

DOI:10.3969/j.issn.1003-5060.2025.08.017

## 基于深度学习的渗流方程求解方法

郭布民<sup>1,2</sup>, 徐延涛<sup>1,2</sup>, 武广瑗<sup>3</sup>, 张雯<sup>1,2</sup>, 杨浩<sup>1,2</sup>,  
王金伟<sup>1,2</sup>, 王倩<sup>4</sup>, 李道伦<sup>4</sup>

(1. 中海油田服务股份有限公司, 天津 300459; 2. 天津市海洋石油难动用储量开采企业重点实验室, 天津 300459; 3. 中海油研究总院有限责任公司, 北京 100029; 4. 合肥工业大学 数学学院, 安徽 合肥 230601)

**摘要:** 基于深度学习的正演与反演是当前研究热点, 而渗流方程是描述流体在多孔介质中运动的数学模型, 该方程存在非线性和源汇项, 给深度学习求解带来了很大挑战。文章提出基于物理约束的深度学习渗流方程求解方法, 并将其应用在油藏参数反演中。针对非线性强和源汇项的问题, 提出多级残差框架用于学习井周围压力变化特征, 从而更好地符合物理规律; 对输入的时间与空间坐标进行非线性变换, 引入自适应参数, 增加网络的灵活性和模型的表达能力, 实现渗流方程的智能求解。该求解方法仅依赖于井底的压力数据, 无需传统的数值计算即可实现正演与参数高效反演。数值实验结果表明, 无论在均质储层还是在非均质油藏中, 该方法都能够精确求解变井流量条件下的井底压力, 并有效反演出储层中的多个参数。

**关键词:** 深度学习; 自动反演; 物理约束; 非均质油藏; 多参数反演

中图分类号: O241

文献标志码: A

文章编号: 1003-5060(2025)08-1117-08

## Solving seepage equation based on deep learning

GUO Bumin<sup>1,2</sup>, XU Yantao<sup>1,2</sup>, WU Guang' ai<sup>3</sup>, ZHANG Wen<sup>1,2</sup>,  
YANG Hao<sup>1,2</sup>, WANG Jinwei<sup>1,2</sup>, WANG Qian<sup>4</sup>, LI Daolun<sup>4</sup>

(1. China Oilfield Services Limited, Tianjin 300459, China; 2. Tianjin Enterprise Key Laboratory of Offshore Oil Difficult-to-Produce Reserves Exploitation, Tianjin 300459, China; 3. CNOOC Research Institute Co., Ltd., Beijing 100029, China; 4. School of Mathematics, Hefei University of Technology, Hefei 230601, China)

**Abstract:** Deep learning-based forward and inverse modeling is currently a research hotspot. The seepage equation is a mathematical model describing the motions of fluids in porous media, and it has nonlinearities and source-sink terms, which brings great challenges to deep learning solution. In this paper, a physical constraint-based deep learning method for solving the seepage equation is proposed and applied to the reservoir parameter inversion. Aiming at the problem of strong nonlinearity and source-sink terms, a multilevel residual framework is proposed for learning the pressure change characteristics around the wells so as to better conform to the physical laws. By nonlinear transformation of the input temporal and spatial coordinates and introducing adaptive parameters to increase the flexibility of the network and the expressive ability of the model, the seepage equation can be intelligently solved. This solution method only relies on the bottomhole pressure data, without the need for traditional numerical calculations, and can achieve the forward modeling and parameter inversion with high efficiency. Results of numerical experiments show that the method can accurately solve the bottomhole pressure under variable well flow rates and effectively invert multiple reservoir parameters, whether in homogeneous or heterogeneous reservoirs.

**Key words:** deep learning; automatic inversion; physical constraints; heterogeneous reservoir; multiparameter inversion

收稿日期: 2024-09-09; 修回日期: 2024-10-29

基金项目: 国家自然科学基金资助项目(12172115; 12372244)

作者简介: 郭布民(1982—), 男, 山东聊城人, 中海油田服务股份有限公司高级工程师;

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, 通信作者, E-mail: lidaol@hfut.edu.cn.

偏微分方程的求解方法主要分为解析求解方法和数值求解方法两类,近几年基于深度学习的智能求解方法成为新的研究热点。传统的数值求解方法(包括有限差分法、有限元法和有限体积法)需要对求解区域进行网格划分,并将偏微分方程离散化成方程组,这在处理复杂几何形状或非标准边界条件时面临挑战,同时也需要考虑计算效率和算法复杂度的问题。相较之下,智能求解方法能更好地应对这些挑战<sup>[1-3]</sup>。

在智能求解方面,文献[4]提出了一种物理信息神经网络,可用于偏微分方程求解和参数反演,通过加入控制方程、边界条件等物理约束,使得求解与反演结果更具物理意义;文献[5]在双相介质理论的基础上,用前馈神经网络与岩石物理模型相结合的方式,反演出储层的孔隙度、饱和度、压力等参数,提高储层反演的精度;文献[6]用 2 个多层前馈神经网络模型结合物理约束,有效反演了油藏的孔隙度、页岩体积和水饱和度;文献[7]用 Biot 理论生成数据,用深度神经网络模型有效地反演孔隙度、固体矩阵的体积模量和剪切模量等参数;文献[8]加入硬约束条件来改进物理信息神经网络,提高求解和参数反演的性能,从而提高计算效率。因此,在数据驱动方法中融入物理约束,能够有效耦合正演与反演过程,从而显著提升求解精度和反演结果的可靠性。

上述方法通常在稳态、均质等较简单的问题下适用,而对于复杂方法往往需要使用大量标签,尤其是对于具有源汇项等强非线性边界的渗流问题处理效果不佳<sup>[9]</sup>。此外,实际油藏只有井的流量和压力是可以测量的。因此,在少量可测量数据的基础上,用深度学习方法求解渗流方程,是实现油气藏参数反演的关键。文献[10]基于残差与多级逼近思想,通过添加一个额外的神经网络逼近源汇项,在仅使用少量井底压力数据的情况下,不仅能有效计算储层压力分布,还能反演渗透率;文献[11]基于多级残差逼近的思想,将其拓展到多参数反演,并通过在主网络输入中添加自适应参数加速模型收敛,然而此方法稳定性不强,需频繁调整超参数,并且没有考虑变流量的情况。深度学习方法能求解渗流方程,实现正演与反演功能,在试井、生产数据分析、油藏数值模拟中带来全新的技术革命。

除此之外,基于深度学习求解渗流方程的方法还能实现地层参数反演,试井与生产数据分析是常见的 2 种反求地层参数方法,有助于提升油

气生产效率和经济效益。现代试井方法通常采用典型曲线作为工具,考虑了井储和表皮对井底压力的影响<sup>[12]</sup>,能更好地分析早期数据。文献[13]将无因次井储系数与表皮系数组合在一起,以无因次压力为纵坐标,以无因次时间和的比值为横坐标绘制双对数曲线,制作了 Gringarten 图版;文献[14]用 Blasingame 型曲线图版拟合生产数据反求渗透率、裂缝半长等参数;文献[15]用递减曲线图版拟合方法有效获得储层参数。然而,现代试井方法对于多相流、非均质性、复杂边界等复杂情况无法解释。

对此,数值试井方法被用于实现对生产历史、井组、井网的模拟及解释<sup>[16-17]</sup>。文献[18]引入动边界概念并用积分方法求解渗流偏微分方程,确定裂缝长度、地层渗透率等参数。数值试井可对不同的油藏结构、地质条件以及流体特征制定具体方案,有效提升了解释精度;然而数值试井也面临着参数不确定、计算时间长等困难,并且通常需要试井人员具备丰富的经验和专业的理论知识,这也限制了其应用范围。

近年来,深度学习技术作为一种强大的工具得到广泛关注。在油藏领域,主要使用数据驱动的深度学习方法,此类方法首先通过人工标注或者模拟器生成大量标签,然后学习标签建立代理模型,从而实现试井解释、历史拟合等功能。文献[19]将双对数曲线中压力数据与压力导数数据作为卷积神经网络的输入,先后建立了多种试井解释模型和油藏识别模型;文献[20-23]用粒子群算法与深度自编码器获取最优网络参数,进行油藏历史拟合,提高反演参数精度;文献[24]将卷积神经网络(convolutional neural network, CNN)、门控循环单元(gated recurrent unit, GRU)与自回归神经网络结合,提出 ConvGRU-AR-Net 模型进行油藏历史拟合,并通过迁移学习解决油藏历史拟合的时效性。然而,此类方法往往需大量标签数据,且要求标签数据的质量高,否则会影响参数反演的效果且缺乏物理意义,不能反映模型参数与模型输出之间的因果关系,这也导致其应用受限。

无论试井分析、生产数据分析还是油藏数值模拟,深度学习在参数反演中的应用过程都是常规的正演方法,起到代理模型的作用,其本质是替换常规的多项式或其他类似的方法<sup>[25]</sup>。

本文提出多级-物理残差神经网络(multi-level physics residual neural network, ML-

PRNN)方法来解决变流量下渗流中的多参数反演问题。由于单个残差块的网络进行多参数反演时网络无法学习到数据的特征,本文方法通过加入多个残差块以增强网络的表达能力和灵活性,避免残差网络的局部最优或退化现象;通过在输入数据中加入  $\varphi = \sqrt{\Delta t} = \sqrt{t_i - t_0}$  ( $t_0$  表示流量发生变化的时刻,  $t_i$  表示流量变化后的时间点),使网络更好地学习流量变化时井底压力的变化;在井周围井底压力呈指数变化,引入对数变化将其变为线性变化,从而更准确地捕获输入数据的复杂空间与时间的关系,提高特征提取能力,改善网络性能;本文方法还将自适应参数引入到残差网络的输入中,加速网络收敛,有效提升反演效果以及网络适应能力。

## 1 渗流方程智能求解

### 1.1 智能求解方法概述

一般地,偏微分方程的表达形式为:

$$F(x, y, t, K, u, u_x, u_y, u_t, u_{xx}, u_{yy}, \dots) = 0 \quad (1)$$

其中:  $x, y, t$  分别表示空间坐标和时间坐标,  $x, y \in \Omega_f, t \in [0, T]$ ;  $K = \{k_1, k_2, \dots, k_n\}$  为所需反演参数的集合,  $k_i$  是偏导数前的系数等;  $u = u(x, y, t)$  为关于  $x, y, t$  的函数;  $u_x, u_y, u_t$  分别为  $u$  对  $x, y, t$  的一阶偏导数。

边界条件和初始条件分别为:

$$B(x, y, t, K, u) = 0, \quad x, y \in \partial\Omega_f, \quad t \in [0, T] \quad (2)$$

$$I(x, y, 0, u) = 0, \quad x, y \in \Omega_f \quad (3)$$

值得注意的是,边界条件中也可包含待反演的参数。

在物理约束方法中,除了使用标签约束,还将控制方程、边界条件、初始条件等构造的残差添加到损失函数中,并且通过训练找到一组最优的网络参数使得残差最小化,则损失函数可表示如下:

$$L_{\text{loss}}(W, b) = || F(x, y, t, K, \hat{u}) ||_2 + || B(x, y, t, K, \hat{u}) ||_2 + || I(x, y, 0, \hat{u}) ||_2 + || u - \hat{u} ||_2 \quad (4)$$

$$W^*, b^* = \text{argmin} L_{\text{loss}}(W, b) \quad (5)$$

其中:  $\hat{u} \triangleq \hat{u}(x, y, t; W, b)$  表示神经网络的预测;  $u$  表示标签数据。

储层反演问题作为一个高维问题,往往需要大量的标签数据,否则神经网络易陷入局部最小值,特别是对于 Neumann 边界问题,需要频繁对模型进行权重调整才能保证稳定的收敛。因此,如何在少量标签下实现高精度反演是一个挑战。

### 1.2 ML-PRNN 智能求解方法

#### 1.2.1 单相渗流方程

对于矩形油藏,单相渗流方程可表示为:

$$\nabla \cdot \left[ \frac{K}{\mu B} (\nabla p) \right] = \left( \varphi \frac{C_f}{B_{\text{ref}}} + \varphi_{\text{ref}} \frac{C_r}{B} \right) \frac{\partial p}{\partial t} \quad (6)$$

其中:  $x, y \in \Omega_f, t \in [0, T]$ ;  $C_f, C_r$  分别为流体压缩系数和岩石压缩系数;  $K$  为渗透率;  $\mu$  为黏度;  $B_{\text{ref}}, \varphi_{\text{ref}}$  分别为地层体积系数和孔隙度。

对应的内边界条件、初始条件和外边界条件分别为:

$$Q - C \frac{\partial p}{\partial t} = \frac{2\pi Kh}{\mu B [\ln(r_e/r_w) + S]} [p(t, r_e) - p_{\text{wf}}] \quad (7)$$

$$p(x, y, t) = p_0, \quad x, y \in \Omega_f, t = 0 \quad (8)$$

$$\left. \frac{\partial p}{\partial x} \right| + \left. \frac{\partial p}{\partial y} \right| = 0, \quad x, y \in \partial\Omega_B \quad (9)$$

其中:  $\Omega_f$  表示储藏区域;  $r_w$  为井半径,  $r_w \in \Omega_R, \Omega_R$  是井半径  $r_w$  所围成的区域;  $r_e = \alpha r_w, \alpha > 1$  是井半径的常数倍,  $r_e \in \Omega_{eR}, \Omega_{eR}$  是  $r_e$  所围成的区域;  $Q$  为流量;  $C$  为井筒存储常量;  $S$  为表皮因子;  $h$  为地层有效厚度;  $p_{\text{wf}}$  为井底压力。

对于式(6)~(9),流体压缩项和岩石压缩项如下:

$$B = \frac{B_{\text{ref}}}{1 + C_f(p - p_{\text{ref}})} \quad (10)$$

$$\varphi = \varphi_{\text{ref}} [1 + C_r(p - p_{\text{ref}})] \quad (11)$$

#### 1.2.2 ML-PRNN 方法

ML-PRNN 方法由多个残差网络组成,如图 1 所示。

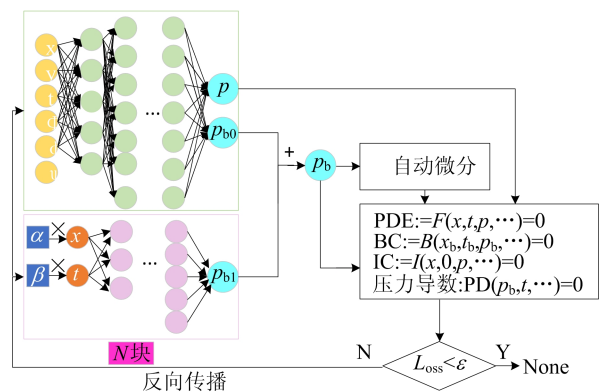


图 1 ML-PRNN 的框架

除了将时空数据输入网络中,  $\varphi, \phi, \psi$  也作为输入。其中:  $\varphi = \sqrt{\Delta t}, \Delta t = t_i - t_0, t_0$  表示流量发生变化的时刻,  $t_i$  表示流量变化后的时间点;  $\phi = \ln r = \ln(\sqrt{x^2 + y^2})$ , 使得坐标分布更加平滑和对

称,有利于网络在训练过程中更好地适应和学习特征之间的关系; $\psi = e^{\delta(r_w - r)}$ 作为输入可以进一步增强输入特征的显著性,增强变化剧烈的井周围压力的学习, $\delta$ 为正的常数。

同时在输入中乘以自适应参数, $\alpha, \beta$ 作为引入的自适应参数可以增加网络的灵活性和表达能力,提高参数调节的自动化程度,并增强模型的适应能力和泛化能力。

### 1.2.3 损失函数

根据方程(6)~(9)构造残差函数,即

$$f := \left( \varphi \frac{C_f}{B_{\text{ref}}} + \varphi_{\text{ref}} \frac{C_r}{B} \right) \frac{\partial p}{\partial t} - \nabla \cdot \left[ \frac{K}{\mu B} (\nabla p) \right] \quad (12)$$

$$P_w := p(t, r_e) - p_{\text{wf}} - \frac{(Q - C) \frac{\partial p}{\partial t} \mu B \left[ \ln \frac{r_e}{r_w} + S \right]}{2\pi K h} \quad (13)$$

$$f_b := \left| \frac{\partial p}{\partial x} \right| + \left| \frac{\partial p}{\partial y} \right| \quad (14)$$

结合压力变化的特点,同时帮助网络快速找到梯度下降的方向,加快网络的收敛,将网络输出 $\hat{p}$ 代入物理损失,这些损失分别为方程损失 $L_{\text{MSE}_f}$ 、内边界损失 $L_{\text{MSE}_{\text{Inner}}}$ 、外边界损失 $L_{\text{MSE}_{\text{Outer}}}$ 和初始条件损失 $L_{\text{MSE}_{\text{IC}}}$ ,则有:

$$L_{\text{MSE}_f} = \frac{\lambda_a}{N_f} \sum_{i=1}^{N_f} |f(t^i, x^i, y^i, \hat{p}^i)|^2 \quad (15)$$

$$L_{\text{MSE}_{\text{Inner}}} = \frac{\lambda_b}{N_b} \sum_{i=1}^{N_b} |P_w(t^i, r^i, \hat{p}^i)|^2 \quad (16)$$

$$L_{\text{MSE}_{\text{Outer}}} = \frac{\lambda_d}{N_f} \sum_{i=1}^{N_f} |f_b(t^i, x^i, y^i, \hat{p}^i)|^2 \quad (17)$$

$$L_{\text{MSE}_{\text{IC}}} = \frac{\lambda_e}{N_I} \sum_{i=1}^{N_I} |\hat{p}_0^i - p_0|^2 \quad (18)$$

在进行参数反演的过程中,不可忽略一个问题就是它们存在多解的情况,井底压力导数(pressure derivative)可以增加新的约束,让神经网络更好地学习特征信息。

因此,在损失函数中加入压力导数,不仅可以提高反演精度,还在一定程度上缓解了多参数反演中多解性的情况。

压力导数计算公式如下:

$$p'_d = \frac{p_i - p_{i-1}}{t_i - t_{i-1}} t_i \quad (19)$$

其中, $p_i$ 为 $t_i$ 时刻对应的压力。根据井底压力标签 $p$ 构造压力导数的标签 $p_d$ ,则基于标签数据的损失如下:

$$L_{\text{MSE}_{\text{Data}}} = \frac{\lambda_{f_1}}{N_b} \sum_{i=1}^{N_b} |\hat{p}^i - p^i|^2 + \frac{\lambda_{f_2}}{N_b} \sum_{i=1}^{N_b} |\hat{p}_d^i - p_d^i|^2 + \frac{1}{N_f} \sum_{i=1}^{N_f} |\max(0, \hat{p}(t^i, x^i, y^i) - \hat{p}(t^i, r_w))|^2 \quad (20)$$

其中, $\hat{p}$ 为网络输出的压力值。在实验过程中发现预测出的井底压力有时会小于标签数据,为了解决这个问题,在 $L_{\text{MSE}_{\text{Data}}}$ 中加入惩罚项,当预测的压力小于井底压力时,让损失值变大,通过加入惩罚项,使得网络输出更加稳定。

由式(15)~(18)和式(20)得到最终的损失函数为:

$$L_{\text{oss}} = L_{\text{MSE}_f} + L_{\text{MSE}_{\text{Inner}}} + L_{\text{MSE}_{\text{Outer}}} + L_{\text{MSE}_{\text{IC}}} + L_{\text{MSE}_{\text{Data}}} \quad (21)$$

因为本文采用有量纲的算例,在计算均方误差时损失函数组成的项之间的数量级差别很大,所以选取合适的权重 $\lambda$ 可以平衡损失函数之间的数量级,从而平衡损失函数各项之间的贡献程度。

## 2 ML-PRNN 方法反演实验

ML-PRNN 方法对多个储层参数准确反演是本研究的核心。分别在均质储藏和非均质储藏参数反演中验证该方法的有效性,实验由 PEBI 网格下的数值试井软件生成<sup>[26-28]</sup>。该软件在 2005 年开发并且广泛运用于大庆油田、长庆油田等油田。本文实验均使用 PyTorch 框架。

### 2.1 均质油藏算例

本实验选取 400 m×400 m 的矩形均质油藏作为案例 1,储层中心是一口半径 $r_w = 0.1$  m 的生产井,如图 2 所示。




图 2 案例 1 均质油藏储层示意图

均质油藏案例的相关参数见表 1 所列。并具有 2 个阶段流量:0~10 d 井流量为 100 m<sup>3</sup>/d;

10~20 d 流量为 200 m<sup>3</sup>/d。随机采样 800 个时空点和 800 个位于内边界的点作为训练数据,其中标签数据为 20 d 中每小时的平均井底压力。在实验过程中,主网络包含 10 个隐藏层,每层有 10 个神经元,残差块中包含 7 个隐藏层,每层有 8 个神经元。实验中首先使用 Adam 优化器进行优化,在优化完成后再使用 L-BFGS 优化器<sup>[29]</sup>进行整体优化。

表 1 均质储层中油藏参数

储层参数	数值
厚度/m	10
孔隙度	0.2
渗透率/mD	48.60
岩石压缩系数/MPa <sup>-1</sup>	0.000 15
表皮系数	5.000
井储系数	0.600

ML-PRNN 的拟合结果如图 3 所示。从图 3 可以看出,ML-PRNN 拟合的井底压力(bottom hole pressure, BHP)与真实 BHP 基本一致,即使在第 10 天流量发生变化,拟合的井底压力也很好地符合了真实 BHP。这是由于在输入中对时空坐标进行了非线性变化,提高了网络特征提取能力,改善了网络性能,从而帮助网络模型更好地拟合。

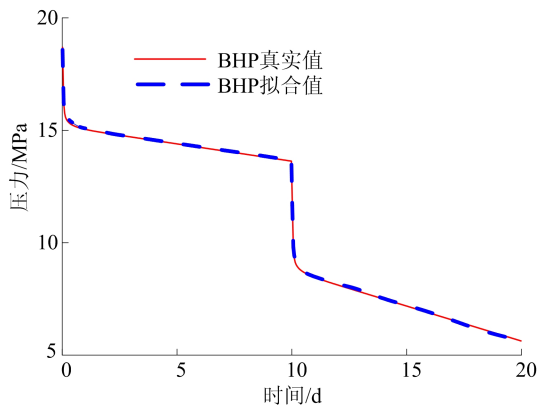



图 3 案例 1 中 ML-PRNN 的拟合结果


相应地,随着 ML-PRNN 的训练损失逐渐缩小,渗透率、表皮系数和井储系数也随之收敛到真实值附近,如图 4 所示。

从图 4 可以看出,3 个参数在训练初期快速接近准确值,并且随着训练次数的增加逐渐稳定直至收敛。


为了评估反演结果的精度,引入绝对误差和相对误差,渗透率、表皮系数、井储系数 3 个参数最终的收敛值及其误差见表 2 所列。



(a) 渗透率反演过程



(b) 表皮系数反演过程



(c) 井储系数反演过程

图 4 均质储层中的 ML-PRNN 参数反演过程

表 2 均质储层中渗透率、表皮系数和井储系数及其误差

参数	真实值	预测值	绝对误差	相对误差/%
渗透率/mD	48.60	47.60	1.00	2.06
表皮系数	5.000	4.903	0.097	1.94
井储系数	0.600	0.564	0.036	6.00

从表 2 可以看出,渗透率和表皮系数的绝对误差都较小,相对误差在 2% 左右,而井储系数的相对误差较高。这是由于井储系数的真实值本身就比较小,放大了相对误差,其绝对误差仅为 0.036。对均质油藏算例的实验结果验证了 ML-PRNN 方法对多参数反演的有效性。

### 2.2 非均质油藏算例

利用复合油藏来检验 ML-PRNN 方法的有

效性。该油藏是  $400\text{ m} \times 400\text{ m}$  的矩形储藏油藏,井位于油藏中间的复合区域内,其形状大致为半径  $R=60\text{ m}$  的圆,储层中心是一口  $r_w=0.1\text{ m}$  的生产井,如图 5 所示。




图 5 案例 2 非均质油藏储层示意图

案例 2 非均质油藏储层中的油藏参数见表 3 所列。

从表 3 可以看出,复合区域的渗透率大于其他区域渗透率。井流量  $Q$  在一定时间后发生变化,该实验中前  $0 \sim 10\text{ d}$  井流量为  $100\text{ m}^3/\text{d}$ ,之后井流量变为  $200\text{ m}^3/\text{d}$ 。

表 3 非均质储层中油藏参数

储层参数	数值
厚度/m	10
孔隙度	0.1
渗透率/mD	68.60
复合区域渗透率/mD	108.60
岩石压缩系数/ $\text{MPa}^{-1}$	0.000 15
表皮系数	3.00
井储系数	0.60

本实验在使用 BHP 数据时,将  $20\text{ d}$  中每小时的 BHP 值进行平均,得到标签数据。同时随机选取 800 个时空点,以 800 个内边界上的点作为空间坐标。主网络由 10 个隐藏层构成,每层有 10 个神经元,残差块中含有 10 个隐藏层,每层均有 7 个神经元。在优化器的选择上,先使用 Adam 优化器进行初始的快速收敛,再使用 L-BFGS 优化器进行整体的精细调优,可以进一步提高模型性能。

训练完成后,网络输出的 BHP 与真实 BHP 如图 6 所示。从图 6 可以看出,ML-PRNN 方法拟合的 BHP 与真实 BHP 之间具有一致性。对于复合油藏在流量发生变化时,ML-PRNN 方法预测的 BHP 也能准确拟合真实值,表明该方法能够有效拟合真实标签。

随着训练次数的增加,损失也随之减小,渗透率、复合区域渗透率、表皮系数、井储系数也逐步逼近真实值,4 个参数的 ML-PRNN 反演过程如

图 7 所示。







图 6 案例 2 中 ML-PRNN 的拟合结果



(a) 渗透率反演过程



(b) 复合区域渗透率反演过程



(c) 表皮系数反演过程




图 7 复合区域中的 ML-PRNN 参数反演过程

从图 7 可以看出,训练初期参数在初始值附近波动剧烈,随着训练的进行,所需反演的参数有效收敛于真实值。

与均质油藏相比,复合油藏的储层参数分布不均匀,同时复合油藏的物理过程更加复杂与非线性。通过在残差块的输入中引入自适应参数,自适应参数可以根据复合油藏的物理过程和数值模拟的误差,动态调整残差块的权重与方向,使得反演过程更加灵活有效。

由图 6 和图 7 可知,本文 ML-PRNN 方法不仅能够基于渗流方程准确地学习井底压力 BHP 的变化规律,还能够准确地反演出多个储层参数。

非均质储层中渗透率、表皮系数、井储系数的真实值、预测值及其绝对误差、相对误差见表 4 所列。

从表 4 可以看出:复合区域的渗透率虽然误差稍大一些,但预测值与真实值具有一定的接近程度;其他区域的渗透率和表皮系数的绝对误差、相对误差较小,预测效果较好;井储系数的相对误差较大,但因其真实值较小,绝对误差也很小,仅为 0.03。这也验证了 ML-PRNN 方法在复合油藏下对多参数反演的有效性。

表 4 非均质储层中渗透率、表皮系数、井储系数及其误差

参数	真实值	预测值	绝对误差	相对误差/%
渗透率/mD	68.60	65.95	2.65	3.86
复合区域渗透率/mD	108.60	102.93	5.67	5.22
表皮系数	3.00	2.91	0.09	3.00
井储系数	0.60	0.57	0.03	5.00

### 3 结 论

本文提出一种多级物理残差神经网络 ML-

PRNN 方法用于解决带有源汇项的渗流方程中的多参数反演问题,在学习井底压力标签的基础上,利用神经网络逼近偏微分方程的解及其参数空间。该方法通过使用多个残差网络逼近源汇项缓解梯度消失问题,加快网络的收敛速度。同时进一步增强输入特征的显著性,提高模型的表达能力和稳定性,如当输入特征是  $\sqrt{\Delta t}$ 、 $\ln r$ 、 $e^{\alpha(r_w-r)}$  时,网络可以更好地学习与流量变化相关的信息特征;这些非线性变换能够对输入特征进行非线性映射,使得网络能够更好地感知不同输入特征的变化,进一步增强网络对特征的感知能力,提高模型的表达能力和稳定性。通过引入自适应参数,网络可以根据不同的输入情况调整自身的参数,增加了网络的灵活性和表达能力;这种自适应参数可以使网络根据输入特征的变化动态地调整其内部状态,以最大程度地适应不同的输入情况,从而增强模型的适应能力和泛化能力。

实验结果表明,ML-PRNN 方法可以准确反演储层中多个参数,反演参数的结果与真实值的绝对误差仅为千分之一,这说明 ML-PRNN 提供了一种精确反演多参数的方法,也为其他参数的反演提供了一种新思路。ML-PRNN 方法可以提供更准确、更全面、更可信的储层信息,为储层评价、开发优化和提高采收率等提供有力的支持,值得进一步深入研究与推广。

### [参 考 文 献]

- [1] 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.
- [2] 李道伦,沈路航,查文舒,等. 基于神经算子与类物理信息神经网络智能求解新进展[J]. 力学学报,2024,56(3):1-15.
- [3] XUE L, LI D L, DOU H E. Artificial intelligence methods for oil and gas reservoir development: current progresses and perspectives [J]. Advances in Geo-Energy Research, 2023, 10(1):65-70.
- [4] RAISSI M, PERDIKARIS P, KARNIADAKIS G E. Physics-informed neural networks: a deep learning framework for solving forward and inverse problems involving nonlinear partial differential equations [J]. Journal of Computational Physics, 2019, 378:686-707.
- [5] GUI J Y, GAO J H, YONG X S, et al. Inversion of reservoir parameters based on dual-phase media theory [J]. Chinese Journal of Geophysics, 2015, 58(9):3424-3438.
- [6] GOGOI T, CHATTERJEE R. Estimation of petrophysical parameters using seismic inversion and neural network modeling in Upper Assam Basin, India [J]. Geoscience Frontiers, 2019, 10(3):1113-1124.

- [7] XIONG F S, YONG H, CHEN H, et al. Biot's equations-based reservoir parameter inversion using deep neural networks[J]. *Journal of Geophysics and Engineering*, 2021, 18(6):862-874.
- [8] 张升, 兰鹏, 苏晶晶, 等. 基于 PINNs 算法的地下水渗流模型求解及参数反演[J]. *岩土工程学报*, 2023, 45(2):376-383.
- [9] LI D L, SHEN L H, ZHA W S, et al. Physics-constrained deep learning for solving seepage equation[J]. *Journal of Petroleum Science and Engineering*, 2021, 206:109046.
- [10] 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.
- [11] LIU Z, HAO Y X, LI D L, et al. Multiparameter inversion of reservoirs based on deep learning[J]. *SPE Journal*, 2024, 29(1):126-137.
- [12] RAMEY J H. Short-time well test data interpretation in the presence of skin effect and wellbore storage[J]. *Journal of Petroleum Technology*, 1970, 22(1):97-104.
- [13] GRINGARTEN A C, BOURDET D P, LANDEL P A, et al. A comparison between different skin and wellbore storage type-curves for early-time transient analysis[C]//SPE Annual Technical Conference and Exhibition. [S. l.]: SPE, 1979; SPE-8205-MS.
- [14] 洪舒娜, 秦峰, 陈斯宇, 等. 海上生产气井动态产能评价新方法[J]. *非常规油气*, 2021, 8(6):60-67.
- [15] 蔡新明, 金忠康, 刘金华. 生产数据分析在江苏油田岩性油藏中的应用[J]. *复杂油气藏*, 2020, 13(1):62-65, 74.
- [16] 张琬璐. 波形指示反演技术方法研究及应用[J]. *非常规油气*, 2019, 6(3):21-25.
- [17] 李道伦, 查文舒. 数值试井理论与方法[M]. 北京:石油工业出版社, 2013.
- [18] 王大为, 李金宜, 刘东, 等. 基于储层物性参数的毛管压力曲线和孔喉分布表征[J]. *非常规油气*, 2024, 11(4):1-9.
- [19] LIU X L, LI D L, YANG J H, et al. Automatic well test interpretation based on convolutional neural network for infinite reservoir[J]. *Journal of Petroleum Science and Engineering*, 2020, 195:107618.
- [20] 李道伦, 刘旭亮, 查文舒, 等. 基于卷积神经网络的径向复合油藏自动试井解释方法[J]. *石油勘探与开发*, 2020, 47(3):623-631.
- [21] LIU X L, ZHA W S, QI Z K, et al. Automatic reservoir model identification method based on convolutional neural network[J]. *Journal of Energy Resources Technology*, 2022, 144(4):043002.
- [22] LIU X L, ZHA W S, LI D L, et al. Automatic well test interpretation method for circular reservoirs with changing wellbore storage using onedimensional convolutional neural network[J]. *Journal of Energy Resources Technology*, 2023, 145(3):033201.
- [23] 李道伦, 齐银, 达引朋, 等. 低速非线性是低渗油藏的流动机制[J]. *非常规油气*, 2020, 7(4):1-8.
- [24] ZHANG K, FU W H, ZHANG J D, et al. Inversion framework of reservoir parameters based on deep autoregressive surrogate and continual learning strategy[J]. *SPE Journal*, 2023, 28(5):1-17.
- [25] ZHA W S, GAO S L, LI D L, et al. Application of the ensemble Kalman filter for assisted layered history matching[J]. *Advances in Geo-Energy Research*, 2018, 2(4):450-456.
- [26] LI D L, LIU X L, ZHA W S, et al. Automatic well test interpretation based on convolutional neural network for a radial composite reservoir[J]. *Petroleum Exploration and Development*, 2020, 47(3):623-631.
- [27] ZHA W S, LI X B, XING Y, et al. Reconstruction of shale image based on Wasserstein Generative Adversarial Networks with gradient penalty[J]. *Advances in Geo-Energy Research*, 2020, 4(1):107-114.
- [28] LI D L, ZHA W S, LIU S L, et al. Pressure transient analysis of low permeability reservoir with pseudo threshold pressure gradient[J]. *Journal of Petroleum Science and Engineering*, 2016, 147:308-316.
- [29] NOCEDAL J. Updating quasi-newton matrices with limited storage[J]. *Mathematical Programming*, 1980, 45(3):343-347.

(责任编辑 胡亚敏)