



基于代理模型的缝内支撑剂铺置形态高效预测方法

张涛 周航宇 张一凡 郭建春 苟浩然 唐堂

An efficient method for predicting the morphology of proppant packs based on a surrogate model

ZHANG Tao, ZHOU Hangyu, ZHANG Yifan, GUO Jianchun, GOU Haoran, TANG Tang

引用本文:

张涛, 周航宇, 张一凡, 郭建春, 苟浩然, 唐堂. 基于代理模型的缝内支撑剂铺置形态高效预测方法[J]. *北科大: 工程科学学报*, 2025, 47(3): 526–537. doi: 10.13374/j.issn2095–9389.2024.05.06.002

ZHANG Tao, ZHOU Hangyu, ZHANG Yifan, GUO Jianchun, GOU Haoran, TANG Tang. An efficient method for predicting the morphology of proppant packs based on a surrogate model[J]. *Chinese Journal of Engineering*, 2025, 47(3): 526–537. doi: 10.13374/j.issn2095–9389.2024.05.06.002

在线阅读 View online: <https://doi.org/10.13374/j.issn2095–9389.2024.05.06.002>

您可能感兴趣的其他文章

Articles you may be interested in

裂缝网络支撑剂非均匀分布对开采动态规律的影响

Effect of uneven distribution of proppant in fracture network on exploitation dynamic characteristics
工程科学学报. 2020, 42(10): 1318 <https://doi.org/10.13374/j.issn2095–9389.2019.10.23.001>

基于深度神经网络的点击率预测模型

Click-through rate prediction model based on a deep neural network
工程科学学报. 2022, 44(11): 1917 <https://doi.org/10.13374/j.issn2095–9389.2021.03.23.002>

深度神经网络模型压缩综述

A survey of model compression for deep neural networks
工程科学学报. 2019, 41(10): 1229 <https://doi.org/10.13374/j.issn2095–9389.2019.03.27.002>

基于KmeansBP神经网络的KR工序终点铁水硫含量预测模型

End sulfur content prediction method of molten iron in KR based on KmeansBP neural network
工程科学学报. 2023, 45(7): 1187 <https://doi.org/10.13374/j.issn2095–9389.2022.05.29.004>

基于3D卷积神经网络的膏体屈服应力预测

Prediction of paste yield stress based on three-dimensional convolutional neural networks
工程科学学报. 2024, 46(8): 1337 <https://doi.org/10.13374/j.issn2095–9389.2023.10.11.005>

深度神经网络模型量化方法综述

A survey of quantization methods for deep neural networks
工程科学学报. 2023, 45(10): 1613 <https://doi.org/10.13374/j.issn2095–9389.2022.12.27.004>

基于代理模型的缝内支撑剂铺置形态高效预测方法

张涛¹⁾, 周航宇^{1)✉}, 张一凡²⁾, 郭建春¹⁾, 苟浩然³⁾, 唐堂⁴⁾

1) 西南石油大学“油气藏地质及开发工程”全国重点实验室, 成都 610500 2) 国家管网集团浙江省天然气管网有限公司, 杭州 310000

3) 长庆油田分公司第七采油厂, 西安 710000 4) 中国石油西南油气田公司页岩气研究院, 成都 610056

✉通信作者, E-mail: hangyu_zhou999@163.com

摘要 非常规油气储层体积压裂中, 大量支撑剂颗粒随压裂液注入地层裂缝, 其在缝内的铺置形态将决定裂缝支撑效果和导流能力. 准确预测缝内支撑剂铺置形态有助于优化压裂设计、提升改造效率. 实验模拟和数值模拟是当前复现缝内支撑剂堆积过程和铺置形态的主要手段, 但仍存在模拟尺度小、模拟耗时长和操作成本高等局限. 本文以支撑剂输送数值模拟结果为数据集, 提取了表征支撑剂铺置堆积的特征参数, 基于级联神经网络, 建立了支撑剂铺置形态预测的智能代理模型. 结果表明, 代理模型预测结果与数值模拟结果高度吻合, 单步预测耗时仅为单步模拟耗时的 0.14%. 本文提出的模型和方法可实现支撑剂输送仿真加速, 极大地缩短了支撑剂铺置形态的预测时间, 其进一步完善后将在压裂实践中具有广泛的应用前景.

关键词 体积压裂; 支撑剂; 铺置形态; 级联神经网络; 代理模型

分类号 TB126; TE357

An efficient method for predicting the morphology of proppant packs based on a surrogate model

ZHANG Tao¹⁾, ZHOU Hangyu^{1)✉}, ZHANG Yifan²⁾, GUO Jianchun¹⁾, GOU Haoran³⁾, TANG Tang⁴⁾

1) National Key Laboratory of Oil & Gas Reservoir Geology and Exploitation, Southwest Petroleum University, Chengdu 610500, China

2) PipeChina Zhejiang Pipeline Network Co., Ltd., Hangzhou 310000, China

3) China Petrolioproduct Plant No.7 Changqing Oilfield Company, Xian 710000, China

4) Shale Gas Research Institute, Petro China Southwest Oil & Gasfield Company, Chengdu 610056, China

✉Corresponding author, E-mail: hangyu_zhou999@163.com

ABSTRACT In the volume fracturing of unconventional oil and gas reservoirs, many proppant particles are injected underground along with the fracturing fluid, and their placement patterns determine the propping effect and conductivity of fractures. Accurate prediction of the in-fracture proppant placement patterns can help optimize the fracturing design and improve fracturing efficiency. Currently, experimental and numerical methods are the main approaches for reproducing the proppant accumulation process and placement patterns in fractures. These methods are still confined by limited simulation scales, time-consuming computations, and high-cost operations. In this paper, the two-fluid method was employed for numerical simulations, with a primary focus on the effects of drag, virtual mass, and lift forces on the momentum exchange between phases. The numerical simulations were conducted on the Fluent platform, and the simulation results were validated against experimental data to ensure reliability and accuracy. The numerical simulation results of proppant transport would be adopted as data sets for input, training, and testing. To characterize the intricate accumulation and packing dynamics of proppants, we distilled key parameters, specifically the concentration distribution and accumulation height profiles. Through correlation analysis, the primary factors influencing these characteristic parameters were identified. Intelligent proxy models for

收稿日期: 2024–05–06

基金项目: 国家自然科学基金联合基金资助项目(U23B6004)

the prediction of proppant placement patterns were established on the basis of the cascade neural network, including a time-concentration model for predicting particle volume fraction and a displacement-height model for predicting particle placement height. The former model enabled predictions of the distribution of proppant concentrations within the fracture at different times, whereas the latter allowed estimation of how the stacking heights of proppants varied with the injection rate. Furthermore, the grid precisions of the prediction models were optimized to enhance their accuracy and performance. The data were allocated to the training, validation, and testing phases of the surrogate model at a ratio of 6 : 2 : 2, respectively. Specifically, 60% of the data was used for training the models, 20% was used for validation to fine-tune the models' parameters, and another 20% was used for testing to evaluate the models' performance on unseen data. The results showed that the predictions of proppant placement patterns were highly consistent with the numerical simulation results. For the time-concentration model, the prediction results were closely aligned with the numerical simulation outcomes, successfully capturing the characteristics of a constant placement height and a progressive increase in placement length after reaching the equilibrium height. For the displacement-height model, although the predicted placement profile lacked detailed irregularities of the proppant accumulation surface because of model simplification, it accurately described the characteristic variation in placement morphology with changes in injection rate, demonstrating that the surrogate model for predicting particle placement height can also efficiently capture the proppant placement morphology within the fracture. Additionally, the time consumed by a single prediction step was only 0.14% of the time consumed by a single simulation step. The model and approach proposed in this study accelerated the speed of proppant transport simulation and greatly shortened the prediction time of the proppant placement patterns, which could be widely applied in fracturing in the field after further improvement.

KEY WORDS volume fracturing; proppant; placement pattern; cascade neural network; surrogate model

目前,国内非常规储层水平井分段多簇压裂总体呈现“大排量、大液量、变黏度、多粒径、强加砂”等特点^[1],压裂液单相流动流态多变、压裂液携带支撑剂输运的多相流动机理复杂等使得缝内支撑剂铺置规律难以把握^[2],导致针对压裂设计和施工优化的科学指导不足,压后裂缝有效支撑体积受限、裂缝导流能力难以保持、油气产能递减迅速^[3]。

缝内支撑剂输运铺置本质属于狭缝内稠密固液多相流问题,实验模拟和数值模拟是当前针对该问题研究的主要手段^[4]。实验模拟通过搭建功能性装置,局部地再现缝内支撑剂运动过程^[5]。实验表征手段从单纯观测支撑剂铺置形态的半定量实验发展到能够解析颗粒流场的定量实验^[6]。由于实验装置和地层裂缝的尺度差异,实验模拟需严格遵守流体力学相似。基于计算流体力学理论的各种数值模拟方法主要分为追踪颗粒运动轨迹的欧拉-拉格朗日法^[7-10]和描述连续颗粒流动的欧拉-欧拉法^[11-13],研究尺度相应地从微纳米级颗粒尺度上升至百米级矿场尺度。相比欧拉-拉格朗日法,欧拉-欧拉法虽然因忽略了颗粒尺度运动信息而适用于矿场尺度裂缝中支撑剂输运铺置模拟^[14],但在面向以地质工程一体化模拟为代表的大型工程数值计算中,该方法仍会占用大量计算资源并消耗较长计算时间,不能较好地满足日益提升的工程需求。

基于代理模型的优化算法能够高效处理固液多相流这类非线性问题^[15],如 Ansari 等^[16]基于 BP 神经网络建立了流化床数值仿真的代理模型, Hosseini Boosari 等^[17]将网格相邻单元信息作为神经网络输入参数,建立了二维溃坝数值仿真的代理模型。此外,代理模型也已被广泛应用于测井解释^[18]、注采优化^[19]和产量预测^[20]等石油工程领域。周德胜等^[21]提出一种基于 BP 神经网络的支撑剂铺置形态预测方法,以支撑剂动态输送实验结果作为数据集,实现对以施工参数为输入的支撑剂砂堤平衡高度、平衡时间和砂堤前缘位置的预测。但该方法不能完整预测缝内支撑剂铺置形态,更无法以预测结果为基础开展支撑导流能力计算等进一步工作。

为解决上述问题,更加准确、快速地获取缝内支撑剂铺置形态,本文借鉴机器学习方法在其他固液多相流领域成功应用经验,提出了结合数值模拟数据和代理模型的新方法以预测缝内支撑剂铺置形态。研究表明,方法中代理模型对数值模型的拟合度达到 0.998,而代理模型对每步长内铺置形态的预测耗时仅为数值模拟的 0.14%,该方法可以减少数值模拟调用次数并大幅减低时间成本,在压裂实践中具有广泛的应用潜力。

1 方法

数值模拟方法通过求解描述支撑剂输运物理

过程的偏微分方程组来实现对支撑剂铺置形态演化的动态仿真, 数学模型经过实验验证, 因此具有明确的物理意义. 代理模型以数值模拟数据作为输入, 通过训练样本构建目标函数近似模型, 在计算目标函数时无需重复调用固液多相流数值模拟器, 直接利用近似模型分析输入参数关联性, 实现

支撑剂铺置形态预测(图 1).

1.1 数值模型

1.1.1 两流体模型

本文采用两流体法开展数值模拟, 两流体中压裂液和支撑剂运动由质量、动量和能量守恒方程表示^[22]:

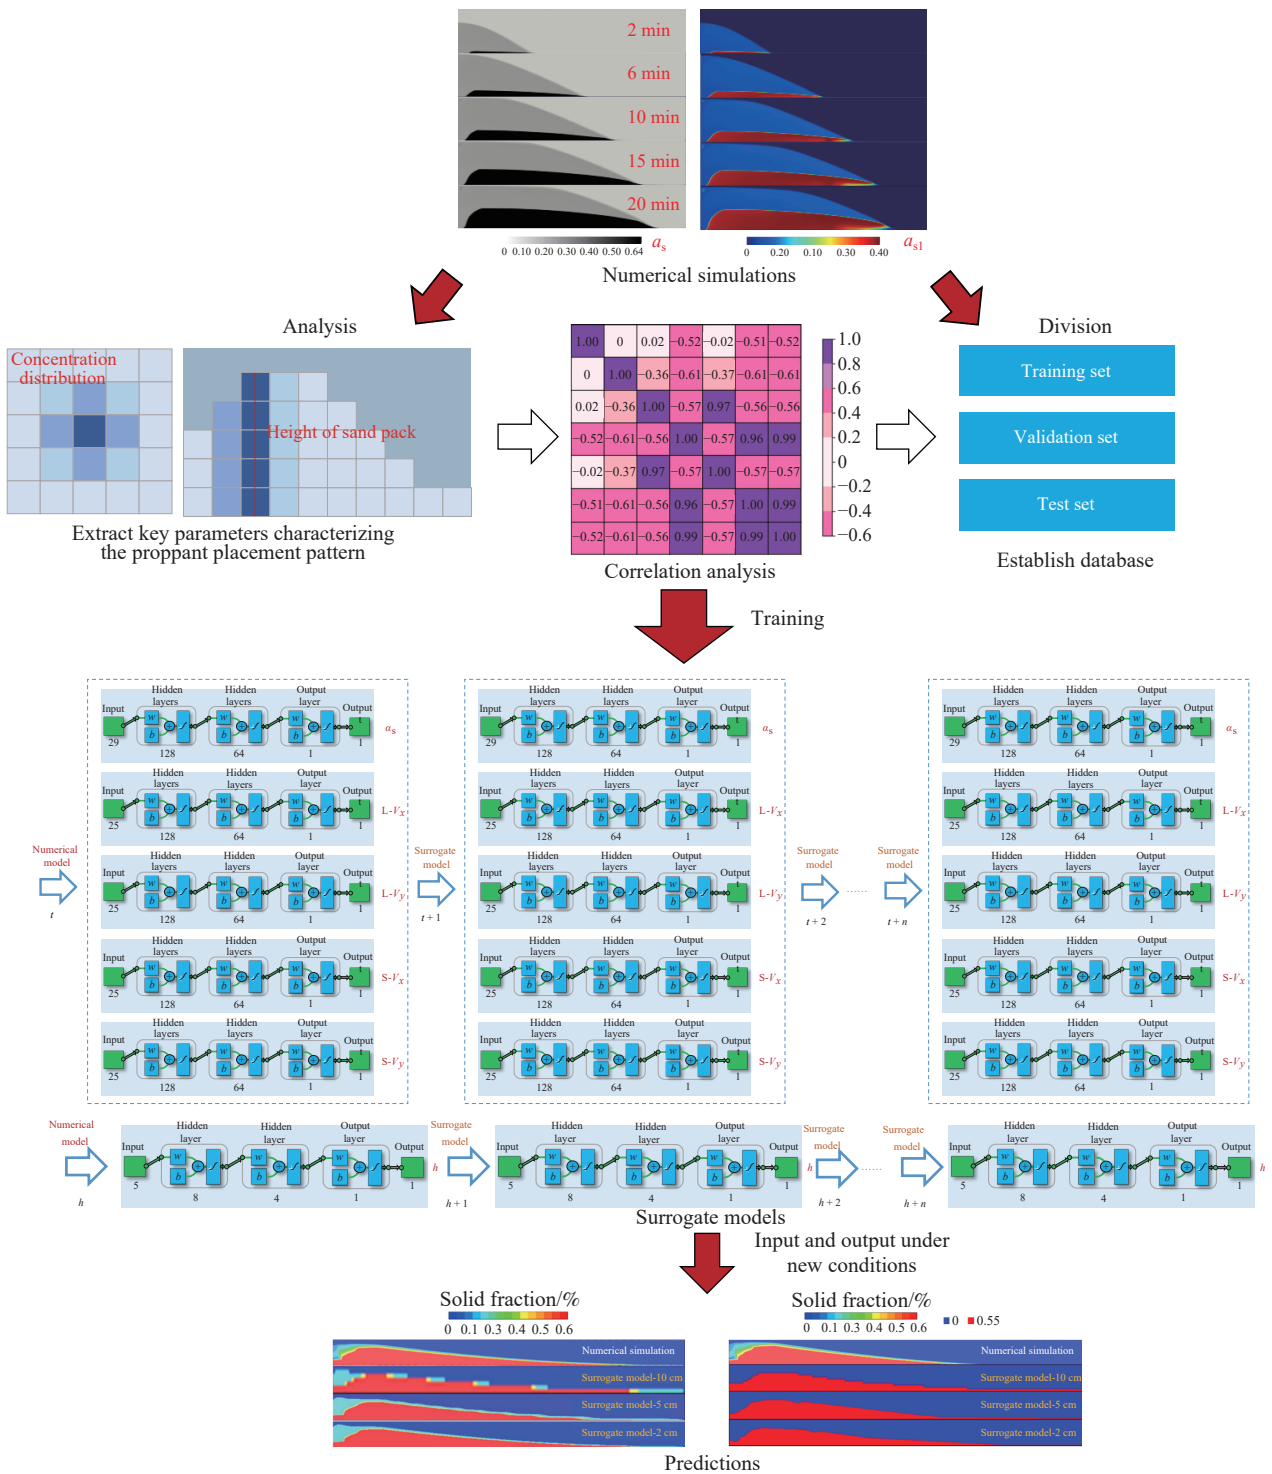


图 1 代理模型预测缝内支撑剂铺置形态流程图

Fig.1 Flowchart of surrogate model prediction for proppant placement morphology within fractures

$$\left\{ \begin{array}{l} \frac{\partial}{\partial t} (\alpha_l \rho_l) + \nabla \cdot (\alpha_l \rho_l \mathbf{U}_l) = 0 \\ \frac{\partial}{\partial t} (\alpha_s \rho_s) + \nabla \cdot (\alpha_s \rho_s \mathbf{U}_s) = 0 \\ \frac{\partial}{\partial t} (\alpha_l \rho_l \mathbf{U}_l) + \nabla \cdot (\alpha_l \rho_l \mathbf{U}_l \mathbf{U}_l) = \\ \quad \alpha_l \rho_l \mathbf{g} - \nabla (\alpha_l p_l) + \nabla \cdot (\alpha_l \boldsymbol{\tau}_l) - \mathbf{F}_{ls} \\ \frac{\partial}{\partial t} (\alpha_s \rho_s \mathbf{U}_s) + \nabla \cdot (\alpha_s \rho_s \mathbf{U}_s \mathbf{U}_s) = \\ \quad -\alpha_s \nabla p_l + \alpha_s \rho_s \mathbf{g} - \nabla p_s + \nabla \cdot \boldsymbol{\tau}_s + \mathbf{F}_{ls} \\ \frac{3}{2} [\partial (\alpha_s \rho_s \Theta) / \partial t + \nabla \cdot (\alpha_s \rho_s \Theta \mathbf{U}_s)] = \\ \quad -\nabla \cdot (\kappa \nabla \Theta) + (-p_s \mathbf{I} + \boldsymbol{\tau}_s) : \nabla \mathbf{U}_s - \gamma \end{array} \right. \quad (1)$$

式中, t 为时间, s; 下标 l 和 s 分别为液相和颗粒相; α 为相体积分数; ρ 为相密度, $\text{kg} \cdot \text{m}^{-3}$; \mathbf{U} 为相速度, $\text{m} \cdot \text{s}^{-1}$; p 为相压力, Pa; $\boldsymbol{\tau}$ 为相剪切应力, Pa; \mathbf{F}_{ls} 为单位体积相间动量交换项, Pa; \mathbf{g} 为重力加速度, 取 $9.81 \text{ m} \cdot \text{s}^{-2}$; Θ 为颗粒温度, $\text{m}^2 \cdot \text{s}^{-2}$; κ 为单位体积内能传导系数, $\text{kg} \cdot \text{m}^{-2} \cdot \text{s}^{-1}$; \mathbf{I} 为单位张量; γ 为单位体积内能耗散率, $\text{kg} \cdot \text{m}^{-1} \cdot \text{s}^{-3}$. 需要对 $\boldsymbol{\tau}$ 、 p_s 、 κ 、 γ 和 \mathbf{F}_{ls} 等项进一步封闭处理^[23-25]. 湍流黏度采用标准 $k-\epsilon$ 模型^[26] 计算.

本文主要考虑曳力、虚拟质量力和升力对相间动量交换的影响^[22], 其中虚拟质量力和升力通过常质量因子和常升力系数模型计算, 曳力采用经壁面阻滞修正的 Gidaspow 模型^[14]. 数值模拟基于 Fluent 平台开展, 采用固定速度入口和固定压力出口边界条件, 液相在壁面上采用无滑移速度边界和标准壁面函数, 固相在壁面上采用 Johnson-Jackson 颗粒滑动和温度边界^[27]. 采用 SIMPLE 算法进行求解, 收敛残差小于 10^{-4} .

1.1.2 模型验证

采用实验结果验证数值模型可靠性, 实验装

置(图 2)为长×高×宽为 $4000 \text{ mm} \times 300 \text{ mm} \times 10 \text{ mm}$ 的可视化平板裂缝, 进出口均为直径 10 mm 的圆形孔, 沿缝高等距分布. 模拟使用的几何模型(图 3)除进出口使用 $8 \text{ mm} \times 10 \text{ mm}$ 的矩形孔代替圆形孔外, 其他尺寸与实验装置保持一致, 采用结构化网格对几何模型进行剖分. 经过网格无关性验证^[14, 26], 长、高、宽三个方向的网格数分别为 400、35 和 5 个.

实验使用 $0.212 \sim 0.38 \text{ mm}$ 石英砂, 数值模拟对应使用 0.3 mm 颗粒; 注入排量均为 $30 \text{ L} \cdot \text{min}^{-1}$, 液体黏度为 $2.5 \text{ mPa} \cdot \text{s}$, 支撑剂注入浓度为 $160 \text{ kg} \cdot \text{m}^{-3}$. 实验模拟与数值模拟结果对比如图 4 所示, 两者在支撑剂铺置形态上基本吻合, 平衡高度接近, 砂堤前、后端沉降坡面角基本相同, 证明了本文所采




图 2 可视化平板裂缝实验装置

Fig.2 Experimental device of a visual plate fracture




图 3 裂缝几何模型

Fig.3 Geometric model of a fracture

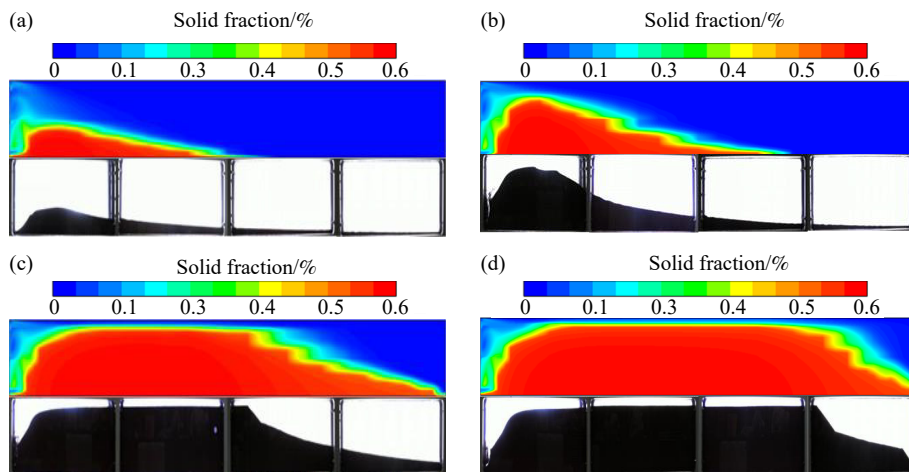


图 4 数值模拟与实验结果对比. (a) 27 s; (b) 70 s; (c) 120 s; (d) 200 s

Fig.4 Comparison of numerical simulation and experimental results: (a) 27 s; (b) 70 s; (c) 120 s; (d) 200 s

用数值模型的有效性.

1.2 代理模型

1.2.1 求解器模型

支撑剂沿缝宽方向(z 轴向)连续铺置, 支撑剂铺置形态沿裂缝长、高方向(xy 平面)演化. 描述铺置形态的数值模拟数据存储在三维离散网格中, 基于人工神经网络, 将三维网格数据降维至二维表格数据, 在保证预测准确性的前提下提升预测速度. 为实现最佳训练效果, 选择结合了 Momentum 梯度下降算法和 AdaGrad 自适应优化算法的 Adam 优化器进行模型优化, 选择 ReLU 函数作为激活函数. 选择 Earliestopping 回调函数防止模型过拟合, 当参数性能在规定迭代次数内不再改善时停止训练. 采用支撑剂铺置高度的均方根误差(RMSE)和拟合度(R^2)对模型预测效果进行评价. 相关模型总结在表 1 中.

式中, G_t 为第 t 时间步的梯度; f 为目标函数, 一般为损失函数; θ 为求解参数; m_t 和 v_t 分别为 G_t 的一、二阶矩; β_1 和 β_2 分别为一、二阶矩的衰减系数; η 为学习率; ε 为小数, 取 10^{-8} ; x 指代任意输入参数; $\hat{\theta}_t$ 为预测值; θ_t 为实际值; $\bar{\theta}$ 为实际值的平均值.

1.2.2 预测目标

根据支撑剂堆积过程, 提取了描述支撑剂铺置形态的特征参数作为代理模型预测目标: (1) 以颗粒体积分数作为预测目标, 可以获取支撑剂铺置形态的演化过程, 同时也便于获取支撑剂砂堤内部空隙率, 为支撑裂缝导流能力计算提供基础数据. (2) 以颗粒铺置高度作为预测目标, 借助微积分思想, 通过连接不同网格铺置高度勾勒出支

表 1 代理模型数学表达式

Name	Expression
Adam	$\begin{cases} G_t = \nabla f(\theta_t) \\ m_t = \beta_1 m_{t-1} + (1 - \beta_1) G_t \\ v_t = \beta_2 v_{t-1} + (1 - \beta_2) G_t^2 \\ \hat{m}_t = \frac{m_t}{1 - \beta_1^t} \\ \hat{v}_t = \frac{v_t}{1 - \beta_2^t} \\ \theta_{t+1} = \theta_t - \frac{\eta}{\sqrt{\hat{v}_t + \varepsilon}} \hat{m}_t \end{cases}$
ReLU	$f(x) = \begin{cases} x & (x > 0) \\ 0 & (x \leq 0) \end{cases}$
RMSE	$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (\hat{\theta}_i - \theta_i)^2}$
R^2	$R^2 = \frac{\sum_{i=1}^n (\theta_i - \bar{\theta})^2 - \sum_{i=1}^n (\theta_i - \hat{\theta}_i)^2}{\sum_{i=1}^n (\theta_i - \bar{\theta})^2}$

撑剂铺置形态轮廓.

1.2.3 预测模型

(1) 预测颗粒体积分数

以颗粒体积分数作为预测目标, 需要使用 t 时刻的参数预测 $t+1$ 时刻的参数变化. 基于 Spearman 相关性分析^[16](图 5), 明确了颗粒体积分数与固、液两相速度和网格位置有较高相关性.

根据关联参数间的传递特点, 建立了数据分层传递系统(图 6), 中心网格颗粒体积分数预测主要受第一层网格数据影响. 因此, 以中心网格和第一层网格的颗粒体积分数、固液两相速度以及中心网格到裂缝边界的距离为输入参数, 建立预测




图 5 中心网格中输入参数与预测目标的相关性

Fig.5 Correlation between the input parameters in the interest cell and the predicted target




图 6 分层系统示意图

Fig.6 Schematic of the hierarchy system

颗粒体积分数的代理模型. 输入参数列于表 2.

颗粒体积分数预测需要固液两相速度, 还需建立中心网格固、液两相分别在 x 、 y 方向的速度预测代理模型. 由于速度与方位的关联性总体较低, 相较于表 2, 用于预测速度的代理模型输入参数省去了中心单元距裂缝边界距离的 4 个参数, 总计 25 个. 最终, 建立了从 t_0 参数输入到 t_n 参数预测的级联神经网络(图 7). 颗粒体积分数预测流程如图 8 所示.

(2) 预测颗粒铺置高度

以颗粒铺置高度作为预测目标, 需要先对高度单元定位(图 9): 沿从裂缝入口(左端)到出口

(右端)的方向将裂缝域等分, 提取不同等分位置处的裂缝高度, 按顺序对高度单元编号.

基于前述方法进行相关性分析, 高度单元编号、当前单元距裂缝左/右边界的距离、上一单元铺置高度和注入排量与当前单元铺置高度的相关性均超过 0.6. 因此, 以这 5 个参数作为输入, 当前单元铺置高度作为输出, 建立了从初始单元铺置高度输入到第 n 个单元铺置高度预测的级联神经网络(图 10). 颗粒体积分数预测流程如图 11 所示.

2 网络优化

代理模型输入数据源于数值模拟结果, 而通过克里金插值法对数值模拟结果进行处理可以获得不同的网格精度. 用于展示预测结果的网格精度将影响数据容量和变量分辨率, 因此需要对展示预测结果的网格数量进行优化. 为体现代理模型对更大尺度裂缝几何模型的适应性, 将 1.1.2 中裂缝几何模型尺度扩大至长 \times 高 \times 宽为 15000 mm \times 600 mm \times 10 mm, 其他条件不变.

2.1 颗粒体积分数预测

对于预测颗粒体积分数的代理模型, 测试了由稀疏到精细的三种网格尺寸(表 3). 将数值模拟(0.3 mm 粒径、50 L \cdot min $^{-1}$ 、2.5 mPa \cdot s 和 160 kg \cdot m $^{-3}$) 在 192 s 时的数据插值到三种网格中, 网格对应的

表 2 颗粒体积分数预测代理模型输入参数

Table 2 Input parameters of the surrogate model for particle volume fraction prediction

Parameter	Number
Phase fraction and two-phase velocities in the central unit	5
Phase fraction and two-phase velocities in the first layer	4 \times 5=20
Distances from the central unit to the fracture boundaries (top, bottom, left, right)	4
Total input	29

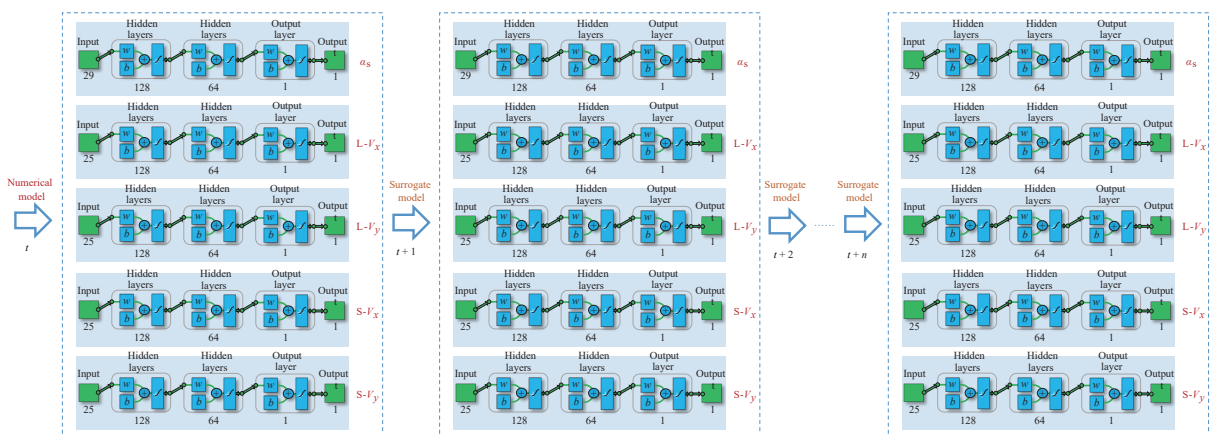


图 7 颗粒体积分数预测级联神经网络示意图(w-权重, b-偏差)

Fig.7 Schematic of the cascade neural network for particle volume fraction prediction (w-weight, b-bias)

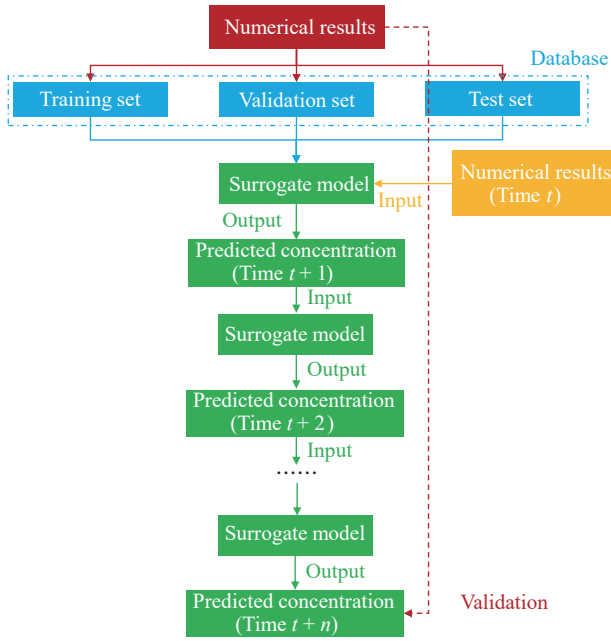


图 8 颗粒体积分数预测流程

Fig.8 Process of particle volume fraction prediction

数据容量分别为 1057、4816 和 23281, 其中用于代理模型训练、验证和测试的数据量比例为 6 : 2 : 2, 即 60% 数据用于训练模型, 20% 用于验证及微调模型参数, 另外 20% 则用于测试模型可靠性。

将数值模拟 194 s 时的数据作为训练后的




图 10 颗粒铺置高度预测级联神经网络示意图

Fig.10 Schematic of the cascade neural network for proppant packing height prediction

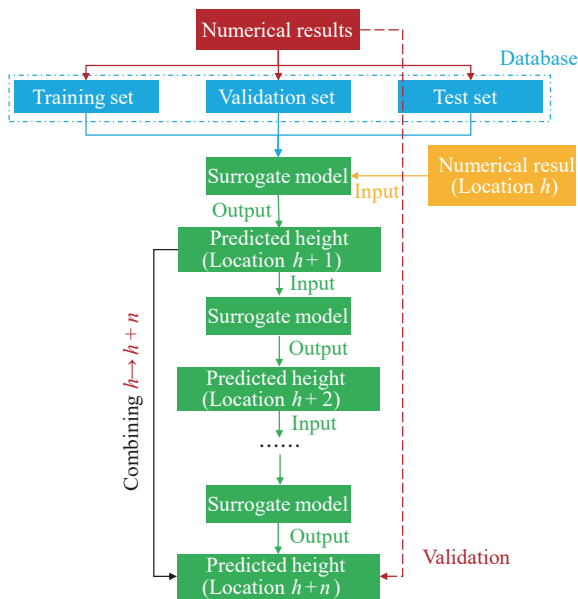


图 11 颗粒铺置高度预测流程

Fig.11 Process of proppant packing height prediction

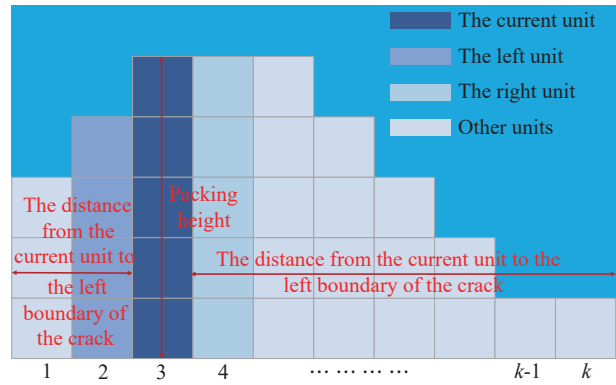


图 9 高度单元划分示意图

Fig.9 Schematic of divided height units

代理模型输入, 每步预测间隔为 2 s, 预测 196 s (1 步)、220 s (13 步) 和 244 s (25 步) 三个时间步的支撑剂铺置形态。稀疏网格预测结果过于粗糙 (图 12)。中等和精细网格在 220 和 244 s 的铺置高度平均预测误差分别是 1.80 cm 和 1.10 cm, 以及 2.13 cm 和 1.36 cm (表 4)。综上所述, 选择 2 cm 精细网格用于预测。

2.2 颗粒铺置高度预测

对于预测颗粒剂铺置高度的代理模型, 主要对沿 x 方向的网格进行细分。使用 2.1 中相同的方法对从稀疏到精细的三种网格 (表 5) 进行测试。

表 3 不同精度网格 (预测颗粒体积分数)

Table 3 Meshes with different precisions (for particle volume fraction prediction)

Grid size after interpolation/cm	Grid number
10 (Sparse)	151×7=1057
5 (Medium)	301×16=4816
2 (Fine)	751×31=23281




图 12 244 s 支撑剂铺置形态 (预测体积分数)

Fig.12 Proppant placement pattern at 244 s (for particle volume fraction prediction)

表 4 使用不同网格产生的高度误差

Table 4 Height error using different grids

Grid size/cm	Height error/cm		
	196 s	220 s	244 s
10 (Sparse)	1.94	3.37	5.16
5 (Medium)	1.09	1.80	2.13
2 (Fine)	0.41	1.10	1.36

表 5 不同精度网格(预测颗粒铺置高度)

Table 5 Meshes with different precisions (for particle packing height prediction)

Grid size after interpolation/cm	Grid number
10 (Sparse)	301×4=1204
5 (Medium)	751×4=3004
2 (Fine)	1501×4=6004

使用排量为 10、30、70、90 L·min⁻¹(其他条件不变)时的数值模拟数据训练模型, 预测 50 L·min⁻¹ 时支撑剂铺置形态(图 13)。稀疏网格得到的预测结果无法细致地刻画支撑剂堆积的表面轮廓。中等和精细网格平均预测误差分别为 2.7% 和 2.3%, 选择 2 cm 精细网格用于模型预测。




图 13 200 s 支撑剂铺置形态(预测铺置高度)

Fig.13 Proppant placement pattern at 200 s (for particle packing height prediction)

3 结果分析

3.1 颗粒体积分数预测

以 50 L·min⁻¹ 进行数值模拟时, 支撑剂将在 244 s 时铺置达到平衡高度。为分析颗粒体积分数




图 15 预测铺置形态轮廓(平衡高度前)

Fig.15 Outlines of placement pattern by prediction (before reaching the equilibrium height)

预测代理模型对砂堤达到平衡高度前的适用性, 以 192 s 时的数值模拟结果作为训练数据, 194 s 时的数值模拟结果作为代理模型输入, 预测了 196 至 244 s 的支撑剂铺置结果(图 14)。代理模型预测结果与数值模拟结果吻合程度高(图 15), 能够完全捕捉随支撑剂铺置高度和长度的逐渐增加、砂堤剖面角不变的特征(椭圆虚线框)。

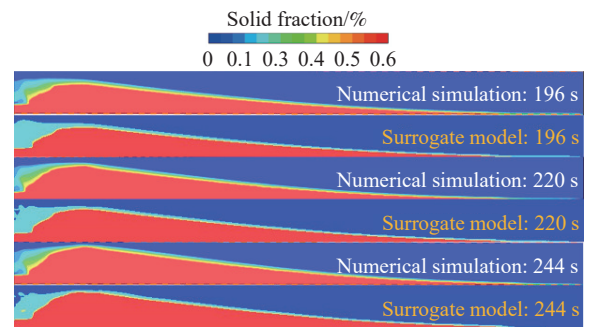


图 14 模拟与预测结果对比(平衡高度前)

Fig.14 Comparison of simulation and prediction (before reaching the equilibrium height)

196 s 时(图 16(a)), 模拟(Numerical simulation)砂堤最大高度和最远长度分别为 0.41 和 12.66 m, 预测(Surrogate model)砂堤最大高度和最远长度分别为 0.41 和 12.64 m, 拟合度达 0.998, 最远长度误差为 2 cm。244 s 时(图 16(b)), 模拟砂堤最大高度和最远长度分别为 0.53 和 13.29 m, 预测砂堤最大高度和最远长度分别为 0.50 和 12.75 m, 拟合度达 0.993, 最大高度和最远长度误差百分比分别为 5.0% 和 3.6%。受级联结构误差累积增大的影响, 平均高度误差随预测时间增长而增大(图 16(c)), 从 0.48 cm (196 s) 增大至 1.24 cm (244 s)。

为分析颗粒体积分数预测代理模型对砂堤达到平衡高度后的适用性, 以 280 s 时的数值模拟结果作为训练数据, 282 s 时的数值模拟结果作为代理模型输入, 预测了 286 至 330 s 的支撑剂铺置结果(图 17)。代理模型预测结果与数值模拟结果吻合程度高(图 18), 能够完全捕捉平衡高度后铺置




图 16 误差分析 (平衡高度前). (a) 铺置轮廓 196 s; (b) 铺置轮廓 244 s; (c) 铺置高度的 RMSE 随时间的变化

Fig.16 Error analysis (before reaching the equilibrium height): (a) outlines of placement patterns 196 s; (b) outlines of placement patterns 244 s; (c) RMSE of packing height changes with time

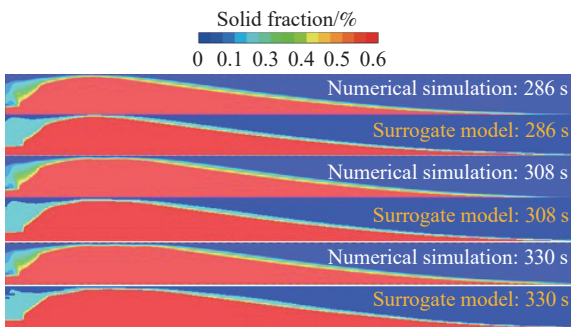


图 17 模拟与预测结果对比(平衡高度后)

Fig.17 Comparison of simulation and prediction (after reaching the equilibrium height)

高度不变、铺置长度呈递进式增长的特征(矩形虚线框).

286 s 时(图 19(a)), 模拟砂堤最大高度和最远长度分别为 0.55 和 13.63 m, 预测砂堤最大高度和

最远长度分别为 0.55 和 13.67 m, 拟合度达 0.998, 最大长度误差为 4 cm. 330 s 时(图 19(b)), 模拟砂堤最大高度和最远长度分别为 0.56 和 14.07 m, 预测砂堤最大高度和最远长度分别为 0.56 和 14.78 m, 拟合度达 0.996, 最远长度误差百分比为 4.7%. 受级联结构误差累积增大的影响, 平均高度误差随预测时间增长而增大(图 19(c)), 从 0.58 cm(286 s) 增大至 1.05cm(330 s). 综上所述, 颗粒体积分数预测代理模型能够高效地获取缝内支撑剂铺置形态.

3.2 颗粒铺置高度预测

以数值模拟中排量 10、30、70 和 90 L·min⁻¹ 泵送支撑剂 200 s 时的结果作为训练数据, 预测相同时刻以 50 L·min⁻¹ 泵送支撑剂形成的铺置形态. 模拟和预测结果在支撑剂主体堆积位置、前后堆积剖面角以及进出口无支撑区都具有相似特征




图 18 预测铺置形态轮廓(平衡高度后)

Fig.18 Outlines of placement patterns by prediction (after reaching the equilibrium height)

(图 20). 模拟砂堤最大高度和最远长度分别为 0.43 和 12.68 m, 预测砂堤最大高度和最远长度分别为 0.42 和 11.84 m, 拟合度达 0.991, 最大高度和最远长度误差百分比分别为 1.7% 和 5.6%.

继续预测了以排量 20、40、60 和 80 L·min⁻¹ 泵送支撑剂 200 s 时的支撑剂铺置形态(图 21). 预测

铺置轮廓虽然丢失了支撑剂堆积表面凹凸不平的细节, 但准确描述了铺置形态随排量变化而变化的特征, 证明了颗粒铺置高度预测代理模型也能够高效地获取缝内支撑剂铺置形态.

3.3 模拟-预测时效分析

两流体数值模拟采用 48 核(Inter Xeon Scalable

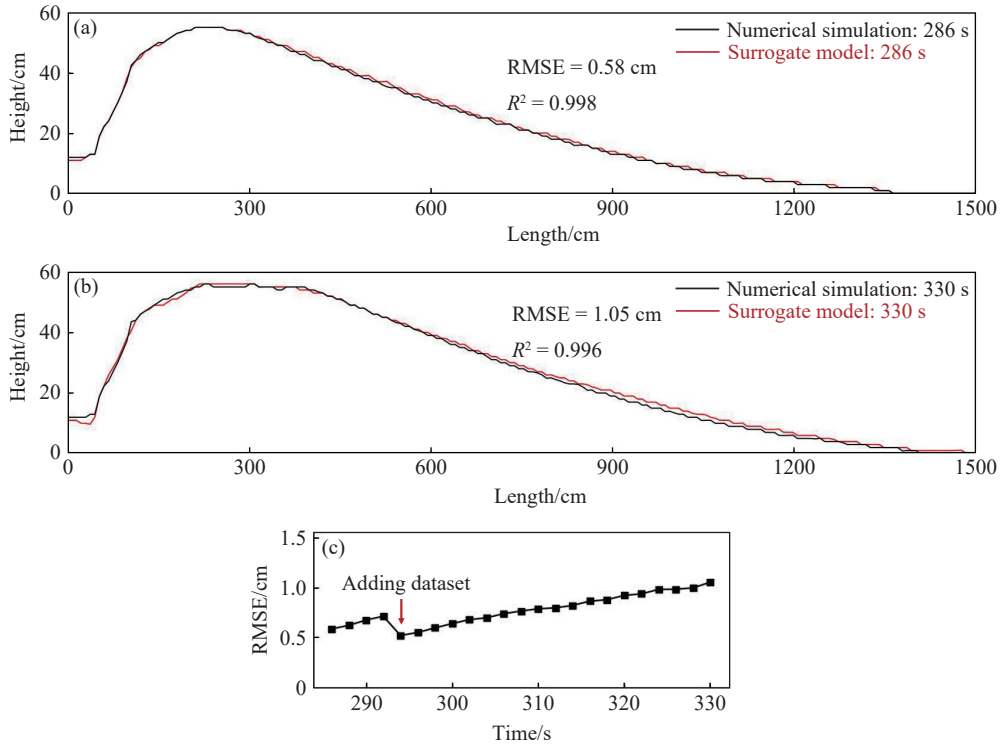


图 19 误差分析(平衡高度后). (a) 铺置轮廓 286 s; (b) 铺置轮廓 330 s; (c) 铺置高度的 RMSE 随时间变化

Fig.19 Error analysis (after reaching the equilibrium height): (a) Outlines of placement patterns 286 s; (b) Outlines of placement patterns 330 s; (c) RMSE of packing height changes with time




图 20 铺置轮廓(50 L·min⁻¹, 200 s)

Fig.20 Outlines of placement patterns (50 L·min⁻¹, 200 s)




图 21 不同排量下铺置轮廓对比(200 s)

Fig.21 Comparison of the outlines of placement patterns under different pumping rates (200 s)

Platinum 8255C CPU) 工作站进行并行计算, 对支撑剂输送 2 s 的模拟平均耗费 1510 s 的物理时间 (表 6); 颗粒体积分数和铺置高度预测代理模型采用 8 核 (Intel Core i7-8750H CPU) 笔记本电脑进行训练和预测, 训练时间分别为 88 和 53 s, 对支撑剂铺置 2 s 的预测耗费 2.17 s 的物理时间. 每步长内预测耗时仅为数值模拟耗时的 0.14%.

表 6 数值模拟计算效率

Table 6 Computing efficiency of numerical simulations

Simulation time/s	Time consumption/s	Average time/s
200–202	1440	
210–212	1680	
220–222	1560	1510
298–300	1500	
308–310	1440	
318–320	1440	

4 结论

本文基于人工神经网络方法建立了以颗粒体积分数和颗粒铺置高度为预测目标的代理模型, 对比了数值模拟和代理模型预测结果, 得到以下结论.

(1) 基于代理模型的缝内支撑剂铺置形态预测方法能够在保证预测精度的前提下实现支撑剂输送仿真加速、大幅提升计算效率.

(2) 颗粒铺置高度预测代理模型只需识别支撑剂的堆积状态, 能够描述支撑剂铺置形态随泵送排量的演化.

(3) 相比颗粒铺置高度预测代理模型, 颗粒体积分数预测代理模型输入参数更多、训练时常更长, 能够刻画支撑剂悬浮运移等细节、描述支撑剂铺置形态随时间的演化, 预测结果与模拟结果差异更小.

(4) 代理模型的级联特性导致误差是累计的, 可以通过优化数据集或增加训练数据的方法降低误差.

(5) 需要深入探索施工参数与预测目标相关参数的联系, 以施工参数代替支撑剂速度等输入参数, 直接通过施工条件改变预测缝内支撑剂铺置形态.

此外, 仍需继续发展高精度仿真支撑剂输送数值模型, 并基于大量数值模拟结果建立更加全面的数据库以供代理模型训练和完善.

参 考 文 献

- [1] Zheng X Q, He C M, Yang N Y, et al. Volumetric fracturing 2.0 process for unconventional oil and gas reservoirs and R & D suggestions. *Pet Sci Technol Forum*, 2022, 41(3): 1
(郑新权, 何春明, 杨能宇, 等. 非常规油气藏体积压裂 2.0 工艺及发展建议. 石油科技论坛, 2022, 41(3): 1)
- [2] Zhu W Y, Zhang Q T, Yue M, et al. Effect of uneven distribution of proppant in fracture network on exploitation dynamic characteristics. *Chin J Eng*, 2020, 42(10): 1318
(朱维耀, 张启涛, 岳明, 等. 裂缝网络支撑剂非均匀分布对开采动态规律的影响. 工程科学学报, 2020, 42(10): 1318)
- [3] Liu Y X, Zhou H Y, Guo J C, et al. Controlling factors of fracture aperture reduction based on experimental study using proppant pack apparent Young's modulus. *J Pet Sci Eng*, 2022, 208: 109506
- [4] Isah A, Hiba M, Al-Azani K, et al. A comprehensive review of proppant transport in fractured reservoirs: Experimental, numerical, and field aspects. *J Nat Gas Sci Eng*, 2021, 88: 103832
- [5] Guo J C, Zhou H Y, Tang T, et al. Advances of experiment and numerical simulation researches on proppant transport for unconventional reservoir fracturing. *Drill Prod Technol*, 2022, 45(3): 48
(郭建春, 周航宇, 唐堂, 等. 非常规储层压裂支撑剂输送实验及数值模拟研究进展. 钻采工艺, 2022, 45(3): 48)
- [6] Zhang T, Tang T, Guo J C, et al. Quantitative testing method of solid-liquid two-phase for unconventional fracturing proppant transport. *Flow Meas Instrum*, 2023, 93: 102431
- [7] Zhu H Y, Huang C H, Zhang M H, et al. A fracture conductivity model for channel fracturing based on lattice-Boltzmann-method and computational-fluid-dynamics. *J Pet Sci Eng*, 2022, 217: 110903
- [8] Loth E, Dorgan A J. An equation of motion for particles of finite Reynolds number and size. *Environ Fluid Mech*, 2009, 9(2): 187
- [9] Xu C Y, Zhang J Y, Kang Y L, et al. Structural formation and evolution mechanisms of fracture plugging zone. *Pet Explor Dev*, 2021, 48(1): 202
(许成元, 张敬逸, 康毅力, 等. 裂缝封堵层结构形成与演化机制. 石油勘探与开发, 2021, 48(1): 202)
- [10] Mao S W, Siddhamshetty P, Zhang Z, et al. Impact of proppant pumping schedule on well production for slickwater fracturing. *SPE J*, 2021, 26(1): 342
- [11] Luo B, Wong G K, Han Y H. Modeling of dynamic bridging of solid particles in multiple propagating fractures. *Int J Solids Struct*, 2023, 262: 112078
- [12] Khmelenko P, Shel E, Boronin S, et al. Proppant packing near the fracture tip during tip screenout: Asymptotic models for pressure buildup calibrated on field data and verified with two-continua simulations. *SPE J*, 2022, 27(4): 2126
- [13] Zhou J A, Liu C M, Liu Z Q, et al. Numerical simulation on gas-solid two-phase flow in slots of porous plugs. *J Univ Sci Technol Beijing*, 2014, 36(10): 1348

- (周建安, 刘春明, 刘中秋, 等. 喷粉透气砖狭缝内气-固两相流动数值模拟. 北京科技大学学报, 2014, 36(10): 1348)
- [14] Zhou H Y, Zhang T, Guo J C, et al. Drag coefficient modification for proppant transport in fractures considering wall retardation. *Chem Eng Res Des*, 2022, 178: 478
- [15] Brunton S L, Noack B R, Koumoutsakos P. Machine learning for fluid mechanics. *Annu Rev Fluid Mech*, 2020, 52: 477
- [16] Ansari A, Mohaghegh S, Shahnam M, et al. *Data Driven Smart Proxy for CFD: Application of Big Data Analytics & Machine Learning in Computational Fluid Dynamics, Report Three: Model Building at the Layer Level*. Morgantown: US Department of Energy, National Energy Technology Laboratory, 2018
- [17] Hosseini Boosari S S. Predicting the dynamic parameters of multiphase flow in CFD (dam-break simulation) using artificial intelligence-(cascading deployment). *Fluids*, 2019, 4(1): 44
- [18] Liu G Q, Gong R B, Shi Y J, et al. Construction of well logging knowledge graph and intelligent identification method of hydrocarbon-bearing formation. *Pet Explor Dev*, 2022, 49(3): 502 (刘国强, 龚仁彬, 石玉江, 等. 油气层测井知识图谱构建及其智能识别方法. *石油勘探与开发*, 2022, 49(3): 502)
- [19] Zhang K, Chen G D, Xue X M, et al. A reservoir production optimization method based on principal component analysis and surrogate model. *J China Univ Pet (Ed Nat Sci)*, 2020, 44(3): 90 (张凯, 陈国栋, 薛小明, 等. 基于主成分分析和代理模型的油藏生产注采优化方法. *中国石油大学学报(自然科学版)*, 2020, 44(3): 90)
- [20] Zhang L, Dou H E, Wang T Z, et al. A production prediction method of single well in water flooding oilfield based on integrated temporal convolutional network model. *Pet Explor Dev*, 2022, 49(5): 996 (张蕾, 窦宏恩, 王天智, 等. 基于集成时域卷积神经网络模型的水驱油田单井产量预测方法. *石油勘探与开发*, 2022, 49(5): 996)
- [21] Zhou D S, Wang H Y. *A Proppant Laying Pattern Prediction Method Based on BP Neural Network*: China Patent, 201810205015. X, 2022-02-18 (周德胜, 王海洋. 一种基于 BP 神经网络的支撑剂铺置形态预测方法: 中国专利, 201810205015. X, 2022-02-18)
- [22] Zhou H Y, Guo J C, Zhang T, et al. Numerical study of the wall-retardation effect on proppant transport in rough fractures. *Comput Geotech*, 2023, 159: 105425
- [23] Benyahia S, Syamlal M, O'Brien T J. Study of the ability of multiphase continuum models to predict core-annulus flow. *AIChE J*, 2007, 53(10): 2549
- [24] Van Wachem B G M. *Derivation, Implementation, and Validation of Computer Simulation Models for Gas-Solid Fluidized Beds* [Dissertation]. Delft: Delft University of Technology, 2000
- [25] Gidaspow D. *Multiphase Flow and Fluidization: Continuum and Kinetic Theory Descriptions*. Boston: Academic Press, 1994
- [26] Zhou H Y, Guo J C, Zhang T, et al. Eulerian multifluid simulations of proppant transport with different sizes. *Phys Fluids*, 2023, 35(4): 043314
- [27] Johnson P C, Jackson R. Frictional-collisional constitutive relations for granular materials, with application to plane shearing. *J Fluid Mech*, 1987, 176: 67