快捷、更精准、更普遍的发展.

3.3.3 多相渗流物理特性预测

多相流体系预测:相对于单相流,多相流引入了润湿性、毛管压力、动态演化的相-相界面等复杂的物理过程,共同控制着多相流体在孔隙介质中的微观流型和宏观分布,例如气-水界面的演化会通过卡断和绕流等形式破坏气体流动连续性,是造成水相圈闭损害的直接微观原因^[112].多相流智能预测是智能技术的又一次应用和挑战,更是对模型复杂物理过程捕捉与表达能力的检验.

早期的工作则是使用人工神经网络 (artificial neural network, ANN) 等机器学习模型直接通过孔隙网络模型或实验数据来预测多相流性质,例如 Liu 等^[113]利用 ANN 训练非均匀润湿毛管束内的毛管压力和相对渗透率.这类方法在特定条件下能取得不错的效果,但需要先学习特征参数,无法直接从岩心结构图像出发进行预测.

从三维数字岩心图像上直接进行“端到端”的预测是近年来的趋势,目的是预测油、水多相流在孔隙中的微观场,进而反演表征储层开发趋势的关键参数——相对渗透率和毛细压力曲线.

在这一方向,CNN 展现出强大的能力,如图 4 所示.研究人员借助 CNN 网络直接学习复杂的非线性函数,如岩心三维灰度图像、多相流动态参数等,省去了图像分割、孔隙网获取等过程^[114].Telvari 等^[114]提出了一种基于 3D CNN 的网络模型,仅依靠灰度图像和流体物性(接触角和界面张力)便能够预测相对渗透率和毛管压力,且计算速度比传统的孔隙网络建模快几个数量级.Xie 等^[81,115]为了提高模型的物理感知能力和在不同尺寸岩心中的应用能力,提出了一种混合深度学习模型,输入了润湿、界面张力等物理参数,并且加入空间金字塔池化结构,最终实现了不同尺寸的数字岩心相对渗透率曲线预测且准确率较高.

针对裂缝性介质等非正则网格结构,Jiang^[116]使用 GNN 构建嵌入式离散裂缝-基质模型的代理,能够准确预测具有复杂压力和饱和度动态的裂缝网络系统,同时对训练集中未见过的裂缝几何形状做出泛化预测.Kim 等^[117]提出了 GNPNM,将孔隙网络编码为图,图卷积编码器与 ML 层感知机共同预测准静态驱替中的流体相.

此外,物理约束神经网络也被应用于多相流模拟,使预测结果严格满足物理规律.Ji 等^[118]将描述非 Dar-

cy 流和润湿性的五个物理模型集成到神经网络中,用于计算致密砂岩中毛管压力和相对渗透率。Hanna 等^[119]将计算控制方程的残差,尤其是控制方程弱形式的残差,加入损失函数,有效提高了模型对移动前缘等强离散性特征的准确表征。这些物理驱动的方法提高了模型的预测精度和在小样本、复杂情形下的鲁棒性、可解释性。




图 4 人工智能模型对多孔介质的不同数据表示

Fig. 4 Different data representative of porous media by AI models

3.3.4 其他物理特性预测

除了流体输运性质外,电学性质和弹性性质在地球物理勘探和储层表征中也很重要,它们在过去常常由经典的物理模式或经验模式来描述,例如通过 Archie 公式将孔隙度、含水饱和度与地层电阻率相联系,通过 Gassmann 方程将饱和流体的弹性模量与地层弹性模量相联系。

人工智能方法为这种从岩心微观结构性性质直接预测上述宏观性质提供了一个可行的途径。研究者直接通过深度学习,尤其是 CNN 模型,从数字岩心三维或者二维图像中学习孔隙几何、分布和连通性等特征与电阻率因子、声波速度等参数之间的映射关系。例如,Cui 等^[120]提出了将 U-Net 与 CNN 结合的 CUCNN 模型,先用 U-Net 分割岩心图像为孔隙和基质两个部分,然后将分割的图像视为对后续 CNN 模型来说具有地球物理约束的数据更有利于 CNN 从图像中提取与弹性参数相关的大、局部特征,并最终得到了较普通 CNN (R^2 达到 0.84) 对 V_p 和 V_s 预测更精准的结果。Karimpouli 等^[121]的研究也证实了 CNN 从岩石图像中估计 P 波和 S 波速度的出色性能,以及使用随机模拟方法对数据进行数据增强的必要性。

AI 模型也被证实可以从更大地球物理尺度来预测:从电磁感应 (electromagnetic induction, EMI) 数据反演地面下电导率^[122-123],或者解决一个复杂的逆问题,例如电阻抗分析成像 (electrical impedance tomography, EIT),其虽然不直接面向岩心尺度,但具备一个共同思路:通过训练神经网络来测量信号到物性参数。Spichak 等^[124]的工作甚至将神经网络作为一个地震地温计,从井孔尺度的地震速度数据中预测了地下温度,且预测结果与实测结果较为一致,平均相对误差为 4.7%~4.8%。这些进展均表明基于数据的人工智能模型,有望在预测岩石的物理性质上实现对岩石物理模型无法预测的复杂结构的微观响应的宏观预测,为更准确的“结构-属性”预测提供了有力的帮助。

3.4 “所学为所得”的意义与局限

“所学为所得”范式以深度学习为核心,为数字岩心技术的发展提供了突破传统瓶颈的革命性路径。它成功地应对了前两代技术的核心挑战:一方面,通过构建以 CNN 为代表的高效代理模型,将物性预测从求解复杂物理方程的耗时计算转变为高效的模式识别与回归问题,预测速度提升了数个数量级,解决了计算成本高昂的瓶颈;另一方面,针对“视场与分辨率”的矛盾,利用生成对抗网络扩充高质量样本库,并通过超分辨率技术 (super-resolution, SR) 提升图像品质,有效缓解了代表性单元体的难题。

尽管该范式取得了显著进展,但目前仍处于发展初期,面临着关键挑战。首先,模型的性能高度依赖大规

模、高质量的标注数据集,而这类数据的获取成本高昂,是阻碍模型开发与验证的重要瓶颈.其次,当前模型的泛化能力与鲁棒性仍有待提升,在面对训练集中未见过的岩性或复杂地质条件时,预测精度可能下降.

此外,深度学习模型的计算开销与资源消耗问题同样不容忽视.尽管模型在推理阶段具备实时预测的优势,但其离线训练过程往往伴随着巨大的算力需求与时间成本^[125].特别是针对高分辨率的三维数字岩心数据,随着输入尺度的增加,深度卷积神经网络的参数量与显存占用呈指数级增长,极易触及硬件瓶颈.为解决这一问题,基于 GPU 集群的并行计算策略已成为主流解决方案.同时,如何在维持预测精度的基础上,利用模型剪枝、混合精度训练及轻量化网络架构来优化计算效率,是推动该技术在工业场景实际应用的关键难点^[126].

最后,深度学习模型的“黑箱”特性导致其物理可解释性较弱,严重制约了工程技术人员对预测结果的信任度.为了解决这一信任危机,建立面向数字岩心的可解释人工智能(explainable AI,XAI)框架已成为当前研究的重要方向^[127].具体而言,研究人员正尝试从“可视化验证”与“量化归因”两个维度打开黑箱:一方面,引入注意力机制^[128]或基于梯度的类激活映射技术生成热力图,直观展示模型在进行渗透率等物性预测时所关注的特定孔隙区域以此验证模型是否捕捉到了正确的物理特征而非背景噪声;另一方面,利用全局敏感性分析等方法,量化孔隙度、迂曲度等不同微观结构参数对宏观预测结果的边际贡献权重^[129].这些方法不仅揭示了深度神经网络的内部决策逻辑,更使得工程人员能够基于流体力学原理对模型行为进行合理性评估,从而显著增强了 AI 预测结果在工业应用中的可信度.

4 挑战与展望

尽管基于深度学习的智能岩心技术在渗流物理特征预测领域取得了显著成效,但是从理论研究向大规模应用还有相当长的路要走,并且仍有新的发展机会,如表 3 所示.

表 3 深度学习在数字岩石物理中应用的主要挑战

Table 3 Key challenges in the application of deep learning to digital petrophysics

challenge category	specific challenge description	impact on application
data level	scarce and costly high-quality labeled datasets	limited training and validation of complex models
	insufficient generalization capability and reduced prediction accuracy for unknown lithologies	hindered industrial application of models in realistic and diverse geological conditions
model level		
interpretability	'black box' characteristics, opaque physical logic	reduced engineers' confidence in prediction results and little contribution to mechanism discovery

4.1 当前面临的挑战

首先,数据依赖和高质量标注数据集的缺乏.深度学习模型的性能与大型、高质量数据集紧密相关,获取高精度三维数字岩心图像并对其流场或物性参数完成物理模拟标注本身是一项耗时耗力且高昂的工作^[27],尤其在开展宏观物性预测时^[1],制约了大型复杂模型对真实储层样本的学习.尽管当前已有研究致力于提升小数据集模型的小数据效率^[130],但建立全面涵盖多种岩性和流相的公开基准数据集仍有待发展.

其次,模型的泛化性和鲁棒性有待提升.现有的模型大多针对特定岩性或孔隙结构训练,面对更多样的复杂地质条件的储层,如低渗透储层非均质复杂^[131]、成岩改造的多孔介质时,模型的预测精度和鲁棒性便会下降.模型的泛化性是学习某种特定岩性的样本并将其应用到未知样本上的一种能力,是油气田勘探开发领域应用中至关重要的泛化推广能力^[132].面对含噪数据时模型如何保持鲁棒性也是一个值得关注的问题.

最后,深度学习黑盒的特性导致其物理可解释性差.以 CNN 为代表的深度学习模型,其预测结果为图像到物性的映射,预测过程黑盒化,难以揭示预测结果的物理机制,不利于研究者对复杂渗流机理的整体认知,油藏工程技术人员对其预测结果也不是很满意,因此提高模型的可解释性是 AI 落地应用的关键^[132].

4.2 未来展望

为了应对上述挑战,未来的研究应聚焦于以下几个前沿方向:

第一,进一步准确地将物理约束纳入人工智能模型.将流体力学的控制方程作为先验知识嵌入到神经网络训练过程是提高模型可靠性的重要途径.一是基于“软约束”的物理信息神经网络架构.其核心实现机制是

利用自动微分技术,直接在神经网络的反向传播中计算流场变量对时空的导数.研究者通过在流场区域内随机采样大量配点,将 Navier-Stokes 方程、Darcy 定律以及边界条件和初始条件的残差项构建为复合损失函数.这种方式迫使网络在优化过程中寻找既拟合观测数据又满足物理守恒律的解,从而在无网格的情况下实现对物理场的逼近.二是基于“硬约束”的网络架构设计.不同于软约束将物理规律作为惩罚项,硬约束旨在通过设计特殊的网络拓扑结构,强制模型输出在数学上严格满足物理条件.例如,在处理不可压缩流体时,通过预测流函数或矢量势而非直接预测速度场,并利用 Curl 算子构建网络输出层,从而从数学构造上保证了速度场严格满足质量守恒方程.这种物理机制与深度学习的有机结合,不仅保障了预测结果的物理一致性,更使得模型在数据稀缺的情况下也能通过物理方程的约束得出可靠的预测结果^[133-134],显著提升模型的泛化能力^[90].

第二,多尺度多模态数据融合.未来的研究必然要跳出单一尺度分析的限制,发展融合岩石物理所需的岩心 CT 图像、测井曲线、地震资料等多源多模态数据信息的多尺度预测模型,训练不同尺度数据之间的内在对应关系,旨在克服岩石物理属性升尺度和代表性单元体选择等关键难题,实现从微观孔隙结构尺度特征到宏观储层特性预测的突破^[1].

第三,向储层“数字孪生”迈进.如图 5 所示,终极目标是结合多场模型、实时监测数据、高效智能代理模型,形成储层多尺度的“数字孪生”体,该系统不仅是对地下实体的静态虚拟映射,更具备在时间维度上推演流体动力学行为的能力.在此框架下,针对油气藏开发中长周期的生产动态优化与储层管理需求,单纯的空间映射已不足以应对.研究重心将向基于时间序列的深度学习模型倾斜,特别是循环神经网络及其变体——长短期记忆网络和门控循环单元,以及近期兴起的 Transformer 架构.这类模型具备独特的记忆机制,能够有效捕捉压力、饱和度及产量等生产数据随时间演化的非线性历史依赖关系.相较于传统数值模拟器,时序 AI 模型能够以秒级速度完成针对数十年开发周期的快速历史拟合与产量预测,从而支持 CCUS、地下储气库及氢能等地下储能系统的长期安全性监测,或复杂油气藏全生命周期的实时闭环优化,为智慧油田的自动决策提供核心动力.




图 5 未来愿景:多尺度的油田数字孪生体,由物理信息人工智能和多模态数据融合赋能

Fig. 5 A vision for the future: a multi-scale oilfield digital twin, empowered by physics-informed artificial intelligence and multimodal data fusion

5 结 论

本文系统性地回顾了数字岩心技术从“所见为所得”的结构表征、“所算为所得”的直接数值模拟算法,到“所学为所得”的智能预测的范式演进历程.并重点归纳了以深度学习为代表的“所学为所得”智能数字岩心渗流物性参数预测方面的突破性进展.以直接数值模拟法为代表的“所算为所得”虽以定量计算为抓手,但

其高昂的计算成本和成像“视场-分辨率”权衡造成的代表性单元体问题是其推广使用的重要制约因素。

数据驱动下的“所学为所得”智能预测模式具有革命性的潜力:一方面,它通过构建高效的代理模型(包括各式各样的 CNN 和 U-Net)和物理信息神经网络将渗流预测效率提高数个数量级,超越了传统数值模拟的“时间成本”,并通过生成式模型、超分辨率等方式为解决“视场-分辨率”的冲突和提高样本的统计代表性问题提供新的思路;另一方面,它已经实现了从孔隙、渗透率等宏观静态物性,到单相流场以及以润湿和毛管压力、相对渗透率为关键输出的两相过程的高效、可靠预测,开启了数字岩石物理研究的新时代。

尽管“所学为所得”研究范式已取得显著进展,但仍面临若干挑战,主要包括高质量标注数据集的稀缺性、模型泛化能力与鲁棒性不足,以及物理可解释性较差等问题。为应对这些挑战,未来的研究应着力于以下几个方面:首先,进一步将物理守恒定律等先验知识与人工智能深度准确融合,提升模型的预测可靠性与物理推演能力;其次,推动多源异构数据的融合,例如通过有效整合计算机断层扫描图像、测井曲线及地震数据等多尺度信息,旨在克服岩石物理属性升尺度和代表性单元体选择等关键难题,实现从微观孔隙结构尺度特征到宏观储层特性预测的突破;最后,促进实时数据流与高效智能模型的结合,通过构建智慧油田及储层数字孪生系统,为地下资源的高效、智能开发与利用提供决策支持。

参考文献(References):

- [1] Wu P, Dong Z, Liu S, et al. Microstructure and physical properties of hydrate-bearing sediment: digital core and deep learning application[J]. *Fuel*, 2026, **404**: 136283.
- [2] Fan W, Yu H, He S, et al. Micro-scale two-phase flow experiments and residual oil distribution in tight sandstone[J]. *Natural Resources Research*, 2025, **34**(6): 3179-3192.
- [3] Bera A, Shukla B, Jogani D. A perspective review of applications of the computed tomography (CT) scan imaging technique for microscopic reservoir rock characterization[J]. *Deep Underground Science and Engineering*, 2026, **5**(1): 4-27.
- [4] Andrä H, Combaret N, Dvorkin J, et al. Digital rock physics benchmarks, part I: imaging and segmentation[J]. *Computers & Geosciences*, 2013, **50**: 25-32.
- [5] Cnudde V, Boone M N. High-resolution X-ray computed tomography in geosciences: a review of the current technology and applications[J]. *Earth-Science Reviews*, 2013, **123**: 1-17.
- [6] Ying D W, Blunt M J, Armstrong R T, et al. Deep learning in pore scale imaging and modeling[J]. *Earth-Science Reviews*, 2021, **215**: 103555.
- [7] Pu Z, Tian Y, Fu J, et al. Stress-sensitive porosity and permeability in carbonate rocks for underground hydrogen storage: a digital rock simulation study[J]. *International Journal of Coal Science & Technology*, 2025, **12**: 55.
- [8] Su X, Han D, Wu F, et al. Evaluation of sealing and permeability reduction during coal seam grouting based on computed tomography imaging technique[J]. *Gas Science and Engineering*, 2025, **143**: 205736.
- [9] Ma S, Liu J, Wang Z, et al. An improved method for pore size distribution measurement of porous geomaterials based on microscopic images[J]. *Computers & Geosciences*, 2025, **205**: 106017.
- [10] Ugolkov E, He X, Kwak H, et al. Super-resolution of 3D micro-CT images using generative adversarial networks: enhancing resolution and segmentation accuracy[J]. *Computers & Geosciences*, 2025, **205**: 106018.
- [11] Li P, Song Y, Jiang J, et al. Pore-scale simulation of oil-water flow in shale media after fracture hits: an integrated approach using U-Net and lattice Boltzmann method[J]. *Fuel*, 2025, **402**: 136038.
- [12] Yu H, Xu H, Fan J, et al. Transport of shale gas in microporous/nanoporous media: molecular to pore-scale simulations[J]. *Energy & Fuels*, 2021, **35**(2): 911-943.
- [13] 龚文波, 陈志强, 郑江韬, 等. 页岩油孔隙微纳渗流的格子 Boltzmann 方法模拟[J]. 力学学报, 2025, **57**(12): 2802-2813. (Gong Wenbo, Chen Zhiqiang, Zheng Jiangtao, et al. Pore-scale simulation of shale oil flow in nanoporous media using lattice Boltzmann method[J]. *Chinese Journal of Theoretical and Applied Mechanics*, 2025, **57**(12): 2802-2813. (in Chinese))
- [14] Moghadasi R, Foroughi S, Goodarzi S, et al. Trapping and remobilization during geological CO₂ storage: a

- pore-scale imaging and modeling study[J]. *Advances in Water Resources*, 2025, **205**: 105092.
- [15] Wang Q, Wang H, Wang X, et al. Numerical simulation study on microseepage and displacement mechanism of coal based on digital core technology[J]. *Physics of Fluids*, 2025, **37**(9): 096610.
- [16] Hashemi L, Blunt M, Hajibeygi H. Pore-scale modelling and sensitivity analyses of hydrogen-brine multiphase flow in geological porous media[J]. *Scientific Reports*, 2021, **11**: 8348.
- [17] Blunt M J, Jackson M D, Piri M, et al. Detailed physics, predictive capabilities and macroscopic consequences for pore-network models of multiphase flow[J]. *Advances in Water Resources*, 2002, **25**(8/9/10/11/12): 1069-1089.
- [18] Chen L, He A, Zhao J, et al. Pore-scale modeling of complex transport phenomena in porous media[J]. *Progress in Energy and Combustion Science*, 2022, **88**: 100968.
- [19] Joeekar-Niasar V, Hassanizadeh S M. Analysis of fundamentals of two-phase flow in porous media using dynamic pore-network models: a review[J]. *Critical Reviews in Environmental Science and Technology*, 2012, **42**(18): 1895-1976.
- [20] Tian J, Qi C, Sun Y, et al. Permeability prediction of porous media using a combination of computational fluid dynamics and hybrid machine learning methods[J]. *Engineering With Computers*, 2021, **37**(4): 3455-3471.
- [21] Blunt M J. Flow in porous media: pore-network models and multiphase flow[J]. *Current Opinion in Colloid & Interface Science*, 2001, **6**(3): 197-207.
- [22] Chen S, Doolen G D. Lattice Boltzmann method for fluid flows[J]. *Annual Review of Fluid Mechanics*, 1998, **30**: 329-364.
- [23] Alqahtani N, Alzubaidi F, Armstrong R T, et al. Machine learning for predicting properties of porous media from 2D X-ray images[J]. *Journal of Petroleum Science and Engineering*, 2020, **184**: 106514.
- [24] Santos J E, Xu D, Jo H, et al. PoreFlow-Net: a 3D convolutional neural network to predict fluid flow through porous media[J]. *Advances in Water Resources*, 2020, **138**: 103539.
- [25] 刘合, 任义丽, 李欣, 等. 岩心智能识别技术内涵与展望[J]. 石油学报, 2024, **45**(8): 1296-1308. (Liu He, Ren Yili, Li Xin, et al. The essence and prospects of intelligent core identification technology[J]. *Acta Petrolei Sinica*, 2024, **45**(8): 1296-1308. (in Chinese))
- [26] Iwai H, Shikazono N, Matsui T, et al. Quantification of SOFC anode microstructure based on dual beam FIB-SEM technique[J]. *Journal of Power Sources*, 2010, **195**(4): 955-961.
- [27] Lozano F A, Juliaio-Lemus T, Pérez E R, et al. Review of microscopic techniques for digital rock models[J]. *Boletín de Geología*, 2022, **44**(1): 161-171.
- [28] Mostaghimi P, Blunt M J, Bijeljic B. Computations of absolute permeability on micro-CT images[J]. *Mathematical Geosciences*, 2013, **45**(1): 103-125.
- [29] Kang Q, Li K Q, Fu J L, et al. Hybrid LBM and machine learning algorithms for permeability prediction of porous media: a comparative study[J]. *Computers and Geotechnics*, 2024, **168**: 106163.
- [30] Wu J, Yin X, Xiao H. Seeing permeability from images: fast prediction with convolutional neural networks[J]. *Science Bulletin*, 2018, **63**(18): 1215-1222.
- [31] Kazemi A, Esmaeili M. Enhancing permeability prediction from digital rock images using generative AI and transfer learning[J]. *Gas Science and Engineering*, 2025, **144**: 205751.
- [32] Dong C, Loy C C, He K, et al. Image super-resolution using deep convolutional networks[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2016, **38**(2): 295-307.
- [33] Xie H, Jiang P, Xu R. A deep learning-based hybrid-coupled multiscale modeling framework for real-time flow field prediction in porous media[J]. *Physics of Fluids*, 2025, **37**(8): 083143.
- [34] Goodfellow I, Pouget-Abadie J, Mirza M, et al. Generative adversarial networks[J]. *Communications of the ACM*, 2020, **63**(11): 139-144.
- [35] Liu M, Mukerji T. Multiscale fusion of digital rock images based on deep generative adversarial networks[J]. *Geophysical Research Letters*, 2022, **49**(9). DOI: 10.1029/2022GL098342.
- [36] Sudakov O, Burnaev E, Koroteev D. Driving digital rock towards machine learning: predicting permeability

- with gradient boosting and deep neural networks[J]. *Computers & Geosciences*, 2019, **127**: 91-98.
- [37] Lavrukhin E V, Gerke K M, Romanenko K A, et al. Assessing the fidelity of neural network-based segmentation of soil XCT images based on pore-scale modelling of saturated flow properties[J]. *Soil and Tillage Research*, 2021, **209**: 104942.
- [38] Yan T, Xu X, Liu J, et al. Data-driven predictive model of coal permeability based on microscopic fracture structure characterization[J]. *Journal of Rock Mechanics and Geotechnical Engineering*, 2025, **17**(7): 4476-4489.
- [39] Saxena N, Day-Stirrat R J, Hows A, et al. Application of deep learning for semantic segmentation of sandstone thin sections[J]. *Computers & Geosciences*, 2021, **152**: 104778.
- [40] Caja M A, Castillo J N, Santos C A, et al. Digital rock physics in cuttings using high-resolution thin section scan images[J]. *Minerals*, 2023, **13**(9): 1140.
- [41] Chen L C, Papandreou G, Kokkinos I, et al. Deeplab: semantic image segmentation with deep convolutional nets, atrous convolution, and fully connected CRFs[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2018, **40**(4): 834-848.
- [42] Chauhan S, Rühaak W, Khan F, et al. Processing of rock core microtomography images: using seven different machine learning algorithms[J]. *Computers & Geosciences*, 2016, **86**: 120-128.
- [43] Esmaeili B, Hosseinzadeh S, Kadkhodaie A, et al. Simulating reservoir capillary pressure curves using image processing and classification machine learning algorithms applied to petrographic thin sections[J]. *Journal of African Earth Sciences*, 2024, **209**: 105098.
- [44] Niu Y, Mostaghimi P, Shabaninejad M, et al. Digital rock segmentation for petrophysical analysis with reduced user bias using convolutional neural networks[J]. *Water Resources Research*, 2020, **56**(2): e2019WR026597.
- [45] Blunt M J, Bijeljic B, Dong H, et al. Pore-scale imaging and modelling[J]. *Advances in Water Resources*, 2013, **51**: 197-216.
- [46] Chorin A J. Numerical solution of the Navier-Stokes equations[J]. *Mathematics of Computation*, 1968, **22**(104): 745-762.
- [47] Saxena N, Hofmann R, Alpak F O, et al. References and benchmarks for pore-scale flow simulated using micro-CT images of porous media and digital rocks[J]. *Advances in Water Resources*, 2017, **109**: 211-235.
- [48] Liu H, Kang Q, Leonardi C R, et al. Multiphase lattice Boltzmann simulations for porous media applications: a review[J]. *Computational Geosciences*, 2016, **20**(4): 777-805.
- [49] Wang L, Wang S, Zhang R, et al. Review of multi-scale and multi-physical simulation technologies for shale and tight gasreservoirs[J]. *Journal of Natural Gas Science and Engineering*, 2017, **37**: 560-578.
- [50] 朱伯靖, 石耀霖. 波尔兹曼数字岩芯致密砂岩渗透率研究[J]. 力学学报, 2013, **45**(3): 384-394. (Zhu Bojing, Shi Yaolin. Study of tight sandstone permeability from lattice Boltzmann & digital rock model[J]. *Chinese Journal of Theoretical and Applied Mechanics*, 2013, **45**(3): 384-394. (in Chinese))
- [51] Chen L, Zhang L, Kang Q, et al. Nanoscale simulation of shale transport properties using the lattice Boltzmann method: permeability and diffusivity[J]. *Scientific Reports*, 2015, **5**: 8089.
- [52] Zhao J, Yao J, Zhang M, et al. Study of gas flow characteristics in tight porous media with a microscale lattice Boltzmann model[J]. *Scientific Reports*, 2016, **6**: 32393.
- [53] Zhao W, Jia C, Song Y, et al. Hydrocarbon migration and accumulation simulation: a review and a novel multi-scale quantitative numerical simulation method[J]. *Advances in Colloid and Interface Science*, 2025, **342**: 103523.
- [54] Zhao J, Kang Q, Yao J, et al. The effect of wettability heterogeneity on relative permeability of two-phase flow in porous media: a lattice Boltzmann study[J]. *Water Resources Research*, 2018, **54**(2): 1295-1311.
- [55] 陈家豪, 娄钦. 考虑接触角滞后性多孔介质内非混相驱替研究[J]. 应用数学和力学, 2021, **42**(9): 900-914. (Chen Jiahao, Lou Qin. An investigation on the immiscible displacement in porous media with contact angle hysteresis[J]. *Applied Mathematics and Mechanics*, 2021, **42**(9): 900-914. (in Chinese))
- [56] Liu T, Zhang S, Wang M. Does rheology of Bingham fluid influence upscaling of flow through tight porous media? [J]. *Energies*, 2021, **14**(3): 680.

- [57] 丁弘毅,王治云,赵敬帅,等. 含孔板微通道内随流气泡运动的两相格子 Boltzmann 模拟[J]. 应用数学和力学, 2024, **45**(1): 97-109. (Ding Hongyi, Wang Zhiyun, Zhao Jingshuai, et al. The 2-phase lattice Boltzmann simulation of flow-following bubble movement through microchannels in orifice plates[J]. *Applied Mathematics and Mechanics*, 2024, **45**(1): 97-109. (in Chinese))
- [58] Chen C, Zhang D. Pore-scale simulation of density-driven convection in fractured porous media during geological CO₂ sequestration[J]. *Water Resources Research*, 2010, **46**(11): 2010WR009453.
- [59] Zhang L, Jing W, Yang Y, et al. The investigation of permeability calculation using digital core simulation technology[J]. *Energies*, 2019, **12**(17): 3273.
- [60] Lanetc Z, Zhuravljov A, Jing Y, et al. Coupling of pore network modelling and volume of fluid methods for multiphase flow in fractured media[J]. *Fuel*, 2022, **319**: 123563.
- [61] Wang J Q, Zhao J F, Yang M J, et al. Permeability of laboratory-formed porous media containing methane hydrate: observations using X-ray computed tomography and simulations with pore network models[J]. *Fuel*, 2015, **145**: 170-179.
- [62] Zhao J, Qin F, Derome D, et al. Improved pore network models to simulate single-phase flow in porous media by coupling with lattice Boltzmann method[J]. *Advances in Water Resources*, 2020, **145**: 103738.
- [63] Wang J. Continuum theory for dense gas-solid flow: a state-of-the-art review[J]. *Chemical Engineering Science*, 2020, **215**: 115428.
- [64] Chandra D, Vishal V. A critical review on pore to continuum scale imaging techniques for enhanced shale gas recovery[J]. *Earth-Science Reviews*, 2021, **217**: 103638.
- [65] Ranjbarzadeh R, Sappa G. Numerical and experimental study of fluid flow and heat transfer in porous media: a review article[J]. *Energies*, 2025, **18**(4): 976.
- [66] Yan X, Huang Z, Yao J, et al. Numerical simulation of hydro-mechanical coupling in fractured vuggy porous media using the equivalent continuum model and embedded discrete fracture model[J]. *Advances in Water Resources*, 2019, **126**: 137-154.
- [67] Liu T, Jin X, Wang M. Critical resolution and sample size of digital rock analysis for unconventional reservoirs [J]. *Energies*, 2018, **11**(7): 1798.
- [68] Liu T, Wang M. Critical REV size of multiphase flow in porous media for upscaling by pore-scale modeling [J]. *Transport in Porous Media*, 2022, **144**(1): 111-132.
- [69] Kochkov D, Smith J A, Alieva A, et al. Machine learning-accelerated computational fluid dynamics[J]. *Proceedings of the National Academy of Sciences of the United States of America*, 2021, **118**(21): e2101784118.
- [70] Petersen K J, Brinkerhoff J R. On the lattice Boltzmann method and its application to turbulent, multiphase flows of various fluids including cryogenics: a review[J]. *Physics of Fluids*, 2021, **33**(4): 041302.
- [71] Li Q, Luo K H, Kang Q J, et al. Lattice Boltzmann methods for multiphase flow and phase-change heat transfer[J]. *Progress in Energy and Combustion Science*, 2016, **52**: 62-105.
- [72] 蔡少斌,杨永飞,刘杰. 考虑热流固耦合作用的多孔介质孔隙尺度两相流动模拟[J]. 力学学报, 2021, **53**(8): 2225-2234. (Cai Shaobin, Yang Yongfei, Liu Jie. Pore-scale simulation of multiphase flow considering thermo-hydro-mechanical coupling effect in porous media[J]. *Chinese Journal of Theoretical and Applied Mechanics*, 2021, **53**(8): 2225-2234. (in Chinese))
- [73] Xi C, Gong W, Lu X, et al. Wettability evolution of sandpacks with clay content during long-term waterflooding: a pore-scale contact angle characterization[J]. *SPE Journal*, 2025, **30**(1): 180-197.
- [74] Wang S, Shen Y. Coarse-grained CFD-DEM modelling of dense gas-solid reacting flow [J]. *International Journal of Heat and Mass Transfer*, 2022, **184**: 122302.
- [75] Patursson Ø, Swift M R, Tsukrov I, et al. Development of a porous media model with application to flow through and around a net panel[J]. *Ocean Engineering*, 2010, **37**(2/3): 314-324.
- [76] Li X, Li B, Liu F, et al. Advances in the application of deep learning methods to digital rock technology[J]. *Advances in Geo-Energy Research*, 2023, **8**(1): 5-18.
- [77] Yang Y, Liu F, Zhang Q, et al. Recent advances in multiscale digital rock reconstruction, flow simulation, and experiments during shale gas production[J]. *Energy & Fuels*, 2023, **37**(4): 2475-2497.

- [78] Rabbani A, Babaei M, Shams R, et al. Deepore: a deep learning workflow for rapid and comprehensive characterization of porous materials[J]. *Advances in Water Resources*, 2020, **146**: 103787.
- [79] Fu J, Wang M, Chen B, et al. A data-driven framework for permeability prediction of natural porous rocks via microstructural characterization and pore-scale simulation[J]. *Engineering With Computers*, 2023, **39**(6): 3895-3926.
- [80] Cawte T, Bazylak A. A 3D convolutional neural network accurately predicts the permeability of gas diffusion layer materials directly from image data[J]. *Current Opinion in Electrochemistry*, 2022, **35**: 101101.
- [81] Xie C, Zhu J, Wang J, et al. Direct prediction of relative permeability curve from 3D digital rock images based on deep learning approaches[J]. *International Journal of Rock Mechanics and Mining Sciences*, 2023, **170**: 105544.
- [82] Wang Y, Rahman S S. Numerical modelling of reservoir at pore scale: a comprehensive review[J]. *Journal of Computational Physics*, 2023, **472**: 111680.
- [83] Mosser L, Dubrule O, Blunt M J. Reconstruction of three-dimensional porous media using generative adversarial neural networks[J]. *Physical Review E*, 2017, **96**(4): 043309.
- [84] Jiang Z, Wang W, Zhu H, et al. Review of shale gas transport prediction: basic theory, numerical simulation, application of AI methods, and perspectives[J]. *Energy & Fuels*, 2023, **37**(4): 2520-2538.
- [85] Mirzaee H, Kamrava S, Tahmasebi P. Minireview on porous media and microstructure reconstruction using machine learning techniques: recent advances and outlook[J]. *Energy & Fuels*, 2023, **37**(20): 15348-15372.
- [86] Song S, Zhang D, Mukerji T, et al. GANSim-surrogate: an integrated framework for stochastic conditional geomodelling[J]. *Journal of Hydrology*, 2023, **620**: 129493.
- [87] Khosravi R, Chahardowli M, Simjoo M. Smart water-polymer hybrid flooding in heavy oil sandstone reservoirs: a detailed review and guidelines for future applications[J]. *Energy & Fuels*, 2024, **38**(14): 12283-12302.
- [88] Zhu Y, Zabarar N. Bayesian deep convolutional encoder-decoder networks for surrogate modeling and uncertainty quantification[J]. *Journal of Computational Physics*, 2018, **366**: 415-447.
- [89] Mo S, Zhu Y, Zabarar N, et al. Deep convolutional encoder-decoder networks for uncertainty quantification of dynamic multiphase flow in heterogeneous media[J]. *Water Resources Research*, 2019, **55**(1): 703-728.
- [90] Feng G, Zhang K, Wan H, et al. Enhancing oil-water flow prediction in heterogeneous porous media using machine learning[J]. *Water*, 2024, **16**(10): 1411.
- [91] Chen X, Zhang K, Ji Z, et al. Progress and challenges of integrated machine learning and traditional numerical algorithms: taking reservoir numerical simulation as an example[J]. *Mathematics*, 2023, **11**(21): 4418.
- [92] Tartakovsky A M, Marrero C O, Perdikaris P, et al. Physics-informed deep neural networks for learning parameters and constitutive relationships in subsurface flow problems[J]. *Water Resources Research*, 2020, **56**(5): e2019WR026731.
- [93] Vu-Quoc L, Humer A. Deep learning applied to computational mechanics: a comprehensive review, state of the art, and the classics[J]. *Computer Modeling in Engineering & Sciences*, 2023, **137**(2): 1069-1343.
- [94] 颜景越, 苏欢. 基于残差的 Fourier 神经网络求解广域椭圆型微分方程以及收敛性证明[J]. 应用数学和力学, 2026, **47**(7): 912-923. (Yan Jingyue, Su Huan. Residual-based Fourier neural network for solving elliptic differential equations on unbounded domains and convergence analysis[J]. *Applied Mathematics and Mechanics*, 2026, **47**(7): 912-923. (in Chinese))
- [95] He Q, Barajas-Solano D, Tartakovsky G, et al. Physics-informed neural networks for multiphysics data assimilation with application to subsurface transport[J]. *Advances in Water Resources*, 2020, **141**: 103610.
- [96] Meng X, Karniadakis G E. A composite neural network that learns from multi-fidelity data: application to function approximation and inverse PDE problems[J]. *Journal of Computational Physics*, 2020, **401**: 109020.
- [97] Yang Y, Perdikaris P. Adversarial uncertainty quantification in physics-informed neural networks[J]. *Journal of Computational Physics*, 2019, **394**: 136-152.

- [98] Kenzhebek Y, Imankulov T, Bekele S D, et al. Coupled pressure and saturation prediction for two-phase flow in porous media using physics-informed neural networks (PINNs) [J]. *Computer Methods in Applied Mechanics and Engineering*, 2025, **446**: 118229.
- [99] Xiang X, Chen Y, Zhang E, et al. Lightweight permeability prediction of digital rocks by merging 3D depth-wise separable convolution with efficient multiscale attention[J]. *Computational Geosciences*, 2025, **29**(3): 21.
- [100] Jamshidi Gohari M S, Emami Niri M, Ghiasi-Freez J. Improving permeability estimation of carbonate rocks using extracted pore network parameters: a gas field case study[J]. *Acta Geophysica*, 2021, **69**(2): 509-527.
- [101] Tian J W, Qi C, Peng K, et al. Improved permeability prediction of porous media by feature selection and machine learning methods comparison [J]. *Journal of Computing in Civil Engineering*, 2022, **36**(2): 04021040.
- [102] 周济民, 张海晨, 王沫然. 基于物理经验模型约束的机器学习方法在页岩油产量预测中的应用[J]. 应用数学和力学, 2021, **42**(9): 881-890. (Zhou Jimin, Zhang Haichen, Wang Moran. Machine learning with physical empirical model constraints for prediction of shale oil production [J]. *Applied Mathematics and Mechanics*, 2021, **42**(9): 881-890. (in Chinese))
- [103] Wang F, Zai Y. Image segmentation and flow prediction of digital rock with U-Net network[J]. *Advances in Water Resources*, 2023, **172**: 104384.
- [104] Tang P, Zhang D, Li H. Predicting permeability from 3D rock images based on CNN with physical information[J]. *Journal of Hydrology*, 2022, **606**: 127473.
- [105] Wang H C, Zhang K, Chen N, et al. Better use of experience from other reservoirs for accurate production forecasting by learn-to-learn method[J]. *Petroleum Science*, 2024, **21**(1): 716-728.
- [106] Liu S, Fan M, Lu D. Uncertainty quantification of the convolutional neural networks on permeability estimation from micro-CT scanned sandstone and carbonate rock images[J]. *Geoenergy Science and Engineering*, 2023, **230**: 212160.
- [107] Wang K, Chen Y, Mehana M, et al. A physics-informed and hierarchically regularized data-driven model for predicting fluid flow through porous media[J]. *Journal of Computational Physics*, 2021, **443**: 110526.
- [108] Yu Y, Chen S, Wei H. Modified U-Net with attention gate and dense skip connection for flow field information prediction with porous media[J]. *Flow Measurement and Instrumentation*, 2023, **89**: 102300.
- [109] Ko D D, Ji H, Ju Y S. Prediction of 3D velocity field of reticulated foams using deep learning for transport analysis[J]. *Transport in Porous Media*, 2023, **148**(3): 577-604.
- [110] Kumar I, Tripathi B K, Singh A. Velocity field prediction for digital porous media using attention-based deep convolutional recurrent neural network[J]. *Chemical Engineering Science*, 2025, **314**: 121825.
- [111] Zhou X H, McClure J E, Chen C, et al. Neural network-based pore flow field prediction in porous media using super resolution[J]. *Physical Review Fluids*, 2022, **7**(7): 074302.
- [112] 田键, 康毅力, 游利军, 等. 致密砂岩孔隙尺度下气-水界面动态演化可视化实验研究[J]. 力学学报, 2024, **56**(3): 862-873. (Tian Jian, Kang Yili, You Lijun, et al. Visualization study on the evolution of gas-water interface at pore-scale in tight sandstone rocks [J]. *Chinese Journal of Theoretical and Applied Mechanics*, 2024, **56**(3): 862-873. (in Chinese))
- [113] Liu S, Zolfaghari A, Sattarin S, et al. Application of neural networks in multiphase flow through porous media: predicting capillary pressure and relative permeability curves[J]. *Journal of Petroleum Science and Engineering*, 2019, **180**: 445-455.
- [114] Telvari S, Sayyafzadeh M, Siavashi J, et al. Prediction of two-phase flow properties for digital sandstones using 3D convolutional neural networks[J]. *Advances in Water Resources*, 2023, **176**: 104442.
- [115] Xie C, Zhu J, Yang H, et al. Relative permeability curve prediction from digital rocks with variable sizes using deep learning[J]. *Physics of Fluids*, 2023, **35**(9): 096605.
- [116] Jiang J. Simulating multiphase flow in fractured media with graph neural networks[J]. *Physics of Fluids*, 2024, **36**(2): 023115.

- [117] Kim Y, Suh H S. GNPNM: a graph neural pore network model for predicting quasi-static drainage displacement patterns[J]. *Computers and Geotechnics*, 2025, **187**: 107497.
- [118] Ji L, Xu F, Lin M, et al. Rapid evaluation of capillary pressure and relative permeability for oil-water flow in tight sandstone based on a physics-informed neural network[J]. *Journal of Petroleum Exploration and Production Technology*, 2023, **13**(12): 2499-2517.
- [119] Hanna J M, Aguado J V, Comas-Cardona S, et al. Residual-based adaptivity for two-phase flow simulation in porous media using physics-informed neural networks[J]. *Computer Methods in Applied Mechanics and Engineering*, 2022, **396**: 115100.
- [120] Cui R, Cao D, Liu Q, et al. V_p and V_s prediction from digital rock images using a combination of U-Net and convolutional neural networks[J]. *Geophysics*, 2021, **86**(1): MR27-MR37.
- [121] Karimpouli S, Tahmasebi P. Image-based velocity estimation of rock using convolutional neural networks[J]. *Neural Networks*, 2019, **111**: 89-97.
- [122] Moghadas D. One-dimensional deep learning inversion of electromagnetic induction data using convolutional neural network[J]. *Geophysical Journal International*, 2020, **222**(1): 247-259.
- [123] Puzyrev V, Swidinsky A. Inversion of 1D frequency- and time-domain electromagnetic data with convolutional neural networks[J]. *Computers & Geosciences*, 2021, **149**: 104681.
- [124] Spichak V V, Zakharova O K. Seismological geothermometer, part I: neural network modeling of the temperature prediction from seismic velocity data at borehole depth scale[J]. *Journal of Applied Geophysics*, 2025, **234**: 105644.
- [125] Zhang T, Bian N, Liu Q, et al. 3D super-resolution reconstruction of porous media based on GANs and CBAMs[J]. *Stochastic Environmental Research and Risk Assessment*, 2024, **38**(4): 1475-1504.
- [126] Elmorsy M, El-Dakhkhni W, Zhao B. Generalizable permeability prediction of digital porous media via a novel multi-scale 3D convolutional neural network[J]. *Water Resources Research*, 2022, **58**(3): e2021WR031454.
- [127] Kashefi A, Mukerji T. Point-cloud deep learning of porous media for permeability prediction[J]. *Physics of Fluids*, 2021, **33**(9): 097109.
- [128] Yang L, Wang S, Chen X, et al. High-fidelity permeability and porosity prediction using deep learning with the self-attention mechanism[J]. *IEEE Transactions on Neural Networks and Learning Systems*, 2023, **34**(7): 3429-3443.
- [129] Zhai S, Geng S, Li C, et al. An improved convolutional neural network for predicting porous media permeability from rock thin sections[J]. *Gas Science and Engineering*, 2024, **127**: 205365.
- [130] Dong Y, Song T, Li X, et al. Multi-scale enhanced multiwavelet-based operator learning model for multiphase flow simulation[J]. *Physics of Fluids*, 2025, **37**(3): 033376.
- [131] Chen X, Zhou K, Jiang P, et al. Identification, characterization, and up-scaling of pore structure facies in the low permeability reservoirs: insight into reservoir quality evaluation and sweet-spots analysis[J]. *Marine and Petroleum Geology*, 2024, **162**: 106646.
- [132] Tosan M. Enhancing evapotranspiration estimation: a bibliometric and systematic review of hybrid neural networks in water resource management[J]. *Computer Modeling in Engineering & Sciences*, 2025, **142**(2): 1109-1154.
- [133] Amini D, Haghighat E, Juanes R. Physics-informed neural network solution of thermo-hydro-mechanical processes in porous media[J]. *Journal of Engineering Mechanics*, 2022, **148**(11): 04022070.
- [134] Yan B, Harp D R, Chen B, et al. A gradient-based deep neural network model for simulating multiphase flow in porous media[J]. *Journal of Computational Physics*, 2022, **463**: 111277.