基于多输出 RBF 神经网络的油藏参数反演方法

沈　婷[1]　付　宁[2]　王　凯[2]　张　康[2]　李道伦[1]

1. 合肥工业大学数学学院，　安徽　合肥　230601；

2. 中国石油川庆钻探工程有限公司长庆井下技术作业公司，　陕西　西安　710018

摘　要：为提高试井分析的反演精度和效率，提出一种基于多输出径向基函数（Radial Basis Function，RBF）神经网络的油藏参数反演方法。首先选定待反演的不确定参数及其范围，生成采样算例；然后利用梯度下降法训练出一个逼近真实函数关系的代理模型，即多输出 RBF 神经网络，构建代理模型预测值与实际观测值偏差的目标函数，再利用粒子群优化（Particle Swarm Optimization，PSO）算法搜索目标函数的最小值，得到一组较优参数值。与单输出 RBF 神经网络相比，多输出 RBF 神经网络通过参数共享与同步输出完整压力响应序列，避免了为每个时间点压力单独建模的重复训练。对比实验表明，多输出 RBF 神经网络训练时间仅为单输出 RBF 神经网络训练时间的 2% 左右，且模型精度更高，预测曲线更平滑。通过油田现场实测数据验证可知，基于多输出 RBF 神经网络的油藏参数反演方法在复杂非均质油藏模型中能有效地对井底压力变化和压力导数进行拟合，为油藏参数智能反演提供了一种高效、可供参考的新方法，具有一定应用价值。

关键词：RBF 神经网络；多输出；油藏参数反演；历史拟合；试井分析

DOI：10. 3969 /j. issn. 1006-5539. 2026. 04. 009

Reservoir parameter inversion method based on multi-output radial basis function neural network

Shen Ting[1], Fu Ning[2], Wang Kai[2], Zhang Kang[2], Li Daolun[1]

1. School of Mathematics, Hefei University of Technology, Hefei, Anhui, 230601, China;

2. PetroChina CCDC Changqing Downhole Technology Company, Xi'an, Shaanxi, 710018, China

Abstract: In order to improve the inversion accuracy and efficiency of well test analyis, this paper proposes a reservoir parameter inversion method based on a multi-output radial basis function (RBF) neural network. First, the uncertain parameters to be inverted and their ranges are selected to generate sampling cases. Then, a surrogate model that approximates the true functional relationship, i. e., the multi-output RBF neural network model, is trained using gradient descent. An objective function is constructed based on the deviation between surrogate model predictions and actual observations, and particle swarm optimization (PSO) is employed to search for the minimum of the objective function to obtain a set of optimal parameter values. Compared with single-output RBF neural networks, the multi-output RBF neural network achieves parameter sharing and synchronous output of complete pressure response sequences, avoiding repetitive training required for modeling pressure at each time point separately. Comparative experiments demonstrate

收稿日期：2025-12-30

基金项目：国家自然科学基金“基于流动方程的致密油气藏深度学习数值模拟方法”（12372244）

作者简介：沈　婷（1994-），女，硕士，主要从事油藏参数反演研究工作。E-mail：563825764@ qq. com

通信作者：李道伦（1972-），男，教授，博士生导师，主要从事渗流模型、求解与数值试井研究等研究工作。E-mail：ldaol@ hfut. edu. cn

that the training time of the multi-output RBF neural network is only approximately 2% of that of the single-output RBF model, with higher model accuracy and smoother prediction curves. It is known from the verification with actual measured data from oilfied sites that the reservoir parameter inversion method based on the multi-output RBF neural network can effectively fit both bottomhole pressure variations and pressure derivatives in complex heterogeneous reservoir models. This method provides an efficient and practical new method for intelligent reservoir parameter inversion with significant application value.

Keywords: RBF neural network; Multi-output; Reservoir parameter inversion; History matching; Well test analysis

0　前言

油藏参数是油藏数值模拟、动态分析及开发方案优化的基础[1]，渗透率、表皮系数等参数直接决定油藏模型的预测精度和可靠性。然而，它们无法直接获取，必须通过间接手段估算而得。试井分析通过分析井底压力及其导数随生产时间的响应特征反演储层特性[2]，其核心是典型的“反问题”求解过程，即调整模型参数使数值模拟器输出与实测数据吻合，该过程常被称为“历史拟合”或“自动历史匹配”[3]。自动历史拟合借助优化算法完成，本质是高维、非线性、多极值的优化问题。早期研究依赖梯度类算法，如 Thomas L K 等人[4]提出的非线性自动历史拟合技术及 Gavalas G R 等人[5]引入的贝叶斯估计框架。然而，梯度类算法对初始模型依赖强，易陷入局部最优[6]。为克服这些局限，无导数优化算法逐渐受到青睐。例如，张凯等人[7]探讨了无梯度多参数自动历史拟合方法；Shams M 等人[8]将和声搜索算法应用于辅助历史拟合；Zhang Xiansong 等人[9]利用改进的遗传算法进行自动历史匹配。其中，粒子群优化（Particle Swarm Optimization，PSO）算法作为一种高效的全局优化方法，已被广泛应用于油藏参数反演[10-11]。

尽管优化算法不断进步，一个根本性挑战依然存在：每次参数调整都需调用计算成本高昂的数值模拟器进行正演计算，整个反演过程极其耗时[12-13]。为突破这一瓶颈，“代理模型”应运而生，旨在构建计算代价极低的数学模型来近似替代复杂的数值模拟过程[14]。

早期，响应面法和拟牛顿法（如 BFGS 算法）已被尝试用于试井分析[14]。随后，支持向量回归[15]、集合卡尔曼滤波[16]等方法也被引入。近年来，神经网络成为研究热点。Liu zhi 等人[17]探讨了基于深度学习的多参数反演方法。Li Daolun 等人[18]利用卷积神经网络（Convolutional Neural Network，CNN）实现了径向复合油藏的自动试井解释，随后，该团队进一步将 CNN 应用于无限大油藏[19]、多类型油藏模型自动识别[20]及变井储圆形油藏的一维 CNN 解释[21]。为提升物理合理性，Shen Luhang 等人[22]提出了物理渐近解网络。在提升效率方面，Ma Xiaopeng 等人[13]提出了基于向量到序列的多层循环网络代理模型；Zhang Chengkai 等人[23]结合混合神经网络与贝叶斯优化预测井底压力；Zhang Daowei 等人[24]和 Zhang Jinding 等人[25]分别利用改进的视觉 Transformer 网络和高效 Transformer 架构构建代理模型。Shen Luhang 等人[26]也研究了利用深度神经网络为多孔介质流动建立代理模型。这些研究证明了数据驱动方法在油藏建模中的有效性。

在诸多神经网络中，径向基函数（Radial Basis Function，RBF）神经网络具有结构简单、收敛速度快的特点，且能以任意精度逼近任意连续非线性函数，特别适合代理模型构建。Huang Kouyuan 等人[27]较早将 RBF 神经网络用于测井数据反演，Memon P Q 等人[28]利用 RBF 神经网络动态预测井底流压，周子琪等人[10]成功将 RBF 神经网络应用于油藏反演。然而，现有基于 RBF 神经网络的油藏反演研究多采用单输出模式，即针对每个时间点的输出响应单独建模。当需同时预测多个相关物理量时，训练效率随输出维度增加而下降，且忽略了输出变量间的潜在关联性，导致预测曲线不平滑。

针对上述问题，本文提出一种基于多输出 RBF 神经网络的油藏参数反演方法。设计了 3 组对比实验，在均质油藏 2000 组和 120 组算例及非均质油藏案例下，对比单输出与多输出 RBF 神经网络的训练时间、模型精度、预测曲线、反演参数相对误差及历史拟合图；然后利用油田实测数据验证多输出 RBF 神经网络方法的实际应用效果。

1　油藏参数反演方法

1.1　多输出 RBF 神经网络

RBF 神经网络是一种具有单隐层前馈结构的局部逼近神经网络，其核心思想是利用 RBF 作为隐藏层节点的激活函数，通过对输入空间的局部响应来逼近复杂的非线性关系。

RBF 神经网络的结构通常包含输入层、隐藏层（径向基层）、输出层。输入层接收输入向量；隐藏层由一组 RBF 构成，每个隐藏节点对应一个“中心”和“宽度”，隐

藏层输出为输入向量与中心之间的 RBF 值，见式(1)。

$$\varphi_i(x) = \exp\left(-\frac{||x - c_i||^2}{2\sigma_i^2}\right) \tag{1}$$

式中：x 为输入向量；i 为隐层节点序号；c_i 为第 i 个隐层节点的中心；σ_i 为第 i 个隐层节点的宽度。

输出层为隐层输出的线性加权和，见式(2)。

$$y_j = \sum_{i=1}^{m} \omega_{ij}\varphi_i(x) \tag{2}$$

式中：ω_{ij} 为权重；j 为输出节点序号；y_j 为输出层第 j 个节点输出值。

神经网络采用梯度下降法反向传播同时训练所有参数(中心、宽度和权重)。训练算法步骤如下。

1)参数初始化：c_i 从训练样本中随机选择；σ_i 使用对数宽度，初始化为较小正值(如 0.1 ~ 1)；ω_{ij} 采用 Xavier 均匀分布初始化。

2)前向传播：对每个训练样本，计算隐藏层输出 $\varphi_i(x)$，计算网络输出 $y_j(x)$。

3)误差计算：比较输出值与真实值，计算误差。

4)反向传播：计算输出层权重梯度，计算隐藏层中心和宽度梯度。

5)参数更新：使用梯度下降法更新所有参数，确保 σ_i 保持正值。

重复步骤 2) ~5)直至收敛。

现有的油藏反演方法中使用的单输出 RBF 神经网络需要为响应量的每个具体观测值(如某个时间点的井底压力)单独建模，如要预测 90 个值时，则要循环训练 90 个模型。这种训练方式导致训练效率很低，且针对小样本数据若使用 K 折交叉验证，训练时间还会成倍增加，不利于小样本数据的实验，并且想要监测所有模型的损失变化较困难，模型超参数的调整难度较高。

本文提出的多输出 RBF 神经网络模型将输出层由单个节点扩展为多个节点。所有输出共享同一隐藏层表示，学习共同特征，只需构建、训练及维护一个模型，大幅减少训练和推理时间。由于训练时只需监测一个模型的损失变化，也降低了模型超参数调整的难度。多输出 RBF 神经网络结构见图 1。神经网络的输入为渗透率、井储、表皮因子等试井解释模型参数，输出为全部时间点的井底压力变化及压力导数。

本文采用 MinMaxScaler 归一化方法对神经网络的输入进行预处理，避免输入数据之间量纲和数量级不同影响模型预测结果，计算见式(3)。

$$x_{\text{norm}} = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \tag{3}$$

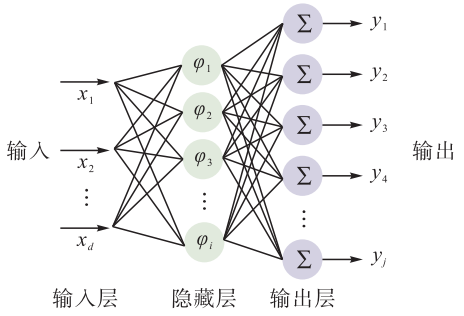

图 1　多输出 RBF 神经网络结构图

Fig. 1　Multi-output RBF neural network structure

式中：x_{norm} 为 x 的归一化处理后数据；$x_{\max}$ 为 x 的最大值；$x_{\min}$ 为 x 的最小值。

模型性能的评价指标采用均方误差(Mean Square Error) E_{MS} 和平均绝对误差(Mean Absolute Error) E_{MA}，计算见式(4) ~ (5)。

$$E_{\text{MS}} = \frac{1}{NM}\sum_{n=1}^{N}\sum_{j=1}^{M}(y_{nj} - \hat{y}_{nj})^2 \tag{4}$$

$$E_{\text{MA}} = \frac{1}{NM}\sum_{n=1}^{N}\sum_{j=1}^{M}|y_{nj} - \hat{y}_{nj}| \tag{5}$$

式中：N 为样本总数，个；M 为输出维度；$\hat{y}_{nj}$ 为第 n 个样本的第 j 个输出预测值；y_{nj} 为第 n 个样本的第 j 个输出实际值。

实验使用了 Tensorflow 框架。多输出 RBF 神经网络隐藏层有 32 个神经元，输出层神经元数量为全部时间点的压力变化及压力导数值的数量。该代理模型使用 Adam 优化器[29]，学习率调度策略使用标准的余弦退火(Cosine Annealing)[30]，初始学习率为 0.01，最小学习率为 0.000 1。将数据集划分出 20% 作为测试集，剩余 80% 的数据划分为 80% 的训练集和 20% 的验证集。

1.2　目标函数

油藏参数反演本质上是一个反问题：即以实测的井底压力变化及压力导数等动态数据作为约束条件，反求未知的地层属性及井筒参数。数学表述为，寻找一组参数解，使得在该参数组合下数值模拟器计算的压力数据，与实测数据之间的差异最小。这一差异通过一个定义的目标函数(如均方误差)进行量化，反演过程转化为对该目标函数的最小化求解。本文使用的目标函数表达式见式(6)。

$$O_{\text{F}} = \frac{1}{M}\sum_{j=1}^{M}[y_{\text{obs}}^{j} - y_{\text{sim}}^{j}(x)]^2 \tag{6}$$

式中：O_{F} 为目标函数，即实测值与预测值之间的均方误差；y_{obs}^{j} 为第 j 个实际观测值；y_{sim}^{j} 为第 j 个预测值。

1.3　PSO 算法

PSO 算法是一种基于群体智能的全局优化算法，仅依赖目标函数值进行搜索，无需梯度信息，适用于黑箱优化(如代理模型反演)。本文使用 PSO 算法优化目标

函数,算法迭代的流程如下。

1)初始化粒子群位置和速度:随机生成一群粒子,每个粒子具有位置 x_k(代表候选解)和速度 v_k。

2)评估每个粒子的适应度:根据目标函数计算每个粒子的适应度 f_k。

3)更新个体与群体最优:每个粒子记录自身历史最优位置 $p_{\text{best}}(k)$,整个群体共享全局历史最优位置 g_{best}。

4)迭代更新:每一代中,粒子根据式(7)~(8)更新速度和位置。

$$v_k^{t+1} = \omega v_k^t + c_1 r_1 [p_{\text{best}}(k) - x_k^t] + c_2 r_2 (g_{\text{best}} - x_k^t) \tag{7}$$

$$x_k^{t+1} = x_k^t + v_k^{t+1} \tag{8}$$

式中:v_k 和 x_k 分别为第 k 个粒子的速度和位置;$p_{\text{best}}(k)$ 和 g_{best} 分别为粒子的个体最优位置和全局最优位置;ω 为惯性权重,平衡全局与局部搜索;c_1、c_2 为学习因子,分别调节个体和群体经验的重要性;r_1、r_2 为随机数,增加探索随机性;t 为迭代次数(或时间步),次;k 为粒子索引。

5)终止:重复步骤 2)~4),直到满足最大迭代次数或收敛精度。

1.4　油藏参数反演方法流程

基于数据驱动代理模型的油藏参数反演方法流程见图 2。

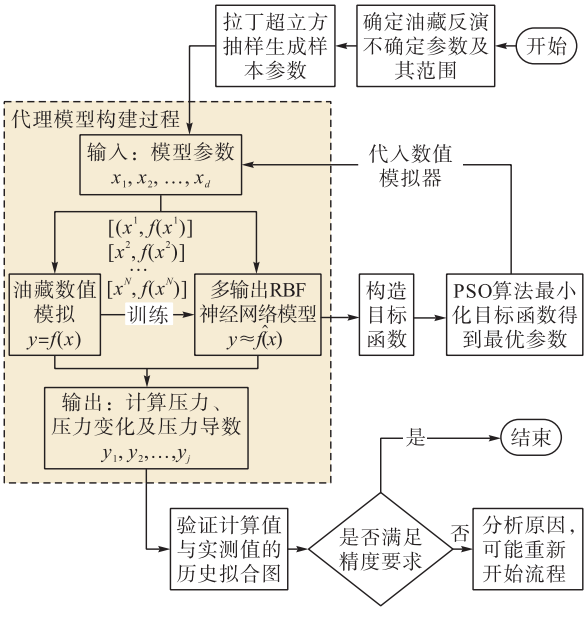

图 2　油藏参数反演方法流程图

Fig. 2　Workflow of reservoir parameter inversion methodology

2　油藏反演方法对比实验

本节将构建单输出与多输出 2 种 RBF 神经网络代理模型,并在均质油藏案例的 2 000 组算例和 120 组算例以及非均质油藏案例下进行测试。从模型训练时间、测试集上的模型精度(如 E_{MS}、E_{MA})、预测曲线、反演参数相对误差及油藏历史拟合图 5 个维度对 2 种方法进行系统比较。

2.1　均质油藏案例

本案例为常规油相均质矩形油藏,大小为 4 000 m × 4 000 m,厚度为 3 m,孔隙度为 0.24,中心为一口直井。其垂直平分(Perpendicular Bisector,PEBI)网格划分见图 3,PEBI 网格是一种灵活的非结构化网格[31],图 3 中为变尺度网格。

选定的待反演参数为:油藏初始压力范围 5~20 MPa,井储范围 0.1~5 m^3/MPa,井表皮因子范围是 -4~5。拟合对象是关井流动段的井底压力曲线、压力变化及压力导数双对数曲线。

利用拉丁超立方抽样确定 2 000 组样本参数组合,将每组参数代入数值模拟软件计算出井底压力、压力变化及压力导数,生成 2 000 组采样算例。基于这些采样算例构建代理模型,然后使用实测数据进行参数反演。

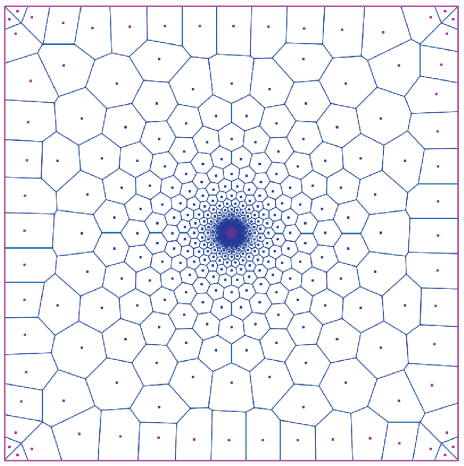

图 3　均质油藏的 PEBI 网格划分图

Fig. 3　PEBI grid division of a homogeneous reservoir

2.1.1　2 000 组算例下的对比实验

在 2 000 组算例下,分别使用单输出 RBF 神经网络方法和多输出 RBF 神经网络方法进行参数反演。

首先使用相同算例,分别训练 1 个有效的代理模型,2 个代理模型的性能对比见表 1。由表 1 可以看出,多输出 RBF 神经网络模型的训练时间是单输出 RBF 神经网络模型训练时间的 1.52%,在测试集上评估的模型精度更高。

表 1　2 个代理模型性能对比表(2 000 组算例)

Tab. 1　Performance comparison of two surrogate models (2 000 simulation cases)

代理模型	训练时间 / min	模型精度	
		E_{MS}	E_{MA}
单输出 RBF 神经网络	937.88	0.032 5	0.036 6
多输出 RBF 神经网络	14.23	0.000 5	0.015 7

单输出 RBF 神经网络模型与多输出 RBF 神经网络模型的压力预测曲线见图 4。其中真实值为测试集的某一组算例，预测值为代理模型的输出值。

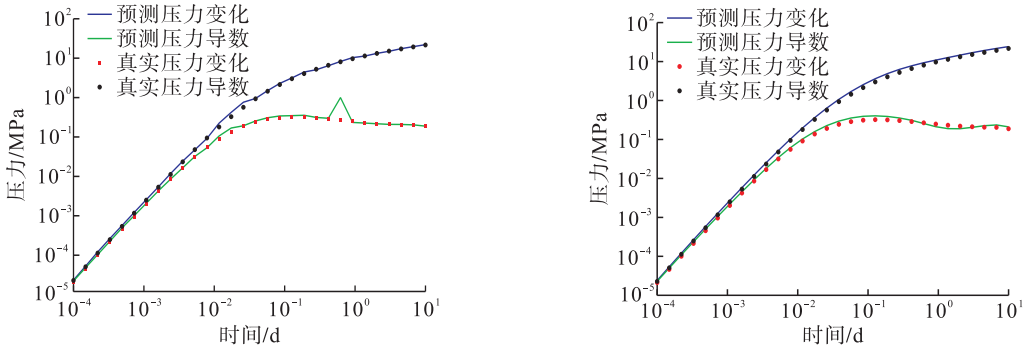

a）单输出 RBF 神经网络模型预测曲线

a）Single-output RBF neural network model prediction curve

b）多输出 RBF 神经网络模型预测曲线

b）Multi-output RBF neural network model prediction curve

图 4　2 个代理模型预测曲线对比图（2 000 组算例）

Fig. 4　Comparison of predicted curves from two surrogate models (2 000 simulation cases)

由图 4 可知，由于单输出 RBF 神经网络模型对每个点都是独立预测的，其预测的导数曲线会出现局部点存在非物理的震荡，使得整个预测曲线不如多输出 RBF 神经网络模型的预测曲线平滑。

接着利用 PSO 算法优化代理模型预测值与实测值偏差的目标函数，求得一组较优的参数；最后将这组反演参数代入数值模拟软件，计算出井底压力、压力变化及压力导数，与实测数据对比，验证历史拟合效果。

2 个代理模型反演参数对比见表 2，可以看出，多输出 RBF 神经网络模型的反演值与准确值的相对误差整体更小。

表 2　2 个代理模型反演参数对比表（2 000 组算例）

Tab. 2　Comparison of inversion parameters for two surrogate models (2 000 simulation cases)

参数	准确值	单输出 RBF 神经网络		多输出 RBF 神经网络	
		反演值	相对误差	反演值	相对误差
油藏初始压力 /MPa	8.090 9	8.131 4	0.50%	8.081 9	0.11%
井储 /(m^3 · MPa^{-1})	1.835 5	1.992 4	8.55%	1.832 5	0.17%
井表皮因子	−2.839 0	−2.751 2	3.09%	−2.942 5	3.65%

图 5 和图 6 分别为单输出 RBF 神经网络模型方法和多输出 RBF 神经网络模型方法的历史拟合结果，图 5 和图 6 中图 a）为井底压力对比，图 b）为压力变化及其导数对比。

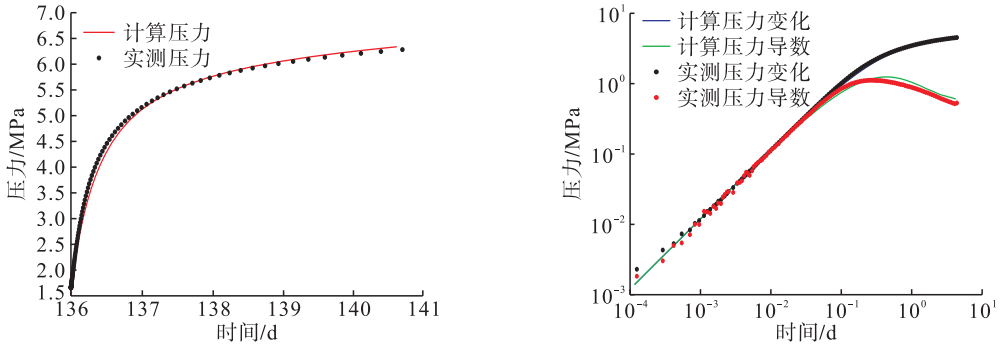

a）井底压力对比

a）Comparison of bottomhole pressure

b）压力变化及其导数对比

b）Comparison of pressure changes and their derivative

图 5　单输出 RBF 神经网络模型历史拟合结果图（2 000 组算例）

Fig. 5　History matching results of the single-output RBF neural network model (2 000 simulation cases)

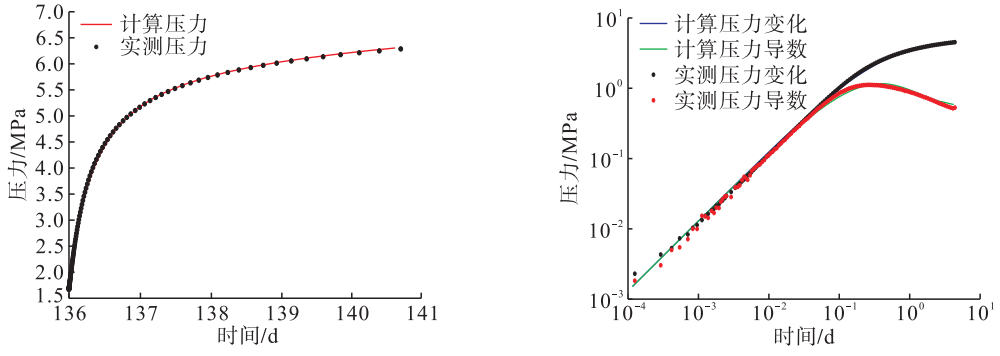

a) 井底压力对比　b) 压力变化及其导数对比

a) Comparison of bottomhole pressure　b) Comparison of pressure changes and their derivative

图 6　多输出 RBF 神经网络模型历史拟合结果图(2 000 组算例)

Fig. 6　History matching results of the multi-output RBF neural network model(2 000 simulation cases)

2.1.2　120 组算例下的对比实验

基于以上油藏模型生成的算例,本组实验仅使用 120 组算例,对比评估 2 个代理模型在小样本量条件下油藏反演的稳定性。

已有研究在构建用于油藏参数反演的单输出 RBF 神经网络模型时,未明确说明其验证集的划分方式或可能未设置独立验证集。为在小样本量条件下实现更系统、公平的模型对比,本组实验将在单输出 RBF 神经网络模型中也引入 5 折交叉验证[32],并基于各折最优模型进行集成平均,以消除验证策略本身带来的性能偏差。

在相同算例下,分别训练单输出 RBF 神经网络模型与多输出 RBF 神经网络模型,模型性能对比见表 3。可以看出,由于使用了 5 折交叉验证,单输出 RBF 神经网络模型的训练时间在原有基础上成倍增加,并且在后续用 PSO 算法优化参数时效率也很低。多输出 RBF 神经网络模型在训练时间及模型精度上都有稳定的优势。

表 3　2 个代理模型性能对比表(120 组算例)

Tab. 3　Performance comparison of two surrogate models (120 simulation cases)

代理模型	训练时间 / min	模型精度	
		E_{MS}	E_{MA}
单输出 RBF 神经网络	2 439.55	0.017 2	0.069 5
多输出 RBF 神经网络	27.22	0.003 0	0.031 1

图 7 为单输出 RBF 神经网络模型与多输出 RBF 神经网络模型预测的压力变化及压力导数曲线,其中真实值为训练集的一组算例,预测值为代理模型的输出值。可以看出,当数据集较小时,单输出 RBF 神经网络模型预测的导数曲线表现出更明显的局部非物理震荡,而多输出 RBF 神经网络模型的预测曲线较稳定。

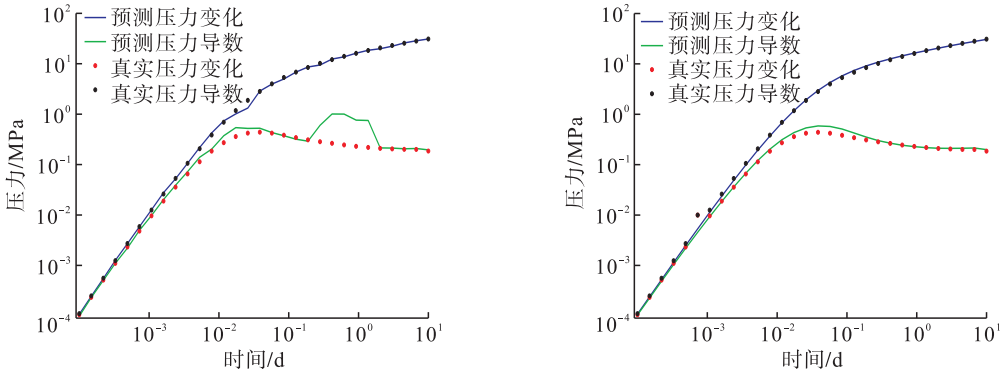

a) 单输出 RBF 神经网络模型预测曲线　b) 多输出 RBF 神经网络模型预测曲线

a) Single-output RBF neural network model prediction curve　b) Multi-output RBF neural network model prediction curve

图 7　2 个代理模型预测曲线对比图(120 组算例)

Fig. 7　Comparison of predicted curves from two surrogate models(120 simulation cases)

根据实测数据,分别用单输出 RBF 神经网络模型方法与多输出 RBF 神经网络模型方法反演不确定参数。对应的反演参数见表 4。由表 4 可见,多输出 RBF 神经网络模型的反演值与准确值的相对误差整体更小。

图 8 和图 9 分别为单输出 RBF 神经网络模型和多输出 RBF 神经网络模型的历史拟合图。可以看出,在小样本量条件下,多输出 RBF 神经网络模型在更少的训练时间下,实现稳定的拟合效果。

表 4　2 个代理模型反演参数对比表(120 组算例)

Tab. 4　Comparison of inversion parameters for two surrogate models(120 simulation cases)

参数	准确值	单输出 RBF 神经网络		多输出 RBF 神经网络	
		反演值	相对误差	反演值	相对误差
油藏初始压力 /MPa	8.090 9	7.977 6	1.40%	8.071 8	0.24%
井储 /(m^3 · MPa^{-1})	1.835 5	1.684 2	8.24%	1.718 5	6.37%
井表皮因子	−2.839 0	−3.052 0	7.50%	−2.972 3	4.70%

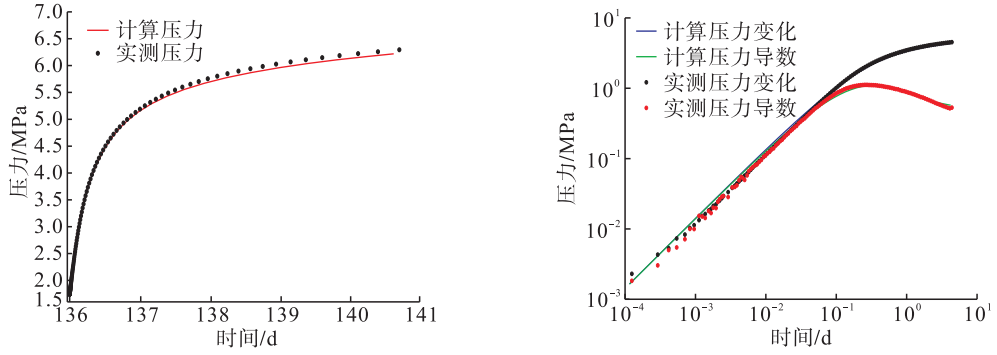

a)井底压力对比　b)压力变化及其导数对比

a) Comparison of bottomhole pressure　b) Comparison of pressure changes and their derivative

图 8　单输出 RBF 神经网络模型历史拟合结果图(120 组算例)

Fig. 8　History matching results of the single-output RBF neural network model(120 simulation cases)

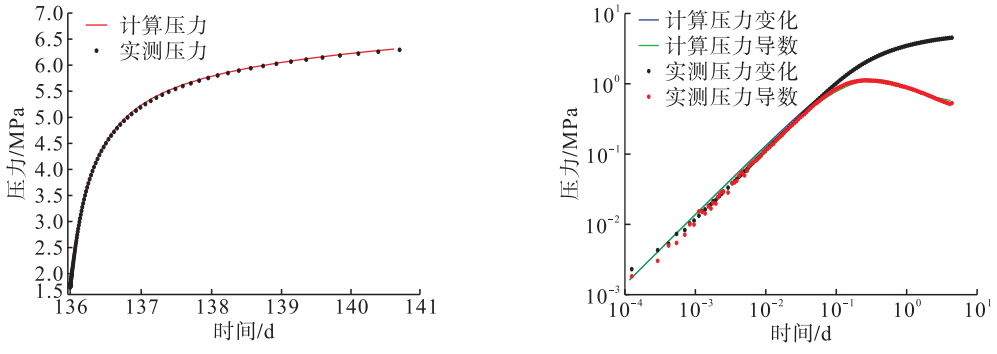

a)井底压力对比　b)压力变化及其导数对比

a) Comparison of bottomhole pressure　b) Comparison of pressure changes and their derivative

图 9　多输出 RBF 神经网络模型历史拟合结果图(120 组算例)

Fig. 9　History matching results of the multi-output RBF neural network model(120 simulation cases)

2.2　非均质油藏案例

油藏中有多段压裂水平井 1,流动相为油相,模型见图 10。储层厚度为 10 m,孔隙度为 0.05,油黏度为 1.45 mPa · s,裂缝中采用无限传导模型。压裂井裂缝数为 5 条,各裂缝周围的复合区域依次为区域 1 至区域 5,外围区域为区域 6。渗透率分布不均,复合区域 1 至复合区域 5 与复合区域 6 的渗透率不同,其他区域的水平渗透率为 0.1 mD。

所选定的 5 个待反演的不确定参数分别为:井储范围 4 ~ 15 m^3 /MPa;复合区域 1 至复合区域 5 的水平渗透率范围 80 ~ 200 mD;复合区域 6 的水平渗透率范围 1 ~ 20 mD;复合区域 1 至复合区域 5 的复合半径范围 5 ~ 20 m;复合区域 6 的复合半径范围 20 ~ 65 m。拟合对象是关井流动段的压力变化及压力导数双对数曲线。

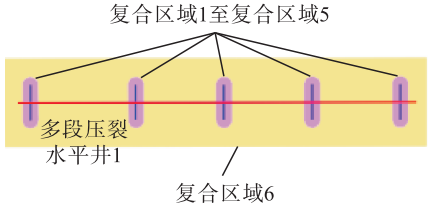

图 10　油藏多段压裂水平井 1 模型图

Fig. 10　Model of multi-stage fractured horizontal Well 1 in reservoir

由拉丁超立方抽样生成 1 000 组算例，使用相同算例，分别构建单输出 RBF 神经网络和多输出 RBF 神经网络代理模型，2 个代理模型的性能对比见表 5、预测曲线对比见图 11。可以看出，多输出 RBF 神经网络模型的训练时间是单输出 RBF 神经网络模型训练时间的 1.48%，多输出 RBF 神经网络模型在测试集上评估的模型精度更高，其预测曲线更平滑、更接近真实值。

表 5　2 个代理模型性能对比表（非均质油藏）

Tab. 5　Performance comparison of two surrogate models (heterogeneous reservoir)

代理模型	训练时间 / min	模型精度	
		E_{MS}	E_{MA}
单输出 RBF 神经网络	435.23	0.017 0	0.037 3
多输出 RBF 神经网络	6.42	0.001 6	0.027 1

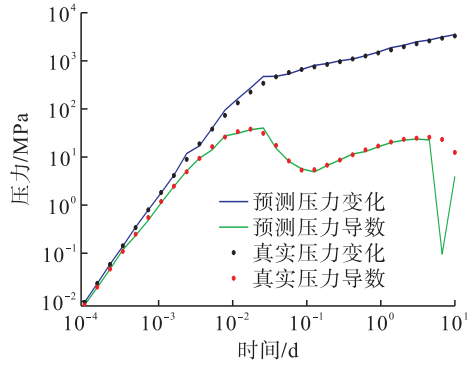

a）单输出 RBF 神经网络模型预测曲线

a) Single-output RBF neural network model prediction curve

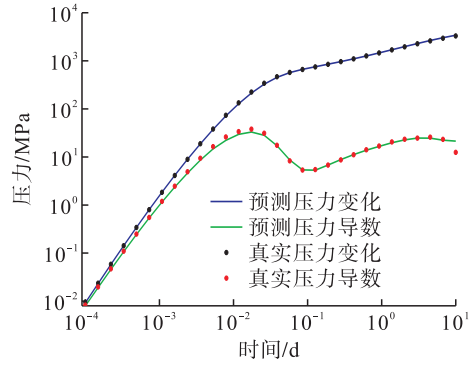

b）多输出 RBF 神经网络模型预测曲线

b) Multi-output RBF neural network model prediction curve

图 11　2 个代理模型预测曲线对比图（非均质油藏）

Fig. 11　Comparison of predicted curves from two surrogate models (heterogeneous reservoir)

用实测数据与代理模型预测值构造目标函数，然后用 PSO 算法搜索目标函数最小值，反求不确定参数值，2 个代理模型方法反求的参数结果对比见表 6。分别将反求参数值代入油藏数值模拟软件中，拟合得到井底压力变化及压力导数，2 个代理模型方法拟合结果对比见图 12。

表 6　2 个代理模型反演参数对比表（非均质油藏）

Tab. 6　Comparison of inversion parameters for two surrogate models (heterogeneous reservoir)

参数	准确值	单输出 RBF 神经网络		多输出 RBF 神经网络	
		反演值	相对误差	反演值	相对误差
井储 /(m^3 · MPa^{-1})	8.950 0	8.099 8	9.50%	9.065 5	1.29%
复合区域 1 至区域 5 水平渗透率 /mD	120.000 0	128.270 9	6.89%	119.503 5	0.41%
复合区域 6 水平渗透率 /mD	10.000 0	9.754 3	2.46%	10.495 2	4.95%
复合区域 1 至区域 5 区域复合半径 /m	13.000 0	16.610 3	27.77%	13.107 2	0.82%
复合区域 6 区域复合半径 /m	45.000 0	45.318 0	0.71%	42.825 2	4.83%

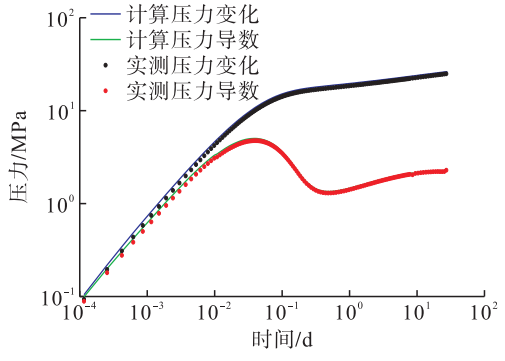

a）单输出 RBF 神经网络模型历史拟合结果

a) History matching results of the single-output RBF model

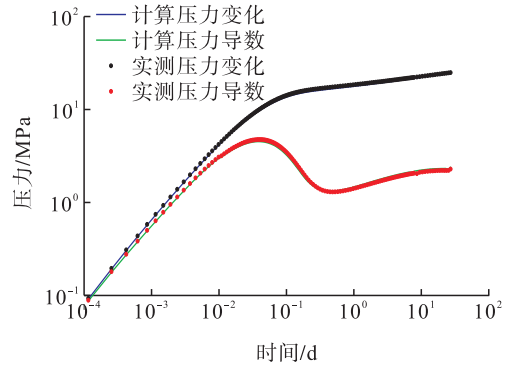

b）多输出 RBF 神经网络模型历史拟合结果

b) History matching results of the multi-output RBF model

图 12　2 个代理模型历史拟合结果对比图（非均质油藏）

Fig. 12　Comparison of history matching results between two surrogate models (heterogeneous reservoir)

由表 6 及图 12 可知,在该非均质油藏案例中,与传统单输出 RBF 神经网络模型方法相比,多输出 RBF 神经网络模型方法的反演值与准确值的相对误差整体更小,历史拟合结果具有等效的良好效果。

实验表明,在相同条件下,本文采用的多输出 RBF 神经网络结构在保证更高精度的同时,训练效率提升了一个数量级以上,具有更平滑的预测曲线,实现了等效的历史拟合结果,这显著增强了本方法应用于复杂实际问题的可行性。

3 实际案例研究

3.1 案例 1

本案例研究了一个以压裂直井为中心的非均质径向复合油藏模型。油藏中有压裂段 1,流动相为水相。油藏大小为 900 m×900 m,厚度为 7 m,孔隙度为 0.056 5,水黏度为 1 mPa·s,地层体积系数为 1.05,压缩系数为 0.000 475 MPa^{-1},裂缝半长 170 m,裂缝方位 90°,裂缝中流动采用无限传导模型。井周围有 3 个由内向外依次分布的复合区域。储层表现出以井筒为中心的径向非均质性,渗透率分布不均,复合区域的渗透率高,其他区域的渗透率低。

所选定的 10 个待反演的不确定参数及其范围见表 7。拟合对象是关井流动段的井底压力变化及压力导数双对数曲线。

本案例中代理模型采用了 3 层多输出 RBF 神经网络结构,同时对神经网络的输出提前使用了标准差标准化处理,避免输出值间数量级差异大影响模型的训练效果。标准差标准化方法是针对初始数据采用均值以及标准差进行处理的方法,处理后的数据 y_{norm} 满足标准正态分布,即均值为 0,标准差为 1,见式(9)。

$$y_{norm} = \frac{y - \mu}{\sigma} \tag{9}$$

式中:μ 为初始数据 y 的均值;σ 为初始数据 y 的标准差。

由拉丁超立方抽样生成 1 000 组算例,然后反求不确定参数值,反求参数结果见表 8,平均相对误差 21.68%,将反求参数代入油藏数值模拟软件中拟合得到压力变化及其导数见图 13。

表 7 压裂段 1 的参数范围表

Tab.7 Parameter range of fractured stage 1

参数	对象	最小值	最大值
初始压力 /MPa	油藏	30.00	50.00
井储 /(m^3·MPa^{-1})	压裂段 1	0.10	1.00
井表皮因子	压裂段 1	0	1.00
水平渗透率 /mD	层 1	1.00	10.00
	区域 1	500.00	1 500.00
	区域 2	20.00	150.00
	区域 3	10.00	100.00
区域复合半径 /m	区域 1	10.00	50.00
	区域 2	30.00	100.00
	区域 3	60.00	200.00

表 8 压裂段 1 的反演参数表

Tab.8 Inversion parameters of fractured stage 1

参数	准确值	反演值	相对误差	绝对误差
油藏初始压力 /MPa	42.000 0	34.000 0	19.05%	—
井储 /(m^3·MPa^{-1})	0.700 0	0.803 4	14.78%	—
井表皮因子	0	0.065 0	—	0.065 0
层 1 水平渗透率 /mD	2.450 0	2.211 4	9.74%	—
复合区域 1 水平渗透率 /mD	900.000 0	1 054.197 7	17.13%	—
复合区域 2 水平渗透率 /mD	80.000 0	33.416 4	58.23%	—
复合区域 3 水平渗透率 /mD	20.000 0	22.005 8	10.03%	—
复合区域 1 区域复合半径 /m	35.000 0	46.562 3	33.04%	—
复合区域 2 区域复合半径 /m	60.000 0	47.119 8	21.47%	—
复合区域 3 区域复合半径 /m	110.000 0	97.158 9	11.67%	—

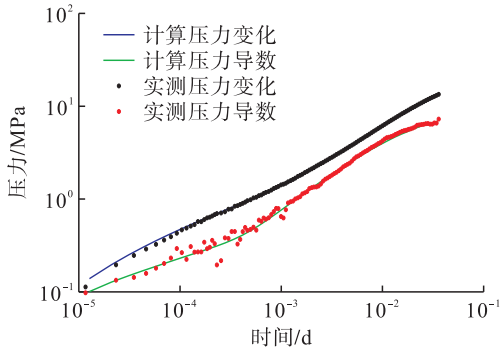

图 13　压裂段 1 历史拟合结果图

Fig. 13　History matching results of fractured stage 1

3.2　案例 2

本案例研究了另一个以压裂直井为中心的非均质径向复合油藏模型。油藏中有压裂段 2，流动相为水相。油藏大小为 900 m×900 m，厚度为 7 m，孔隙度为 0.056，水黏度为 1 mPa·s，地层体积系数为 1.05，压缩系数为 0.000 475 MPa^{-1}，裂缝半长 192 m，裂缝方位 90°，裂缝中流动采用无限传导模型。井周围有 3 个复合区域，分别为复合区域 1、复合区域 2 和复合区域 3。渗透率分布不均，不同复合区域与其他区域分别具有不同的渗透率。

所选定的 10 个待反演的不确定参数及其范围见表 9。拟合对象是关井流动段的井底压力变化及压力导数双对数曲线。

表 9　压裂段 2 的参数范围表

Tab. 9　Parameter range of fractured stage 2

参数	对象	最小值	最大值
初始压力 /MPa	油藏	12.950 0	38.850 0
井储 /(m^3·MPa^{-1})	压裂段 2	0.095 0	0.285 0
井表皮因子	压裂段 2	0.100 0	2.100 0
水平渗透率 /mD	层 1	0.265 0	0.795 0
	区域 1	12.500 0	37.500 0
	区域 2	150.000 0	450.000 0
	区域 3	100.000 0	300.000 0
区域复合半径 /m	区域 1	5.000 0	15.000 0
	区域 2	30.000 0	90.000 0
	区域 3	60.000 0	180.000 0

利用拉丁超立方抽样确定 1 000 组样本参数组合。将每组参数代入数值模拟软件计算出井底压力变化及压力导数，生成 1 000 组采样算例，基于算例训练出有效的多输出 RBF 神经网络代理模型。

用实测数据与代理模型预测值构造目标函数，然后用 PSO 算法搜索目标函数最小值，反求不确定参数值，反求的参数结果见表 10，平均相对误差 18.41%。将这组反求参数值代入油藏数值模拟软件中，拟合得到井底压力变化及压力导数，拟合结果见图 14。

表 10　压裂段 2 的反演参数表

Tab. 10　Inversion parameters of fractured stage 2

参数	准确值	反演值	相对误差	绝对误差
油藏初始压力 /MPa	26.500 0	26.500 0	0	—
井储 /(m^3·MPa^{-1})	0.190 0	0.098 6	—	0.091 4
井表皮因子	0.600 0	0.712 2	—	0.112 2
层 1 水平渗透率 /mD	0.530 0	0.571 1	7.76%	—
复合区域 1 水平渗透率 /mD	25.000 0	16.161 7	35.35%	—
复合区域 2 水平渗透率 /mD	300.000 0	253.386 5	15.54%	—
复合区域 3 水平渗透率 /mD	200.000 0	218.417 0	9.21%	—
复合区域 1 区域复合半径 /m	10.000 0	5.364 6	46.35%	—
复合区域 2 区域复合半径 /m	60.000 0	40.769 0	32.05%	—
复合区域 3 区域复合半径 /m	120.000 0	121.185 6	0.99%	—

3.3　结果讨论

如图 13 和图 14、表 8 和表 10 所示，本研究将多输出 RBF-PSO 反演框架首次应用于油田非均质径向复合油藏的实测数据。结果表明，该方法在动态历史拟合上取得了良好效果，构建的代理模型能够有效逼近该复杂地质模型下的真实流动响应。表 8 和表 10 中井储和井表皮由于真实值很小，使用了绝对误差衡量。案例 1 和案例 2 中反演参数的平均相对误差分别为 21.68% 和 18.41%，部分反演参数存在一定的相对误差为历史拟合中常出现的多解性问题。由于径向复合模型参数间存

在强耦合效应,例如内区流度降低与复合半径减小可能对压力导数曲线产生相似影响,导致目标函数多峰,即使在全局优化下亦难以获得唯一解。本文方法获得的历史拟合结果良好,对短期生产预测和开发方案调整有参考价值。

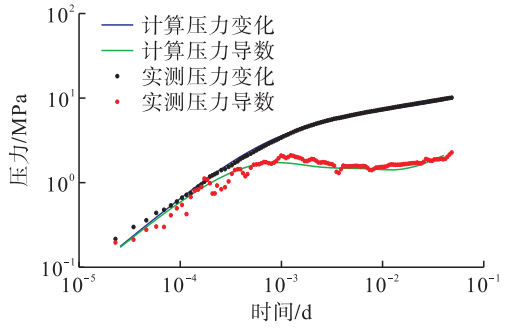

图 14　压裂段 2 历史拟合结果图

Fig. 14　History matching results of fractured stage 2

4　结论

本文提出了基于多输出 RBF 神经网络和 PSO 算法的油藏参数反演方法,并通过理论模型与实测案例系统验证了其有效性。主要结论如下。

1)方法效能优势显著。多输出 RBF 神经网络共享隐藏层特征与同步预测完整压力序列,其训练时间仅为传统单输出 RBF 神经网络模型训练时间的 2% 左右,且预测的导数曲线更为平滑、物理上更合理,避免了后者可能出现的非物理震荡。

2)复杂非均质案例应用可行。针对非均质径向复合油藏实测数据,本方法能有效反演多参数并实现良好的压力变化及其导数拟合。

3)本研究工作为油藏参数智能反演提供了一种高效、可供参考的新方法。该方法未来也可迁移到其他开发生产应用中,如注水优化问题。

参考文献:

[1] Liu Piyang, Zhang Kai, Yao Jun. Reservoir automatic history matching: Methods, challenges, and future directions [J]. Advances in Geo-Energy Research, 2023, 7 (2): 136-140.

[2] 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.
Li Daolun, Zha Wenshu. Theory and method of numerical well testing [M]. Beijing: Petroleum Industry Press, 2013.

[3] Abdulrazzaq F N, Hasan O F. A review of automatic history matching [J]. Materials Today: Proceedings, 2023, 80: 3817-3822.

[4] Thomas L K, Hellums L J, Reheis G M. A nonlinear automatic history matching technique for reservoir simulation models [J]. Society of Petroleum Engineers Journal, 1972, 12 (6): 508-514.

[5] Gavalas G R, Shah P C, Seinfeld J H. Reservoir history matching by Bayesian estimation [J]. Society of Petroleum Engineers Journal, 1976, 16 (6): 337-350.

[6] Szklarz S P, Rojas M, Kaleta M P. The optimization problem in model-reduced gradient-based history matching [J]. IFAC Proceedings Volumes, 2012, 45 (8): 13-18.

[7] 张　凯,路然然,周文胜,等. 无梯度多参数自动历史拟合方法[J]. 中国石油大学学报(自然科学版),2014,38(5):109-115.
Zhang Kai, Lu Ranran, Zhou Wensheng, et al. Multi-parameter gradient-free automatic history matching method [J]. Journal of China University of Petroleum (Edition of Natural Science), 2014, 38 (5): 109-115.

[8] Shams M, El-banbi A, Sayyouh H. Harmony search optimization applied to reservoir engineering assisted history matching [J]. Petroleum Exploration and Development, 2020, 47 (1): 154-160.

[9] Zhang Xiansong, Hou Jian, Wang Daigang, et al. An automatic history matching method of reservoir numerical simulation based on improved genetic algorithm [J]. Procedia Engineering, 2012, 29: 3924-3928.

[10] 周子琪,查文舒,李道伦,等. 基于径向基神经网络的油藏反演方法[J]. 合肥工业大学学报(自然科学版),2023,46(5):713-720.
Zhou Ziqi, Zha Wenshu, Li Daolun, et al. Reservoir inversion method based on RBF neural network [J]. Journal of Hefei University of Technology (Natural Science), 2023, 46 (5): 713-720.

[11] Ullah J, Li H, Soupios P, et al. Optimizing geothermal reservoir modeling: A unified Bayesian PSO and BiGRU approach for precise history matching under uncertainty [J]. Geothermics, 2024, 119: 102958.

[12] Zhao Yulong, Luo Ruike, Li Longxin, et al. A review on optimization algorithms and surrogate models for reservoir automatic history matching [J]. Geoenergy Science and Engineering, 2024, 233: 212554.

[13] Ma Xiaopeng, Zhang Kai, Zhao Hanjun, et al. A vector-to-sequence based multilayer recurrent network surrogate model for history matching of large-scale reservoir [J]. Journal of Petroleum Science and Engineering, 2022, 214: 110548.

[14] 李道伦,陈　刚,查文舒,等. 响应面法和 BFGS 算法在试井分析中的应用[J]. 中国科学技术大学学报,2018,48(5):400-408.
Li Daolun, Chen Gang, Zha Wenshu, et al. Application of

response surface method and BFGS algorithm in well test analysis [J]. Journal of University of Science and Technology of China, 2018, 48 (5): 400-408.

[15] 许恩华,查文舒,李道伦,等.基于支持向量回归的油藏瞬态压力拟合[J].合肥工业大学学报(自然科学版),2020,43(11):1570-1574.
Xu Enhua, Zha Wenshu, Li Daolun, et al. Reservoir history matching for transient pressure based on support vector regression [J]. Journal of Hefei University of Technology (Natural Science), 2020, 43 (11): 1570-1574.

[16] 高善露,查文舒,杨景海,等.基于集合卡尔曼滤波的大规模压裂参数反演方法[J].合肥工业大学学报(自然科学版),2020,43(9):1288-1292.
Gao Shanlu, Zha Wenshu, Yang Jinghai, et al. Parameter inversion method for large-scale fracturing based on ensemble Kalman filter [J]. Journal of Hefei University of Technology (Natural Science), 2020, 43 (9): 1288-1292.

[17] Liu Zhi, Hao Yuxiang, Li Daolun, et al. Multiparameter inversion of reservoirs based on deep learning [J]. SPE Journal, 2024, 29 (1): 126-137.

[18] Li Daolun, Liu Xuliang, Zha Wenshu, 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.

[19] Liu Xuliang, Li Daolun, Yang Jinghai, 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] Liu Xuliang, Zha Wenshu, Qi Zhankui, et al. Automatic reservoir model identification method based on convolutional neural network [J]. Journal of Energy Resources Technology, 2022, 144 (4): 043002.

[21] Liu Xuliang, Zha Wenshu, Li Daolun, et al. Automatic well test interpretation method for circular reservoirs with changing wellbore storage using one-dimensional convolutional neural network [J]. Journal of Energy Resources Technology, 2023, 145 (3): 033201.

[22] Shen Luhang, Li Daolun, Zha Wenshu, et al. Physical Asymptotic-Solution nets: Physics-driven neural networks solve seepage equations as traditional numerical solution behaves [J]. Physics of Fluids, 2023, 35 (2): 023603.

[23] Zhang Chengkai, Zhang Rui, Zhu Zhaopeng, et al. Bottom hole pressure prediction based on hybrid neural networks and Bayesian optimization [J]. Petroleum Science, 2023, 20 (6): 3712-3722.

[24] Zhang Daowei, Li Heng. Efficient surrogate modeling based on improved vision transformer neural network for history matching [J]. SPE Journal, 2023, 28 (6): 3046-3062.

[25] Zhang Jinding, Kang Jinzheng, Zhang Kai, et al. An efficient transformer-based surrogate model with end-to-end training strategies for automatic history matching [J]. Geoenergy Science and Engineering, 2024, 240: 212994.

[26] Shen Luhang, Li Daolun, Zha Wenshu, et al. Surrogate modeling for porous flow using deep neural networks [J]. Journal of Petroleum Science and Engineering, 2022, 213: 110460.

[27] Huang Kouyuan, Shen Liangchi, Weng Lisheng. Well log data inversion using radial basis function network [C]// 2011 IEEE International Geoscience and Remote Sensing Symposium, July 24-29, 2011, Vancouver, BC, Canada. New York: IEEE, 2011: 4439-4442.

[28] Memon P Q, Yong S P, Pao W, et al. Dynamic well bottom-hole flowing pressure prediction based on radial basis neural network [C]//Arai K, Kapoor S, Bhatia R. Intelligent Systems in Science and Information 2014, August 27-29, 2014, London, UK. Cham: Springer International Publishing, 2015: 279-292.

[29] Kingma D P, Ba J. Adam: A method for stochastic optimization [PP/OL]. V9. arXiv (2017-01-30) [2025-12-29]. https://doi.org/10.48550/arXiv.1412.6980.

[30] Loshchilov I, Hutter F. SGDR: Stochastic gradient descent with warm restarts [PP/OL]. V5. arXiv (2017-05-03) [2025-12-29]. https://doi.org/10.48550/arXiv.1608.03983.

[31] 查文舒,李道伦,卢德唐,等.井间干扰条件下 PEBI 网格划分研究[J].石油学报,2008,29(5):742-746.
Zha Wenshu, Li Daolun, Lu Detang, et al. PEBI grid division in inter-well interference area [J]. Acta Petrolei Sinica, 2008, 29 (5): 742-746.

[32] 弗朗索瓦·肖莱.Python 深度学习[M].张亮,译.2 版.北京:人民邮电出版社,2022.
Chollet F. Deep learning with Python [M]. Zhang Liang, trans. 2nd ed. Beijing: Posts & Telecom Press, 2022.