

DOI:10.3969/j.issn.1003-5060.2023.05.023

# 基于径向基神经网络的油藏反演方法

周子琪, 查文舒, 李道伦, 刘旭亮

(合肥工业大学 数学学院, 安徽 合肥 230601)

**摘要:**文章提出一种基于径向基(radial basis function, RBF)神经网络的油藏反演方法。该方法利用抽样生成的井底压力数据构造 RBF 神经网络模型,由 RBF 神经网络预测值与实际观测值的偏差定义目标函数,再利用粒子群算法(particle swarm optimization, PSO)对其进行优化,最终得到不确定参数的最优解和反演参数。与多项式拟合方法相比,RBF 神经网络方法具有更好的拟合结果和更高的精度,甚至在多项式拟合方法失效时,该方法也能得到很好的模拟结果。油田实际算例表明,该方法具有良好的拟合效果,能大幅提高反演效率,具有很好的应用前景。

**关键词:**油藏反演;径向基(RBF)神经网络;目标函数;优化算法;历史拟合

中图分类号:TE319

文献标志码:A

文章编号:1003-5060(2023)05-0713-08

## Reservoir inversion method based on RBF neural network

ZHOU Ziqi, ZHA Wenshu, LI Daolun, LIU Xuliang

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

**Abstract:** This paper proposes a reservoir inversion method based on radial basis function(RBF) neural network. In this method, the RBF neural network model is constructed by using the bottom hole pressure(BHP) data generated by sampling, and the objective function is defined by the deviation between the predicted value of the RBF neural network and the actual observed value, and then the particle swarm optimization(PSO) algorithm is used to optimize the objective function. Finally, the optimal solution of the uncertain parameters and the inversion parameters are obtained. Compared with the polynomial fitting method, the RBF neural network method has better fitting results and higher precision. Even when the polynomial fitting method fails, the RBF neural network method still works well. A practical example in oilfield shows that this method has good fitting effect, can greatly improve the inversion efficiency, and has a good application prospect.

**Key words:** reservoir inversion; radial basis function(RBF) neural network; objective function; optimization algorithm; history matching

油藏反演,即油藏历史拟合<sup>[1-3]</sup>,是油藏工作人员和地质工程师进一步了解油藏地下流体特征、预测油田生产动态、制定油田开发方案的重要手段之一<sup>[4-6]</sup>。为了使预测结果尽可能接近油藏的实际情况,需要进行油藏历史拟合,即根据现场实测的实际生产数据对油藏参数进行反演和修

改。油藏历史拟合是获得多种可靠的油藏模型并进行预测的有效途径。油藏反演是指获得一组油藏参数,如孔隙度、渗透率等,使模拟油藏模型计算的数据与实际数据相符。油藏历史拟合有助于发现和修正油藏描述数据中的误差,改进模型以及验证油藏描述的可靠性。因此,需要花费时间

收稿日期:2021-04-01

基金项目:国家科技重大专项资助项目(2017ZX05009005-002)

作者简介:周子琪(1996—),女,湖南常德人,合肥工业大学硕士生;

查文舒(1982—),男,安徽池州人,博士,合肥工业大学副教授,硕士生导师;

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: ldao@hfut.edu.cn.

和精力评估拟合结果,确定其是否符合预期。

根据开发过程和实现方法,油藏历史拟合可被分为人工历史拟合和自动历史拟合 2 类。人工历史拟合采用“试错法”,即油藏工程师根据数值模拟计算值与油藏实际观测值之间的偏差,对 1 个或多个油藏参数进行人工分析和修改,以减少历史拟合误差<sup>[7-8]</sup>。实际油藏一般有很多参数,而高精度油藏模型有大量网格。人工历史拟合法主观性强,耗时长,效率低。因此,计算机和优化算法被引入到油藏历史拟合中,完成自动调整油藏参数的工作,形成了自动历史拟合技术<sup>[9-10]</sup>。

油藏自动历史拟合始于 20 世纪 60 年代。文献<sup>[11]</sup>首次使用回归分析代替“试错法”,由此开创了自动历史拟合的研究。1973—1992 年是自动历史拟合研究的形成阶段,该阶段引入了非线性回归方法、梯度算法和最优控制理论<sup>[12-13]</sup>。1993—2002 年是自动历史拟合研究的发展阶段。自动历史拟合的基本方法已经从直接法、梯度法发展到随机法、智能算法,逐步形成了一系列启发式的自动历史拟合方法<sup>[14-16]</sup>。近年来,集合卡尔曼滤波被用于油藏历史拟合<sup>[17-19]</sup>。集合卡尔曼滤波是一种递归过滤器,适用于有大量参数的问题。

自动历史拟合方法主要包括目标函数<sup>[20]</sup>和优化算法 2 个部分。目标函数定义为模型的计算值与观测值之间的偏差,可以通过响应面模型、样条法、克里金法或基于克里金法的多项式加扰动的组合得到<sup>[21-22]</sup>。响应面法<sup>[23]</sup>出现于 20 世纪 90 年代初。它的基本思想是通过构造一个具有明确表达式的多项式来近似真实的函数关系,通过对多项式的分析,寻求最优工艺参数,解决多变量问题。20 世纪 90 年代,响应面法被引入油藏工程<sup>[24]</sup>。在响应面问题中,通常采用多项式函数进行逼近。由于响应变量与解释变量之间是非线性关系,用高阶多项式模型近似可能会出现龙格现象,并且随着变量数量的增加,计算成本也会以几何级数增长。

径向基函数(radial basis function, RBF)以空间距离为自变量。由于它的简单性和各向同性,近年来得到了迅速的发展,并在分散数据处理、微分方程求解等领域得到了广泛的应用。对于多元问题甚至高维问题,它比其他类型的基函数具有明显的优势。RBF 神经网络最初是由 Moody 和 Darken 在 1989 年提出的<sup>[25]</sup>。它属于前向神经网络类型,能够以任意精度逼近任意连续函数,处理系统中难以处理的分析规律。此外,

该方法具有较好的泛化能力,学习收敛速度较快。RBF 神经网络已成功应用于非线性函数的逼近等问题。虽然有一些类似于 RBF 神经网络技术的方法,如支持向量回归<sup>[26]</sup>,但这些方法复杂、计算成本高。

优化算法主要分为 2 大类:基于梯度的优化算法和进化类算法。梯度算法通过对目标函数中的未知参数进行微分来寻找最优值<sup>[27-30]</sup>。进化算法是一种基于种群的优化算法,如模拟退火算法<sup>[31]</sup>、神经网络算法<sup>[32]</sup>、粒子群(particle swarm optimization, PSO)算法<sup>[33]</sup>和遗传算法<sup>[34]</sup>。相对于基于梯度的算法容易陷入局部极小值,进化算法是一种更稳定、适用性更广的全局优化算法。

本文提出一种基于 RBF 神经网络和 PSO 算法的油藏反演方法。首先比较多项式拟合方法和 RBF 神经网络方法在相同试算次数下的拟合结果;然后减少试算次数再次比较;最后通过实验验证了 RBF 神经网络方法的有效性。

## 1 油藏反演方法

### 1.1 多项式拟合

多项式拟合的原理是找到近似的多项式曲线  $y = \phi(x)$ ,使其与  $y = f(x)$  的偏差最小,其中  $f(x)$  经过给定数据点  $p_i(x_i, y_i), i = 1, 2, \dots, m$ 。近似曲线在点  $p_i$  处的偏差为  $\delta_i = \phi(x_i) - y_i, i = 1, 2, \dots, m$ 。最小二乘法是最常用的方法,是根据偏差的最小二乘原则选择拟合曲线,即

$$\min_{\phi} \sum_{i=1}^m \delta_i^2 = \sum_{i=1}^m [\phi(x_i) - y_i]^2 \quad (1)$$

多项式拟合通常用二次多项式拟合。给定数据点  $(x_i, y_i), i = 1, 2, \dots, m$ ,用二次多项式  $\phi(x) = a_0 + a_1x + a_2x^2$  作为近似曲线,均方误差为:

$$Q(a_0, a_1, a_2) = \sum_{i=1}^m (a_0 + a_1x_i + a_2x_i^2 - y_i)^2 \quad (2)$$

通过求极值得到拟合曲线的正规矩阵方程:

$$\begin{bmatrix} m & \sum_{i=1}^m x_i & \sum_{i=1}^m x_i^2 \\ \sum_{i=1}^m x_i & \sum_{i=1}^m x_i^2 & \sum_{i=1}^m x_i^3 \\ \sum_{i=1}^m x_i^2 & \sum_{i=1}^m x_i^3 & \sum_{i=1}^m x_i^4 \end{bmatrix} \begin{bmatrix} a_0 \\ a_1 \\ a_2 \end{bmatrix} = \begin{bmatrix} \sum_{i=1}^m y_i \\ \sum_{i=1}^m x_i y_i \\ \sum_{i=1}^m x_i^2 y_i \end{bmatrix} \quad (3)$$

求解方程(3),得到系数  $\hat{a}_0, \hat{a}_1, \hat{a}_2$ ,拟合曲线

为  $\phi(x) = a_0 + a_1x + a_2x^2$ 。

### 1.2 RBF 神经网络

RBF 的基本思想是将低维线性不可分数据映射到高维空间,使其在高维空间中线性可分。与传统神经网络算法不同的是,RBF 神经网络不需要训练全局连接权值,只调整影响输出值的一些重要权值,提高了训练速度。

RBF 神经网络的结构是一种 3 层前馈网络。第 1 层为输入层,包括信号源节点;第 2 层为隐含层,隐含层单元的转换函数为 RBF,是对中心点径向对称、衰减的非负非线性函数;第 3 层为输出层,是对输入模式做出的响应。输入层空间到隐含层空间的变换是非线性的,而隐含层空间到输出层的空间变换是线性的。

在大多数情况下,高斯函数被设为 RBF,具体表达式为:

$$G(x) = \exp(-d^2/2\sigma^2) \quad (4)$$

其中: $d$  为矢量到各隐含层中心的距离,距离节点越近,对节点输出的影响越大; $\sigma$  为控制高斯函数平滑度的平滑因子。

网络的输出层对 RBF 作用的结果采用线性加权求和的形式。最后高斯 RBF 神经网络的输出为:

$$y_j = \sum_{i=1}^m \omega_{ij} \exp(-d^2/2\sigma^2), j = 1, 2, \dots, n \quad (5)$$

RBF 神经网络的总体结构如图 1 所示。

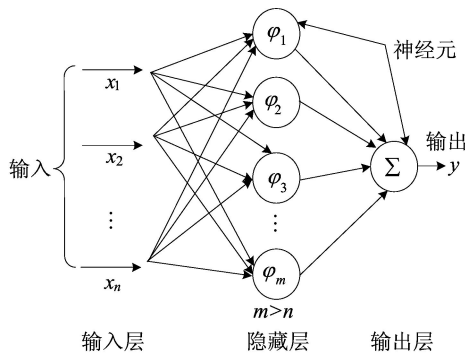


图 1 典型的 RBF 神经网络结构

神经网络训练包括 2 个阶段:无监督学习和监督学习。利用无监督学习方法得到高斯 RBF 的中心和方差,利用监督学习方法(即最小均方误差)得到隐含层对输出层的权值。具体内容如下。

(1) 选取训练样本集中的  $m$  个样本作为  $m$  个 RBF 的中心。

(2) 求解方差,公式如下:

$$\sigma_i = \frac{d_{\max}}{\sqrt{2m}}, i = 1, 2, \dots, m \quad (6)$$

其中: $d_{\max}$  为所选中心之间的最大距离; $m$  为隐含层节点数。

(3) 用最小均方误差计算隐含层与输出层之间神经元的连接权值。计算公式如下:

$$W = \Phi^+ d \quad (7)$$

$$\Phi^+ = (\Phi^T \Phi)^{-1} \Phi^T \quad (8)$$

其中, $d$  为期望的输出值。

### 1.3 目标函数

在油藏反演中,地层和井筒参数未知,而压力已知。油藏反演的目标是找到一组地层和井筒参数,使在这组合适的地层和井筒参数下,模拟的压力数据等于或接近实测的压力数据。因此定义 1 个目标函数反映模拟值和实际测量值之间的误差。

目标函数通常以加权平方和的形式表示,具体表达式为:

$$O_F = \sum_{j=1}^n \omega_j [D_{\text{obs}}^j - D_{\text{sim}}^j(x)]^2 \quad (9)$$

其中: $j$  为测量数据(压力、压力变化、压力导数)的时间点序号; $\omega_j$  为测量数据在  $j$  时间点的权重; $n$  为测量数据的时间点总数; $D_{\text{obs}}^j$  和  $D_{\text{sim}}^j(x)$  分别为测量数据值和模拟曲线; $x$  为不确定参数。

### 1.4 优化算法

因为油藏反演问题最初被考虑为最优控制问题<sup>[27]</sup>,所以一系列优化算法被应用到油藏反演中,包括基于梯度的算法、进化类算法等;不同的优化算法适用于不同的油藏。本文将 PSO 算法应用于油藏反演中。

PSO 算法是一种随机搜索方法,它来自于对鸟类狩猎行为的研究。在 PSO 优化算法中,每个优化问题的解都像搜索空间中的 1 只鸟,称之为粒子。每个粒子都有 1 个由优化函数决定的适应度值,每个粒子都有 1 个速度,这个速度决定了它们飞行的方向和距离;然后粒子跟随当前的最优粒子搜索解空间。

PSO 优化算法从一组随机粒子(随机解)出发,通过迭代得到最优解。在每次迭代中,粒子通过跟踪 2 个“极端”来更新自身。第 1 个是粒子自身找到的最优解,称为个体极值  $p_{\text{best}}$ ;另一个极值是目前为止所有粒子中的最优解,这个极值是全局极值  $g_{\text{best}}$ 。用变量  $p_{\text{best}}$  来记录个体搜索的最优解,用  $g_{\text{best}}$  记录整个群体在一次迭代中搜索的最优解。粒子速度和位置的更新公式如下:

$$v_{i+1} = \omega v_i + c_1 \text{rand}() [p_{\text{best}}(i) - z_i + c_2 \text{rand}() (g_{\text{best}} - z_i)] \quad (10)$$

$$z_{i+1} = z_i + v_{i+1} \quad (11)$$

其中:  $v_i$  为第  $i$  个粒子的速度;  $\omega$  为惯性权重;  $c_1$  和  $c_2$  为学习参数;  $\text{rand}()$  为  $0 \sim 1$  之间的随机数;  $p_{\text{best}}(i)$  为第  $i$  个粒子搜索的最优值;  $g_{\text{best}}$  为搜索整个集群的最优值;  $z_i$  为第  $i$  个粒子的当前位置。

标准 PSO 算法的步骤如下。

(1) 初始化 PSO, 包括种群大小  $N$ , 每个粒子的位置  $x_i$  和速度  $v_i$ 。

(2) 计算每个粒子的适应度值  $f_i$ 。

(3) 对每个粒子的适应度值  $f_i$  与个体极值  $p_{\text{best}}(i)$  进行比较。若  $f_i > p_{\text{best}}(i)$ , 则将  $p_{\text{best}}(i)$  替换为  $f_i$ 。

(4) 对于每个粒子, 将其适应度值  $f_i$  与全局极值  $g_{\text{best}}$  进行比较。若  $f_i > g_{\text{best}}$ , 则将  $g_{\text{best}}$  替换为  $f_i$ 。

(5) 根据(10)式和(11)式更新粒子的速度和位置。

(6) 若满足结束条件(误差足够小或达到最大循环次数), 则退出算法; 否则返回步骤(2)。

### 1.5 油藏反演方法步骤

油藏反演方法的步骤如下。

(1) 确定油藏反演的不确定参数及其范围。

(2) 用拉丁超立方抽样法确定试算算例。

(3) 利用油藏数值模拟软件计算井底压力、压力变化及压力导数。

(4) 利用步骤(3)中的数据构造高斯 RBF 神经网络, 并定义目标函数。

(5) 利用 PSO 算法最小化目标函数, 得到 1 组不确定参数值。

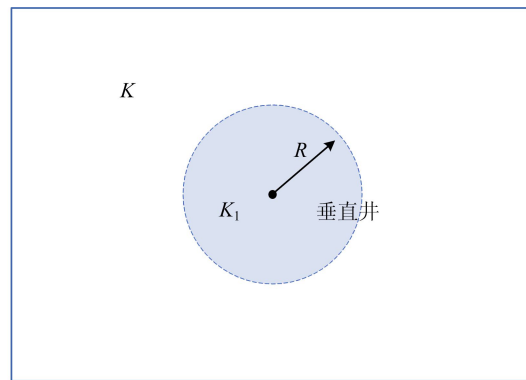
(6) 利用步骤(5)中获得的不确定参数值, 计算井底压力、压力变化和压力变化导数; 然后将计算数据与实测数据进行比较。

## 2 油藏反演方法对比实验

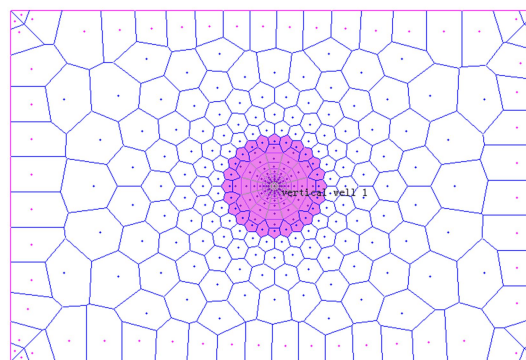
本节对多项式拟合方法和 RBF 神经网络方法进行比较。

### 2.1 模型描述

矩形油藏中心为一口直井, 如图 2 所示, 其中存在 5 个不确定参数: 油藏渗透率  $K$ 、区域渗透率  $K_1$ 、井筒储量  $C$ 、井表皮系数  $S$  和复合半径  $R$ 。



(a) 油藏及井



(b) 渗透率模型

图 2 矩形油藏模型

### 2.2 相同试算算例数的拟合结果对比

首先, 采用拉丁超立方抽样法确定 120 组试算算例; 然后, 将每组试算算例带入油藏数值模拟软件中, 计算相应的井底压力值; 最后, 根据井底压力值可以计算压力变化和压力导数数据。

将 120 组试算算例的第 1 组算例作为实际值。分别进行多项式拟合和运用 RBF 神经网络方法。

多项式拟合采用最小二乘法对其余 119 组试算算例进行拟合, 构造多项式函数; RBF 神经网络方法将 RBF 的中心距离值  $d$  设为 1, 利用其余 119 组试算算例构建有 10 个隐含层的高斯 RBF 神经网络。利用实际数据值和多项式函数或高斯 RBF 神经网络定义目标函数; 在得到目标函数后, 利用 PSO 算法获得不确定参数的最优值; 最后将估计的不确定参数输入到油藏数值模拟软件中, 产生井底压力、压力变化和压力导数数据。

基于多项式的拟合结果如图 3 所示, 基于 RBF 神经网络方法的拟合结果如图 4 所示。从图 3、图 4 可以看出, 基于多项式拟合的压力导数在  $0.5 \sim 1.0 d$  之间拟合效果不佳, 而基于 RBF 神经网络的拟合结果较好。结果表明, RBF 神经网络方法优于多项式拟合方法。




图 3 基于多项式的自动拟合结果




图 4 基于 RBF 神经网络的自动拟合结果

### 2.3 减少试算算例数的拟合结果对比

在最小二乘多项式拟合中,为了使得到的多项式具有唯一性,需要保证试算算例数大于等于多项式项数;否则最小二乘多项式拟合方法将失效。然而用 RBF 神经网络方法可以解决多项式拟合方法的这个缺点,RBF 神经网络方法只需要较少的试算算例。为了验证这一点,逐渐减少试算算例数,分别分析最小二乘多项式拟合和 RBF 神经网络方法的拟合结果。本文考虑 2 种情况:① 将试算算例

数减少 1/2;② 将试算算例数减少至 20 组。

为了将试算算例数减少 1/2,采用拉丁超立方抽样生成了 60 组试算算例数。同样将第 1 组作为实际值,分别用最小二乘多项式拟合和 RBF 神经网络方法反求不确定参数。对应的井底压力、压力变化及压力导数拟合结果如图 5 和图 6 所示。




图 5 算例数为 60 时基于多项式的自动拟合结果




图 6 算例数为 60 时基于 RBF 神经网络的自动拟合结果

从图 5、图 6 可以看出,最小二乘多项式拟合的压力导数在 0.1~2.0 d 之间拟合得不好,而

RBF 神经网络方法拟合结果较好。结果表明,当样本数据减少 1/2 时,RBF 神经网络方法仍然可以得到很好的结果,而最小二乘多项式拟合得到的结果不好。

当试算算例数减少到 20 时,最小二乘多项式拟合失效。然而 RBF 神经网络方法仍然可以得到很好的结果,RBF 神经网络方法的结果如图 7 所示。这说明 RBF 神经网络方法是一种高效的油藏反演方法。





图 7 算例数为 20 时基于 RBF 神经网络的自动拟合结果

### 3 实际案例研究

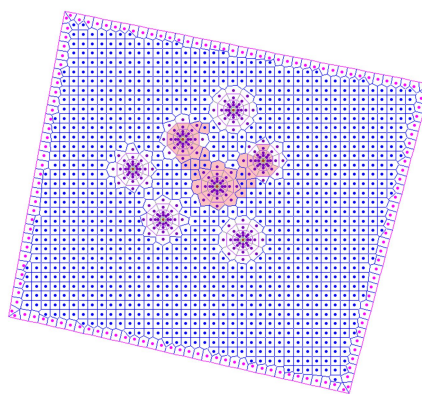
#### 3.1 油藏模型描述

在大庆油田某区块中选择 1 组井群进行油藏反演。大庆油田是我国最大的油田,也是世界上为数不多的特大砂岩油田之一。它由 52 个油气田组成,含油面积约为 6 000 km<sup>2</sup>,自开发以来,取得了良好的开发效果。

该区块从 1965 年开始开发,成为大庆地区的主要油藏<sup>[35]</sup>。井群如图 8 所示,其中共有 7 口井,平均厚度 5.8 m。需要反求的不确定参数为:层渗透率  $K$ 、红色标记区域的渗透率  $K_1$  和水饱和度  $s_w$ 、生产井 7 井的井筒储量  $C$  和井表皮系数  $S$ 。它们的取值范围分别为 [500 mD, 2 000 mD]、[1 000 mD, 3 000 mD]、[0.5, 0.8]、[0.1 m<sup>3</sup>/MPa, 1.0 m<sup>3</sup>/MPa] 和 [0, 3]。



(a) 油藏形状及井分布



(b) 渗透率

图 8 实际案例油藏模型

#### 3.2 拟合结果

根据 1.5 节中的步骤,由拉丁超立方体抽样生产 120 组试算算例,然后反求不确定参数值,不确定参数值的反求结果被代入油藏数值模拟软件中拟合得到压力、压力变化和压力导数,如图 9 所示。




图 9 实际案例的自动拟合结果对比

由图9可知,RBF神经网络方法在该实际案例中得到的曲线拟合结果良好,由此验证了该方法的有效性。

#### 4 结 论

本文提出了一种基于RBF神经网络的油藏反演方法。首先确定不确定参数,将拉丁超立方抽样生成的试算算例输入到油藏数值模拟软件中生成井底压力数据;然后建立RBF神经网络,拟合压力变化和压力导数;在此基础上定义了表示计算值与实际观测值之间偏差的目标函数;最后采用PSO优化算法对目标函数进行优化,得到不确定参数的最优解。本文还对设计的油藏模型进行了模拟,比较了最小二乘多项式拟合和RBF神经网络方法,并将RBF神经网络方法应用于油藏反演,得到了较好的拟合结果。与最小二乘多项式拟合相比,RBF神经网络方法具有更高的精度且不需要较多的试算算例数。在相同试算算例数下,RBF神经网络方法的拟合结果一般优于最小二乘多项式拟合。当试算算例数减少到最小二乘多项式拟合失效的数目时,RBF神经网络方法仍能得到很好的拟合结果。通过实际案例验证了本文方法的有效性,且精度高,所需试算算例数少,具有比较广阔的应用前景。

#### [参 考 文 献]

- [1] OLIVER D S, YAN C. Recent progress on reservoir history matching: a review[J]. *Computational Geosciences*, 2011, 15(1): 185-221.
- [2] ZHAO Y, FOROUZANFAR F, REYNOLDS A C. History matching of multi-facies channelized reservoirs using ESMDA with common basis DCT[J]. *Computational Geosciences*, 2017, 21(5/6): 1343-1364.
- [3] CHAI Z, YAN B, KILLOUGH J E, et al. An efficient method for fractured shale reservoir history matching: the embedded discrete fracture multi-continuum approach [J]. *Journal of Petroleum Science and Engineering*, 2018, 160: 170-181.
- [4] 刘姣姣,刘志军,刘倩,等.基于数值试井法的神木气田多层压裂气井产能评价[J]. *非常规油气*, 2020(5): 75-82.
- [5] 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(4): 1-8.
- [6] 谢晶,罗沛,杨云,等.东坪基岩气藏压力恢复试井曲线特征识别及解释研究[J]. *非常规油气*, 2020(3): 90-95.
- [7] SALERI N G, TORONYI R M. Engineering control in reservoir simulation: part I [C]//SPE Annual Technical Conference and Exhibition, Houston, T X; Society of Petroleum Engineers, 1988: 1-42.
- [8] MATTAX C C, DALTON R L. Reservoir simulation[J]. *Journal of Petroleum Technology*, 1990, 42(6): 692-695.
- [9] HERZYK D J, BUSSIÈRE J L. Immunotoxicology strategies for pharmaceutical safety assessment [M]. Hoboken, N J; John Wiley & Sons, Inc., 2008: 299-317.
- [10] CHAVENT G, DUPUY M, LEMONNIER P. History matching by use of optimal theory[J]. *Society of Petroleum Engineers Journal*, 1975, 15(1): 74-86.
- [11] JACQUARD P, JAIN C. Permeability distribution from field pressure data [J]. *Society of Petroleum Engineers Journal*, 1965, 5(4): 281-294.
- [12] CHEN W H. A new algorithm for automatic history matching[J]. *Society of Petroleum Engineers Journal*, 1974, 14(6): 593-608.
- [13] WASSERMAN M L, EMANUEL A S, SEINFELD J H. Practical applications of optimal-control theory to history-matching multiphase simulator models[J]. *Society of Petroleum Engineers Journal*, 1975, 15(4): 347-355.
- [14] OUEENES A, BHAGAVAN S. Application of simulated annealing and other global optimization methods to reservoir description: myths and realities [C]//SPE Annual Technical Conference and Exhibition, Louisiana: [s. n.], 1994: 547-561.
- [15] SEN M K, DATTA G A, STOFFA P L, et al. Stochastic reservoir modeling using simulated annealing and genetic algorithm[J]. *SPE Formation Evaluation*, 1995, 10(1): 49-56.
- [16] GOMEZ S, GOSSELIN O, BARKER J W, et al. Gradient-based history-matching with a global optimization method [C]//SPE Annual Technical Conference and Exhibition, Houston, Texas; Society of Petroleum Engineers, 1999: 1-13.
- [17] CHANG H, ZHANG D. History matching of stimulated reservoir volume of Shale-Gas reservoirs using an iterative ensemble smoother[J]. *SPE Journal*, 2017, 23(2): 346-366.
- [18] ZHANG Y, OLIVER D S, CHEN Y, et al. Data assimilation by use of the iterative ensemble smoother for 2D facies models[J]. *SPE Journal*, 2015, 20(1): 169-185.
- [19] 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.
- [20] BERTOLINI A C, SCHIOZER D J. Influence of the objective function in the history matching process[J]. *Journal of Petroleum Science and Engineering*, 2011, 78(1): 32-41.
- [21] HE J, XIE J, WEN X, et al. Improved proxy for history matching using proxy-for-data approach and reduced order modeling [C]//SPE Western Regional Meeting, Garden Grove; Society of Petroleum Engineers, 2015: 855-867.
- [22] BUSBY D, FREAILLE M. Adaptive design of experiments for calibration of complex simulators: an application to uncertainty quantification of a mature oil field[J]. *Journal of Physics: Conference Series*, 2008, 135: 12-26.
- [23] KHURI A I, MUKHOPADHYAY S. Response surface methodology[J]. *Wiley Interdisciplinary Reviews: Compu-*

- tational Statistics, 2010, 2(2): 128-149.
- [24] AGARWAL R, LI Y K, NGHIEM L. A regression technique with dynamic-parameter selection for phase behavior matching[C]//SPE California Regional Meeting. Ventura: Society of Petroleum Engineers, 1987: 207-214.
- [25] MOODY J, DARKEN C J. Fast learning in networks of locally-tuned processing units [J]. Neural Computation, 1989, 1(2): 281-294.
- [26] GUO Z, REYNOLDS A C. Robust life-cycle production optimization with a support vector regression proxy[J]. Society of Petroleum Engineers Journal, 2018, 23(6): 2409-2427.
- [27] 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.
- [28] RODRIGUES J, WAECHTER A, CONN A R, et al. Combining adjoint calculations and Quasi-Newton methods for automatic history matching [J]. Computational Geosciences, 2006, 10(1): 119-136.
- [29] GAVALAS G R, SHAH P C, SEINFELD J H. Reservoir history matching by Bayesian estimation [J]. Old SPE Journal, 1976, 16(6): 337-350.
- [30] KOLDA T G, OLEARY D P, NAZARETH L. BFGS with update skipping and varying memory[J]. SIAM Journal on Optimization, 1998, 8(4): 1060-1083.
- [31] MASCHIO C, SCHIOZER D J. A new methodology for history matching combining iterative discrete Latin Hypercube with multi-start simulated annealing[J]. Journal of Petroleum Science and Engineering, 2018, 169: 560-577.
- [32] FOROUD T, SEIFI A, AMINSHAHIDI B. Assisted history matching using artificial neural network based global optimization method—applications to Brugge field and a fractured Iranian reservoir[J]. Journal of Petroleum Science and Engineering, 2014, 123: 46-61.
- [33] MOHAMED L, CHRISTIE M, DEMYANOV V. Comparison of stochastic sampling algorithms for uncertainty quantification[J]. Society of Petroleum Engineers Journal, 2010, 15(1): 31-38.
- [34] XAVIER C R, SANTOS E P D, VIEIRA V D F, et al. Genetic algorithm for the history matching problem[J]. Procedia Computer Science, 2013, 18(1): 946-955.
- [35] LI D L, YANG J, LU D T. Thief zone identification based on transient pressure analysis; a field case study[J]. Journal of Petroleum Exploration and Production Technology, 2016, 1(6): 63-72.

(责任编辑 朱晓临)

## (上接第 669 页)

擦角和压缩模量的影响程度最大, 膨润土质量比对黏聚力的影响程度最大。

(4) 配制土体相似材料过程中, 含水量对黏聚力指标的影响较显著, 且水与膨润土相互作用, 应严格控制其含水量。

## [参 考 文 献]

- [1] 张云鹏, 王浩, 魏新宇. 爆破地震作用下边坡稳定性分析与振动相似模型试验[J]. 矿业研究与开发, 2019, 39(4): 86-91.
- [2] 万露, 辛保泉, 郭明东, 等. 基于模型相似理论的尾矿库溃坝试验研究[J]. 矿业研究与开发, 2018, 38(12): 66-71.
- [3] 王风云, 袁继坤, 杨传亮. 隧道模型试验中软弱围岩相似材料配合比试验研究[J]. 安徽建筑大学学报(自然科学版), 2020, 28(4): 8-13.
- [4] 王志佳, 揭基红, 李胜民, 等. 独龙江隧道岩爆相似材料配比试验研究[J]. 防灾减灾工程学报, 2020, 40(2): 279-285.
- [5] 王维强, 刘耀儒. 基于地质力学模型试验的岩体相似材料配比研究[J]. 青海大学学报(自然科学版), 2020, 38(1): 44-52.
- [6] 宁弈冰, 唐辉明, 张勃成, 等. 基于正交设计的岩石相似材料配比研究及底摩擦物理试验应用[J]. 岩土力学, 2020, 41(6): 2009-2020.
- [7] 阮博, 罗先启. 磁性岩土相似材料物理力学性能试验研究[J]. 地下空间与工程学报, 2019, 15(1): 45-51.
- [8] 陈政律, 吴洁, 张俊儒. 地下工程模型试验中围岩相似材料的配制研究[J]. 现代隧道技术, 2018, 55(增刊 2): 102-107.
- [9] 周辉, 陈珺, 张传庆, 等. 低强度高脆岩爆模型材料试验研究[J]. 岩土力学, 2019, 40(6): 2039-2049.
- [10] 周慧颖, 李树忱, 段壮, 等. 玄武岩相似材料配制及其物理力学参数研究[J]. 人民长江, 2021, 52(6): 130-135.
- [11] 崔雪婷, 张子东, 范珊. 基于相似理论的力学模型试验材料研究[J]. 人民珠江, 2019, 40(5): 82-86.
- [12] 詹志发, 贺建先, 郑博文, 等. 边坡模型相似材料配比试验研究[J]. 地球物理学报, 2019, 34(3): 1236-1243.
- [13] 杨何, 张振波, 侯宏韬, 等. 相似土体原材料配比试验研究[J]. 建筑结构, 2021, 51(增刊 1): 1905-1909.
- [14] 窦远明, 王建宁, 田贵州, 等. 基于正交试验的软弱土质相似材料配比研究[J]. 铁道科学与工程学报, 2017, 14(3): 480-487.
- [15] 窦远明, 王建宁, 朱旭曦, 等. 软弱土质类相似材料的配比试验结果分析[J]. 水利水电技术, 2017, 48(5): 128-135.
- [16] 李国梁, 康后金, 韩超, 等. 深基坑大型物理模拟试验土质相似材料的研究[J]. 公路, 2011, 56(10): 184-187.
- [17] 廖圆冰, 魏雯, 陈仁春, 等. 基于正交设计的土质相似材料配比试验研究[J]. 福州大学学报(自然科学版), 2016, 44(4): 570-576.
- [18] 徐楚, 胡新丽, 何春灿, 等. 水库型滑坡模型试验相似材料的研制及应用[J]. 岩土力学, 2018, 39(11): 4287-4293.

(责任编辑 张淑艳)