

DOI:10.3969/j.issn.1003-5060.2025.06.018

## 基于双分支卷积神经网络的气水动态分析

李道伦, 吕茂春, 查文舒, 沈路航

(合肥工业大学 数学学院, 安徽 合肥 230601)

**摘要:**传统气水分析方法主要有数值分析方法、实验模拟法等,但数值分析方法需要大量难以测量的数据,实验模拟法难以表征复杂油气开发现场,为此,文章基于深度学习神经网络提出一种新的气水分析方法。该方法根据气水动态物理模型建立的双分支卷积神经网络分别对排水井和产气井进行建模,个性化表征生产井和排水井的动静态数据;将产气井的气水产量数据作为输出,实现井组动态耦合关联,建立井组气水动态分析的深度学习网络模型。主动排水井组动态生产数据分析表明,该双分支卷积神经网络可实现 3 口生产井的日产气量和日产水量的高质量预测,揭示了主动排水井组中的复杂关联,可进行气水关系动态分析,从而为油气藏工程师提供了一种方便快捷的分析方法。

**关键词:**气水动态分析;主动排水井组;双分支卷积神经网络;日产气;日产水

**中图分类号:**TE331.2;TP183 **文献标志码:**A **文章编号:**1003-5060(2025)06-0828-06

### Gas-water dynamic analysis based on two-branch convolutional neural network

LI Daolun, LYU Maochun, ZHA Wenshu, SHEN Luhang

(School of Mathematics, Hefei University of Technology, Hefei 230601, China)

**Abstract:** Traditional gas-water analysis methods mainly include numerical analysis methods and experimental simulation methods, but numerical analysis methods require a large amount of difficult-to-measure data, and experimental simulation methods are difficult to characterize complex oil and gas development sites. For this reason, this paper proposes a new gas-water analysis method based on deep learning neural networks. Based on the dynamic physical model of gas and water, a two-branch convolutional neural network is established to model drainage well and production well separately, and personalize the dynamic and static data of production and drainage wells; the gas and water production data from the production wells are then used as the output to achieve dynamic coupling and correlation of the well group, thereby building a deep learning network model for the dynamic analysis of gas and water in the well group. The analysis of the dynamic production data of the active drainage well group shows that the two-branch convolutional neural network can achieve high-quality prediction of daily gas and water production of the three production wells. This suggests that the two-branch convolutional neural network can reveal complex correlations of wells in active drainage well group and perform dynamic analysis of gas-water relationships, thus providing a convenient and fast analysis method for oil and gas reservoir engineers.

**Key words:** gas-water dynamic analysis; active drainage well group; two-branch convolutional neural network; daily gas production; daily water production

沉积岩形成过程中普遍存在封存水,在油藏开发的某一阶段,发生水侵灾害具有一定的必然

性。各个气藏之间由于地理特征存在差异,水侵发生的模式也不同,分为突变剧烈影响、渐变显著

收稿日期:2023-03-24;修回日期:2023-05-09

基金项目:国家自然科学基金资助项目(12172115)

作者简介:李道伦(1972—),男,安徽合肥人,博士,合肥工业大学教授,博士生导师。

影响和缓慢影响 3 种<sup>[1]</sup>。当水侵入时,气藏裂缝/地层界面附近流体饱和度增大,严重阻碍气体流动,影响气藏页岩气的采集,因此裂缝存在越活跃,生产井受水侵的影响越大<sup>[2]</sup>。针对不同类型的水侵,最优控水方式也不同,包括堵水<sup>[3]</sup>、动态监测<sup>[4]</sup>和排水采气等。堵水控水方式可分为化学堵水法和机械堵水法<sup>[3]</sup>,这 2 种方式都是通过建立一个阻挡水流入的屏障来控制井水产量。动态监测技术是通过增加水平段长度来控制生产压差,延长气井无水产气周期<sup>[4]</sup>。相比其他 2 种方式,排水采气控水方式更为高效。

早期常用的排水采气技术包括电潜泵排水采气、射流泵排水采气、柱塞气举排水采气等<sup>[5]</sup>。近年来,单井排水技术与气藏工程相结合的主动排水技术开始推广应用,其原理是在已见水的生产井周围单独建立 1 口排水井,形成 1 个排水井组。排水井的作用是将侵入生产井的地下水引流过来排出,从而减缓周围生产井的排水压力<sup>[6]</sup>。

气水关系分析是生产控水过程中不容忽视的一环,传统气水分析方法大多采用实验模拟或数据挖掘等方法。实验模拟方法是通过建立气藏模型直观感受水侵方式。文献[7]利用蚀刻玻璃模型模拟多孔岩石,建立了不同润湿性裂隙吸附模型和不同润湿性驱替模型,研究了水侵过程中气水分布特征的变化情况。文献[8]通过 3D 打印的注水测试岩心模型,对储层中的气和水进行可视化分析。然而,实验模拟方法对实验设备的精度要求很高,不能完全模拟气藏全部特征,对于气水规律的挖掘通过人为观察来获取,无法保证方法准确性。

数值分析方法相较于实验模拟方法可行性更高。文献[9]根据页岩气的产气周期将数据分为几个样本集,针对不同的样本集使用不同的非参数可加性模型来判断不同润湿性区域的气水关系假设是否成立。文献[10]采用非侵入式嵌入式离散裂缝模型结合统计学 Oda 方法,应用新算法在离散裂缝网络中搜索多条连通裂缝迹,通过对它们的总距离进行排序,结合实际水侵特征,有助于模拟和快速匹配相应的水入侵行为。但以上 2 种数值分析方法都存有一定的局限性,不能实现数据特征的自动学习,对潜在气水规律的挖掘能力较弱。常规的数值模拟分析方法需要大量的数据(如渗透率分布、相对渗透率曲线、复杂气水边界等),并且这些数据难以获得,从而影响分析结果的精度。

近年来,深度学习方法在油田开发中的成功应用证明了其具有较高的有效性和准确性<sup>[11]</sup>。文献[12]提出了一种以单源或单汇为边界条件求解多孔渗流方程的物理约束方法,可以很好地利用实测数据反演渗透率;文献[13]提出用卷积神经网络作为无限作用油藏试井自动解释方法;文献[14]提出了一种基于时间卷积神经网络的预测方法,可以学习气藏的投入与产出之间的关系。以上研究验证了深度学习方法在油田数据上的高度适用性。此外,在图像领域中,采用局部特征融合方法从图像中提取特征,并将感兴趣区域的局部微特征作为多输入神经网络的多分支输入,可以减少不完整图像中缺失部分贡献率的影响,提高表情检测的鲁棒性和准确性<sup>[15]</sup>。

基于以上分析,本文提出了一种双分支卷积神经网络模型,分别提取生产井和排水井的数据特征,再进行整合优化,最终得到气水动态分析方法。本文方法增强了对数据特征的学习,提升了预测精度。

## 1 双分支卷积神经网络模型

### 1.1 气田数据

本实验研究数据来自某气藏的主动排水井组,该井组由 1 口排水井和 3 口生产井组成,分别记为排水井 MX0 和生产井 MX1、MX2、MX3。水侵发生后,3 口生产井的产水量迅速增加,产气量和油压明显下降,受水侵影响明显。气水动态分析所使用的动态数据为该井组形成以来排水井的日产水量、油压和 3 口生产井的日产水量、日产气量、油压、井状态,使用的静态数据为生产井的渗透率和孔隙度。

MX1、MX2 和 MX3 的生产情况如图 1 所示。




图 1 MX1、MX2 和 MX3 的生产情况

由图 1 可知,在井组生产的第 340 天左右时,

井组进行了一次集体关井措施,关井前后井组的生产趋势发生变化,MX2、MX3 的日产气量、日产水量与关井前的相比均上升。

考虑以上情况,本实验选择 2 个阶段进行分析。第 1 阶段为排水井投入生产第 0 天至第 335 天,第 2 阶段为排水井投入生产第 370 天至第 450 天。在这 2 个阶段 3 口生产井的生产数据平均值见表 1 所列。

表 1 主动排水井组的日产气量和日产水量平均值

井编号	第 1 阶段		第 2 阶段	
	日产水量/ m <sup>3</sup>	日产气量/ (10 <sup>3</sup> m <sup>3</sup> )	日产水量/ m <sup>3</sup>	日产气量/ (10 <sup>3</sup> m <sup>3</sup> )
MX0	341.285		197.335	
MX1	99.333	19.261	104.892	19.688
MX2	111.415	1.850	159.845	2.654
MX3	157.331	15.115	139.627	16.463

由表 1 可知:MX1 的日产气量平均值最高,

日产水量平均值最低,因此 MX1 受水侵危害最小;MX2 在 2 个阶段的日产气量平均值都较小,说明 MX2 的生产已经接近枯竭期。

### 1.2 双分支卷积神经网络模型的构建

#### 1.2.1 模型框架

卷积神经网络是一种前馈传播神经网络,在大面积的图像处理上表现优异。本文提出的双分支卷积神经网络模型是在普通卷积神经网络模型的基础上添加了输入分支和联结层。模型具体框架如图 2 所示,该模型由 1 个输入层、7 个隐藏层和 1 个输出层组成,其中 7 个隐藏层分别由 3 个双分支一维卷积层(Convolution 1D, Conv 1D)、1 个联结层(Concatenate)和 3 个全连接层(Dense)组成。每个网络层包括 BN 层、激活函数层和残差结构。其中一个分支的输入数据分别为排水井的油压、日产水量、生产日期;另一个分支的输入数据为 3 口生产井的组合数据,输出为 3 口生产井的日产气量和日产水量。

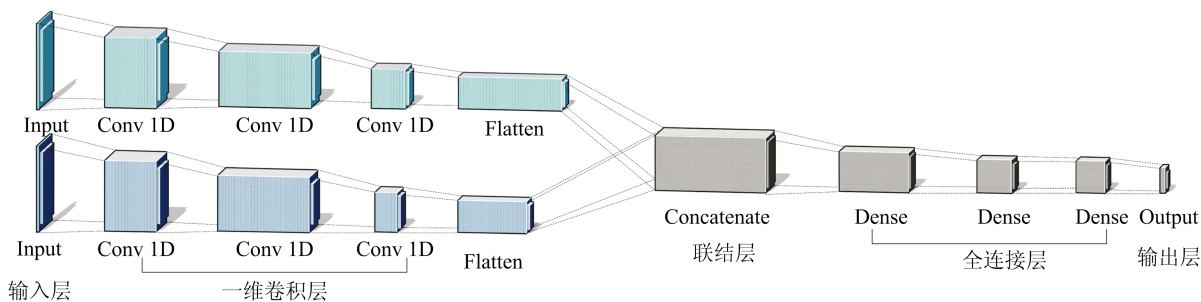


图 2 模型框架

#### 1.2.2 模型流程

该模型的具体流程如图 3 所示。

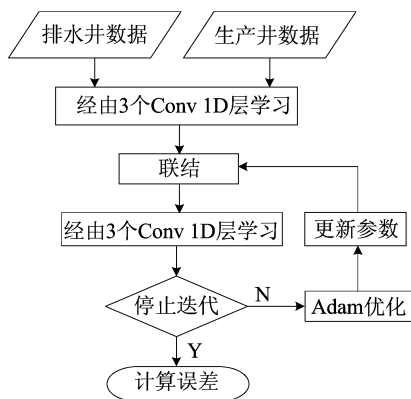


图 3 模型流程

由图 2 可知,该模型的前向计算过程分 2 个阶段。第 1 阶段在联结层之前,模型的 2 个输入

分支同时进行前向计算过程,分别学习生产井和排水井的数据特征;第 2 阶段,数据经过联结层后变为 1 个分支进行学习,在设置好的迭代次数结束前,模型使用 Adam 优化器进行迭代,更新网络模型中的所有可学习参数。

#### 1.2.3 数据输入变换

模型使用的排水井数据只与排水井本身相关,而学习的生产井数据单个数据只与单个井相关,因此本实验对每口生产井的动态渗透率  $K_D$ 、基质渗透率  $K_B$ 、孔隙度  $\mu$ 、油压  $P$ 、井状态  $S$ (是否关井)进行组合,形式为:

$$I^i = \frac{K_D^i}{K_B^i} \mu^i P^i S^i, \quad i = 1, 2, 3 \quad (1)$$

其中: $I^i$  分别表示 MX1、MX2、MX3 的组合数据; $S$ (是否关井)表示该生产井当日是否关井,关井则  $S$  为 0,否则为 1。

### 1.2.4 样本设置

为了分析生产井组中生产井对排水井的敏感性,该模型设置其他样本来预测在不同的产水量情况下生产井的日产水量、日产气量。该实验共设置 3 个样本集,分别为真实集、预测集 1、预测集 2,具体设置见表 2 所列。这 3 个样本集除了排水井的日产水数据有改变,其余数据不变。

表 2 样本集设置

样本集	分支 1	分支 2
真实集	排水井的日产水量、油压、生产日期	$I^1, I^2, I^3$
预测集 1	排水井的油压、生产日期、日产水量减少 50 m <sup>3</sup>	$I^1, I^2, I^3$
预测集 2	排水井的油压、生产日期、日产水量增加 5 m <sup>3</sup>	$I^1, I^2, I^3$

模型学习真实集中的气水规律,再对预测集 1 和预测集 2 中的产水情况做出预测,分析在该情况下生产井的日产水量和日产气量。

### 1.3 模型参数设置

模型使用的误差函数为均方误差 (mean square error, MSE) 和平均绝对误差 (mean absolute percentage error, MAPE), 计算公式如下:

$$E_{MS} = \frac{1}{N} \sum_{t=1}^N (Y_t - y_t)^2 \quad (2)$$

$$E_{MAP} = \frac{1}{N} \sum_{t=1}^N \left| \frac{Y_t - y_t}{Y_t} \right| \quad (3)$$

其中:  $N$  为样本数;  $y_t$  和  $Y_t$  分别为预测值和真实值。

模型训练使用的参数设置如下: 一个分支的模型单位为 18、32、12, 另一个分支的为 12、32、8, 双分支的为 20、64、18、6; 第 1 阶段模型设置的最佳迭代次数为 300, 第 2 阶段的最佳迭代次数为 600; 模型的双分支 Conv 1D 层使用 ReLU 激活函数, Dense 层使用 Swish 激活函数; 利用 Adam 优化器进行参数更新。

## 2 实验数据处理及实验过程

### 2.1 评价指标设置

为了直观分析生产井组中生产井对排水井的敏感性, 实验设置评价因子  $E_F$ :

$$E_F = \frac{1}{N} \sum_{t=1}^N \frac{Y_t - y}{\bar{Y}} \quad (4)$$

其中,  $\bar{Y}$  为排水井该阶段真实均值。

当  $E_F$  为负值时, 表示排水井对生产井的生产起到抑制作用; 当  $E_F$  为正值时, 说明排水井对

生产井的生产起到促进作用;  $E_F$  的绝对值表示生产井对排水井的敏感性程度。

### 2.2 气水动态分析

本实验利用 TensorFlow 框架构建模型结构, 对设备要求较低, 使用 CPU 训练即可快速完成训练, 可实施性较高。

#### 2.2.1 第 1 阶段气水动态分析

第 1 阶段 3 口生产井的日产气量和日产水量  $E_F$  值见表 3 所列。由表 3 可知: 当输入样本集为预测集 2 时, 3 口生产井的日产水量  $E_F$  值均为负值, 日产气量  $E_F$  值均为正值; 当输入样本集为预测集 1 时, 3 口生产井的日产水量  $E_F$  值都为正值, 日产气量  $E_F$  值均为负值。说明排水井的建立有利于缓解生产井的水侵问题, 提高采收率。

表 3 第 1 阶段生产井日产气量、日产水量的  $E_F$  值

井编号	预测集 1		预测集 2	
	日产水量	日产气量	日产水量	日产气量
MX1	1.817	-0.312	-1.289	0.312
MX2	2.441	-0.541	-3.330	0.270
MX3	2.126	-1.919	-2.368	1.852

根据  $E_F$  的绝对值大小可知, MX1 的日产气量和日产水量对排水井的敏感性都最小, MX2 日产水量的  $E_F$  绝对值高于 MX3 的, 而日产气量的  $E_F$  绝对值低于 MX3 的。结合前文可知, MX2 是低产气量井, 已经进入了生产枯竭期, MX1 是受水侵危害最小的井, 表明生产井对排水井的敏感性与其受水侵程度和地质储量有关。

#### 2.2.2 第 2 阶段气水动态分析

第 2 阶段 3 口生产井的日产气量和日产水量  $E_F$  值见表 4 所列。由表 4 可知: 在井组进行过一次集体关井且排水井无法降低生产井产水量的情况下, 当输入样本集为预测集 2 时, 3 口生产井的日产水量  $E_F$  值均为正值, 但绝对值小于第 1 阶段的; MX2 和 MX3 的日产气量  $E_F$  绝对值与第 1 阶段的相比有所上升, MX1 的日产气量  $E_F$  绝对值与第 1 阶段的接近。其中, MX3 的日产气量  $E_F$  绝对值在 2 个阶段均是最大的, MX1 的日产水量  $E_F$  绝对值在 2 个阶段均最大。

结合上述气水动态分析可以发现, 排水井的建立可以促进 MX1、MX2 和 MX3 的产气量, 减少其产水量。结合主动排水井组的生产情况可知, MX1 本身产气量高、产水量低, MX3 日产水量大, 说明 MX1 受水侵破坏较小, 而 MX3 受水侵影响较大, MX0 的建立对 MX1 的影响有限。

此外, MX2 投产时间最长, 原有日产气量较低, 对 MX0 的敏感性也比 MX3 的小。这说明生产井对排水井的敏感性与生产井本身的储量、水侵程度有关。由以上分析可知, 3 口生产井对排水井的敏感性排序从大到小依次为 MX3、MX2、MX1。

表 4 第 2 阶段生产井日产气量、日产水量的  $E_F$  值

井编号	预测集 1		预测集 2	
	日产水量	日产气量	日产水量	日产气量
MX1	-0.767	-0.415	0.753	0.493
MX2	-0.316	-0.529	0.322	0.931
MX3	-0.415	-1.430	0.440	1.587

### 2.3 模型拟合结果分析

实验模型在第 2 阶段对 MX1 和 MX3 的日产水量拟合情况如图 4 所示。




图 4 第 2 阶段 MX1 和 MX3 日产水量拟合及预测结果

根据 2.2 节可知, MX2 在第 2 阶段对于排水井的敏感性几乎消失, 因此不再作拟合效果分析。实验设置的预测集大小为整个样本集的 0.16 倍, 即长度为 300 的输入集中, 末尾的 48 个数据集将被用作预测集, 图中蓝色竖线划分预测集 1 和预测集 2。预测集结果表明, 该双分支卷积神经网络模型对于生产井的日产水量及其趋势有很好的预测效果。

## 3 结 论

本文提出了一种双分支卷积神经网络模型, 对主动排气井组进行气水动态分析, 所得结论如下:

1) 所提出的双分支卷积神经网络可有效对井组动态进行建模, 一个双分支卷积神经网络对井组动态数据的拟合精度高, 说明该模型可对井组流动状态进行很好的模拟。该模型可对不同阶段的气水动态进行分析, 对 3 口生产井的日产气量、日产水量进行很好预测。

2) 当 MX0 排水能力增强, MX1 和 MX3 的日产气量预计增加, 日产水量预测减少, 而 MX2 在第 2 阶段预测不再受益于排水井。这说明排水井的建立有助于生产井组缓解水侵危害, 提高采收率, 但影响程度有限。

3) 双分支卷积神经网络为井组气水动态分析提供了一种有效、快捷分析方法, 有很好的应用前景。

### [参 考 文 献]

- [1] 冯曦, 钟兵, 杨学锋, 等. 有效治理气藏开发过程中水侵影响的问题及认识[J]. 天然气工业, 2015, 35(2): 35-40.
- [2] HU Z, DUAN X, HE Y, et al. Influence of reservoir primary water on shale gas occurrence and flow capacity[J]. Natural Gas Industry B, 2019, 6(1): 71-78.
- [3] TAHA A, AMANI M. Overview of water shutoff operations in oil and gas wells: chemical and mechanical solutions [J]. Chem Engineering, 2019, 3(2): 51.
- [4] YANG Y, GU D, LIAN Y, et al. Mechanisms and prevention & control countermeasures of water breakthrough in horizontal wells in multi-layer unconsolidated sandstone gas reservoirs: a case study of the Tainan Gas Field in the Qaidam Basin[J]. Natural Gas Industry B, 2019, 6(6): 564-571.
- [5] 魏纳, 刘安琪, 刘永辉, 等. 排水采气工艺技术新进展[J]. 新疆石油天然气, 2006(2): 78-81, 101-102.
- [6] 阮基富, 欧家强, 周莲莲, 等. 磨溪龙王庙组气藏水侵模式及治水关键技术[C]//第 32 届全国天然气学术年会(2020)论文集. 重庆: 中国石油学会天然气专业委员会, 2020: 777-785.
- [7] GUO P, ZHOU R, TIAN Z, et al. Gas and water distribution characteristics of water-driven gas process in tight sandstone gas reservoirs: a microscale study by molecular simulation and experiment[J]. Energy Reports, 2022, 8: 7025-7036.
- [8] PENG S. Gas-water relative permeability of unconventional reservoir rocks: hysteresis and influence on production after shut-in[J]. Journal of Natural Gas Science and Engineering, 2020, 82: 103511.

(下转第 838 页)

由图 5 可知,该算法计算所得的残差分布基本符合正态分布,其残差值可能受随机误差的影响。

#### 4 结 论

本文提出一种联合 FAST 算法和双像光束法平差的相机标定方法。首先通过 FAST 算法自动提取像片标志点的像素坐标,并基于人工辅助方式纠正少量错误点;然后利用直接线性变换法解得相机的内、外参数及畸变系数的初值;最后将该初值代入将基线长度约束条件纳入平差模型考虑的光束法平差计算中进行解算,并采用分类阈值的方法提高模型迭代计算的收敛效率,获得更高精度的相机内、外参数及畸变系数。结果表明该方法的精度高于普通的双像光束法平差,具有较快的收敛速度,可以应用于高精度的相机标定工作。

#### [参 考 文 献]

- [1] ABDEL-AZIZ Y I. Photogrammetric potentials of non-metric cameras[D]. Illinois: University of Illinois at Urbana-Champaign, 1974.
- [2] 张永军,张祖勋,张剑清. 利用二维 DLT 及光束法平差进行数字摄像机标定[J]. 武汉大学学报(信息科学版), 2002, 27(6): 566-571.
- [3] ZHAO Z, YE D, ZHANG X, et al. Improved direct linear transformation for parameter decoupling in camera calibration[J]. Algorithms, 2016, 9(2): 31.
- [4] BARONE F, MARRAZZO M, OTON C J. Camera calibration with weighted direct linear transformation and anisotropic uncertainties of image control points[J]. Sensors, 2020, 20(4): 1175.
- [5] 付兵杰,赵双明,喻国荣,等. 一种无需控制信息的智能手机自检校方法[J]. 武汉大学学报(信息科学版), 2019, 44(2): 268-275, 282.
- [6] ZHANG C S, ZHU S H, ZHANG Y F, et al. GPS-supported bundle adjustment method of UAV by considering exposure delay[J]. Acta Geodaetica et Cartographica Sinica, 2017, 46(5): 565.
- [7] DABEER O, DING W, GOWAIKER R, et al. An end-to-end system for crowdsourced 3D maps for autonomous vehicles: The mapping component[C]//2017 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS). Vancouver: IEEE, 2017: 634-641.
- [8] YANG S, SONG Y, KAESS M, et al. Pop-up slam: Semantic monocular plane slam for low-texture environments[C]//2016 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS). Daejeon: IEEE, 2016: 1222-1229.
- [9] 赵帅华,李言言,曹健,等. 基于 BFGS 修正的高斯牛顿光束法平差解算方法[J]. 北京大学学报(自然科学版), 2020, 56(6): 1013-1019.
- [10] LEPETIT V, FUA P. Keypoint recognition using randomized trees[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2006, 28(9): 1465-1479.
- [11] 贾迪,朱宁丹,杨宁华,等. 图像匹配方法研究综述[J]. 中国图像图形学报, 2019, 24(5): 677-699.
- [12] 张绍荣,张闻宇,李云,等. 基于 FAST 角点和 FREAK 描述符改进的无人机景象匹配算法[J]. 电子测量与仪器学报, 2020, 34(4): 102-110.
- [13] ROSTEN E, DRUMMOND T. Machine learning for high-speed corner detection [C]//Computer Vision-ECCV 2006: 9th European Conference on Computer Vision. Heidelberg: Springer, 2006: 430-443.
- [9] ZHOU Q, WANG J Y, XIAO Y. Identification and illustration of relationships between produced gas and water in marcellus under different spatial and temporal domains through data-driven analytics-Nonparametric model [J]. Journal of Petroleum Science and Engineering, 2020, 184: 106434.
- [10] CHEN P, FIALLOS-TORRES M, XING Y, et al. Water intrusion characterization in naturally fractured gas reservoir based on spatial DFN connectivity analysis[J]. Energies, 2020, 13(16): 4235.
- [11] 查文舒,李道伦,沈路航,等. 基于神经网络的偏微分方程求解方法研究综述[J]. 力学学报, 2022, 54(3): 543-556.
- [12] SHEN L H, LI D L, ZHA W S, et al. Surrogate modeling for porous flow using deep neural networks[J]. Journal of Petroleum Science and Engineering, 2022, 213: 110460.
- [13] LIU X L, LI D L, YANG J, et al. Automatic well test interpretation based on convolutional neural network for infinite reservoir[J]. Journal of Petroleum Science and Engineering, 2020, 195: 107618.
- [14] LI D L, WANG Z Q, ZHA W S, et al. Predicting production-rate using wellhead pressure for shale gas well based on Temporal Convolutional Network[J]. Journal of Petroleum Science and Engineering, 2022, 216: 110644.
- [15] WANG A, LIU D, ZHAO W. An expression detection technique based on multi-input convolutional neural network for incomplete face images[C]//2021 IEEE International Conference on Artificial Intelligence and Industrial Design (AIID). [S. l.]: IEEE, 2021: 211-216.

(责任编辑 吴 亮)

(责任编辑 闫杏丽)

(上接第 832 页)