

文章编号: 0253-2697(2024)10-1522-07 DOI:10. 7623/syxb202410006

基于 IMA-AmMLP 模型的 CO₂ 驱最小混相压力预测

骆正山¹ 张景奇¹ 骆济豪² 王小完¹

(1. 西安建筑科技大学管理学院 陕西西安 710055; 2. 北京理工大学睿信学院 北京 102488)

摘要:最小混相压力是衡量油藏能否达到混相驱的标准。为了对最小混相压力进行精准预测,运用改进蜉蝣算法(IMA)优化多层感知机(MLP)的预测模型。运用注意力机制实现对最小混相压力影响因素的提取;通过引入混沌 Sobol 序列、非线性惯性权重和反向学习的方法增强蜉蝣算法寻优能力,为多层感知机提供最优的权值和阈值,进而构建 IMA-AmMLP 最小混相压力预测模型;并以吉林油田实际区块为例,对使用效果进行了验证。验证结果表明,IMA-AmMLP 模型的预测结果与实际值的拟合度更高,其平均绝对误差为 1.036 MPa,平均绝对百分误差为 0.024,均方根误差为 0.835,均优于原始模型。研究结果表明,IMA-AmMLP 模型能够更准确地预测最小混相压力,可以为运用 CO₂ 驱开采油藏提供参考。

关键词:最小混相压力;多层感知机;惯性权重;蜉蝣优化算法;注意力机制

中图分类号:TE357

文献标识码:A

Prediction of minimum miscibility pressure for CO₂ flooding based on the IMA-AmMLP model

Luo Zhengshan¹ Zhang Jingqi¹ Luo Jihao² Wang Xiaowan¹

(1. School of Management, Xi'an University of Architecture and Technology, Shaanxi Xi'an 710055, China;

2. Ruixin Institute, Beijing Institute of Technology, Beijing 102488, China)

Abstract: The minimum miscibility pressure (MMP) is a critical parameter that determines whether a reservoir can be explored by miscible flooding. To accurately predict the MMP, the multi-layer perceptron (MLP) prediction model was optimized using an improved mayfly algorithm (IMA). The attention mechanism was used to extract the factors affecting MMP; the optimization capability of IMA was enhanced by incorporating chaotic Sobol sequences, nonlinear inertia weights, and reverse learning methods. These improvements can provide optimal weights and thresholds for the MLP, leading to the establishment of the IMA-AmMLP model for MMP prediction. The model was validated by the case study of a block in Jilin oilfield. The results demonstrate that the IMA-AmMLP model exhibit a higher degree of fitting between the predicted and actual values, with a mean absolute error (MAE) of 1.036 MPa, a mean absolute percentage error (MAPE) of 0.024, and a root mean square error (RMSE) of 0.835, and the values were all superior to those of the original model. This indicates that the IMA-AmMLP model can more accurately predict MMP, providing a valuable reference for the exploitation and management of reservoirs using CO₂ flooding in fields.

Key words: minimum miscibility pressure; multilayer perceptron; inertia weight; mayfly optimization algorithm; attention mechanism

引用:骆正山,张景奇,骆济豪,王小完. 基于 IMA-AmMLP 模型的 CO₂ 驱最小混相压力预测[J]. 石油学报, 2024, 45(10): 1522-1528.

Cite: LUO Zhengshan, ZHANG Jingqi, LUO Jihao, WANG Xiaowan. Prediction of minimum miscibility pressure for CO₂ flooding based on the IMA-AmMLP model[J]. Acta Petrolei Sinica, 2024, 45(10): 1522-1528.

注二氧化碳驱替原油技术具有适用范围广、成本低、环保安全等优点,尤其是混相驱,在一次采油效率仅达到 40% 的情况下,混相驱的平均采收率可达 90% 以上。但由于环境的特殊和设施的限制,在现场实时检测困难的情况下,进行精准的最小混相压力(MMP)预测是保证 CO₂ 混相驱顺利进行、提高采收率的一项

重要措施^[1-3]。目前,最小混相压力的确定方法主要分为实验法和理论公式法。实验法^[4-6]可以精准测定最小混相压力,但对仪器要求精密、实验成本高且耗时长;理论公式法又分为经验模型和半经验模型,经验模型^[7]通过大量以往实践总结凝练而成,而半经验模型^[8-10]在经验模型的基础上融入机理支撑。这些模型

基金项目:国家自然科学基金项目(No. 41877527)资助。

第一作者:骆正山,男,1969 年 8 月生,2009 年获西安建筑科技大学博士学位,现为西安建筑科技大学教授、博士生导师,主要从事系统工程理论与方法、信息管理与信息系统等研究。Email:luozhengshan@163.com

通信作者:张景奇,女,1999 年 7 月生,2021 年获郑州航空工业管理学院学士学位,现为西安建筑科技大学硕士研究生,主要从事油气藏流体相态及注气提高采收率研究。Email:2435336196@qq.com

操作简单、应用方便,但使用条件高、适用范围具有针对性,没有统一的公式可供参照。

在实际进行油藏开采的过程中,最小混相压力会随着环境的改变发生变化,实验方法和理论公式都难以达到即时、精准的预测要求。因此,引入机器学习算法,借助其强大的学习能力和精准的拟合性能进行最小混相压力预测成为一种新的研究方法。以多层感知机(MLP)作为基本模型,运用注意力机制的打分函数按照影响因素的重要程度对多层感知机的初始权重进行赋值,实现最小混相压力影响因素的定量分析。为了提高算法效率,利用改进的蜉蝣算法(IMA)进行了权值阈值寻优,解决了蜉蝣算法容易陷入局部最优进而早衰的问题。从而构建了基于注意力机制的 IMA-AmMLP 最小混相压力预测模型,

1 基础理论

1.1 最小混相压力影响因素

最小混相压力是在目前油藏条件下可以使微观驱替效率理论上达到 100% 的最小驱替压力,主要受油藏温度、原油组分和注入气组成影响。油层温度是引起原油黏度、溶解度、饱和压力等油气物理化学参数变化的必要条件。混相驱是在 CO₂ 注入压力达到一定值时,气体经过多级接触与原油达到完全混相,因此不同条件的变化势必会影响最小混相压力。

Shokir^[11]研究表明,温度越高,最小混相压力越大,并在此基础上建立了最小混相压力经验模型。不同的原油组分与注入的 CO₂ 气体会产生不同程度的交互作用。由于组分过于复杂,大多数研究按照碳原子数量分成挥发组分(CH₄ 和 N₂)、中间组分(CO₂、H₂S 和 C₂—C₄)和重质组分(C₅₊) 3 个拟组分,运用挥发组分摩尔分数、中间组分摩尔分数和重质组摩尔质量进行衡量。宋兆杰等^[12]研究表明:挥发组分摩尔分数越高,最小混相压力越大;中间组分摩尔分数越高,最小混相压力越小。注入气中的杂质含量也会对最小混相压力造成影响。常见的杂质有甲烷、N₂、H₂S 和气态烃,杂质的种类及含量会对最小混相压力造成不同的影响。

因此,以油藏温度、重质烃摩尔质量、挥发烃组分摩尔分数、中间烃组分摩尔分数、注入气中 C₂—C₄ 的摩尔分数和 C₅、C₆ 的摩尔分数作为模型的输入变量。

1.2 多层感知机模型

多层感知机模型是人工神经网络模型中的一种经典模型,运用输入层、隐藏层、输出层的组织结构描述变量间复杂映射关系^[13]。根据通用近似定理^[14],多层感知机凭借非线性隐含层可以拟合任意函数关系,与

BP、DNN 等神经网络相比,具有更高的灵活性^[15-16]。多层感知机模型结构如图 1 所示。

2 改进蜉蝣优化算法

蜉蝣优化算法(MA)由 Zervoudakis 提出^[17]。该算法保留了智能群体优化算法的主要优点,每个个体作为候选解 $X = (x_1, x_2, \dots, x_n)$,依靠个体和社会飞行经验的动态交互确定飞行方向和速度 $v = (v_1, v_2, \dots, v_d)$ 指引全局搜索寻找最优解,并在此基础上根据蜉蝣特有的习性求偶舞蹈提升局部搜索能力,融入交叉变异进化的思想进行交配产生子代,逐步淘汰劣势个体,保留优质解。




图 1 多层感知机结构
Fig. 1 Multi-layer perceptron structure

蜉蝣群体中包含雄性和雌性两类个体,雄性个体进行探索,雌性个体跟随。雄性个体位置更新公式为:

$$x_{ij}(t+1) = x_{ij}(t) + v_{ij}(t) \tag{1}$$

雌性个体跟随移动的位置更新公式为:

$$y_{ij}(t+1) = y_{ij}(t) + u_{ij}(t) \tag{2}$$

为了提高迭代过程中的变异程度,通过雌雄交配的方式产生下一代:

$$o_1 = LM + (1 - L)F \tag{3}$$

$$o_2 = LF + (1 - L)M \tag{4}$$

2.1 改进 Sobol 序列初始化种群

种群初始化分布不均匀将导致种群陷入局部最优解,致使迭代提前结束。为了解决这一问题,可以运用混沌方法初始化种群,如 Tent 混沌方法、Cubic 混沌方法等^[18]。但这些方法的不确定性强、存在不稳定点,为了削弱这些负面影响,同时保留混沌方法的随机性,运用 Sobol 序列均匀混沌方法的不稳定性,产生高遍历性和多样性的初始种群。Sobol 序列是一种产生低偏差计算中的随机数的方法,在确定起点和终点后,选择合理的采样

方向,在高维空间中生成均匀分布的点集,使得这些点在微观和宏观上都具有优异的均匀性和周期性^[19]:

$$x_n = x_{\min} + k_n \cdot (x_{\max} - x_{\min}) \tag{5}$$

其中:

$$k_{n-1} = \begin{cases} \mu k_n, k_n < 0.5 \\ \mu(1 - k_n), k_n \geq 0.5 \end{cases} \tag{6}$$

设置粒子数量为 200,改进前后粒子初始化结果如图 2 所示。




图 2 粒子初始化情况
Fig.2 Particle initialization situation

2.2 反向学习策略

反向学习机制(OBL)的主要思想是通过光学反射原理计算出当前解的反向解,为解决问题提供加倍的候选方案^[20-21]。蜉蝣种群在搜寻过程中,种群信息利用不充分。针对该问题,引入反向学习策略,扩大个体更新范围,提高靠近最优解的概率^[22-23]。改进后的蜉蝣雄性个体反向解位置为:

$$\begin{cases} x_{ij}^*(t) = k[a_j(t) + b_j(t)] - x_{ij}(t) \\ a_j(t) = \min[x_{1j}(t), \dots, x_{mj}(t)] \\ b_j(t) = \max[x_{1j}(t), \dots, x_{mj}(t)] \end{cases} \tag{7}$$

改进后的蜉蝣雌性个体反向解位置为:

$$\begin{cases} y_{ij}^*(t) = k[c_j(t) + d_j(t)] - y_{ij}(t) \\ c_j(t) = \min[y_{1j}(t), \dots, y_{mj}(t)] \\ d_j(t) = \max[y_{1j}(t), \dots, y_{mj}(t)] \end{cases} \tag{8}$$

在 $x_{ij}(t)$ 、 $x_{ij}^*(t)$ 、 $y_{ij}(t)$ 、 $y_{ij}^*(t)$ 中各自保留适应度前一半的个体,作为改进后的雄性和雌性 $x'_{ij}(t)$ 、 $y'_{ij}(t)$ 。

2.3 非线性惯性权重指引

Tuppadung 等^[24]研究发现,在智能种群优化算法中增加惯性权重可以实现对全局勘测能力和局部开发能力的调控。将非线性惯性权重加入蜉蝣优化算法中引导个体位置更新,通过多次试验得到:

$$\omega(t) = \omega_{\max} - (\omega_{\max} - \omega_{\min}) \sin\left[\frac{\pi}{2} \left(\frac{t}{T_{\max}}\right)\right]^3 \tag{9}$$

其中, $\omega_0 = 1.0$,调整前后惯性权重递减趋势如图 3 所示。




图 3 惯性权重因子调整
Fig.3 Inertial weight factor adjustment graph

将式(9)代入式(1)、式(2)中,得到的位置更新:

$$x_{ij}(t+1) = \omega(t) \cdot x'_{ij}(t) + v_{ij}(t) \tag{10}$$

$$y_{ij}(t+1) = \omega(t) \cdot y'_{ij}(t) + u_{ij}(t) \tag{11}$$

3 模型构建

3.1 构建 IMA-AmMLP 模型

为了充分发挥 MLP 的结构优势,同时提高模型预测精度,对 MLP 进行改进。

3.1.1 引入注意力机制

注意力机制是根据人脑会首先处理自己所认为最重要的信息这一特点所构建的,其核心在于从先验信

息中提取各个特征及其关系,并按其对目标的作用程度分配权重,后期由权重决定对信息进行加工的程度^[25]:

$$a_i = \frac{\exp[s(h_i, \beta)]}{\sum_1^z \exp[s(h_i, \beta)]} \quad (12)$$

$$Y = \sum_1^z a_i \cdot h_i \quad (13)$$

最终进行加权求和输出结果 Y , 作为 MLP 的初始值输入模型。

3.1.2 弹性梯度下降法

将传统多层感知机迭代时采用的误差梯度下降法改为弹性梯度下降法。这样在进行误差修正时,以更新值作为基准,梯度只作为更新方向的标注改进权值。更新公式为:

$$\Delta w(t)_{ij} = \begin{cases} -\Delta(t)_{ij}, & \frac{\partial E(t)}{\partial w_{ij}} > 0 \\ \Delta(t)_{ij}, & \frac{\partial E(t)}{\partial w_{ij}} < 0 \\ 0, & \frac{\partial E(t)}{\partial w_{ij}} = 0 \end{cases} \quad (14)$$

设计的模型步骤为:

步骤①:对样本进行预处理。对数据进行归一化处理,将训练集数据传入模型,注意力机制提取信息。

步骤②:种群初始化。通过改进的 Sobol 序列初始化蜉蝣优化算法的位置向量,生成种群大小为 N 、搜索空间维数为 D 、上下界分别为 u_j 和 l_j 的蜉蝣种群,设置最大迭代次数 $t_{\max}$,随机分配雄性个体和雌性个体。

步骤③:更新种群的位置。雄性蜉蝣个体的位置更新由个体最优解和全局最优解指引,雌性蜉蝣个体的位置更新仅受雄性蜉蝣指引,速度的大小及方向分别为:

$$v_{ij}(t+1) = \begin{cases} v_{ij}(t) + \delta_1 \cdot e^{-\lambda \cdot r_p^2} [p_{ij} - x_{ij}(t)] + \delta_2 \cdot e^{-\lambda \cdot r_g^2} [g_i - x_{ij}(t)] & f(x_i) > f(g_i) \\ v_{ij}(t) + d \cdot r_m & f(x_i) \leq f(g_i) \end{cases} \quad (15)$$

$$u_{ij}(t+1) = \begin{cases} u_{ij}(t) + \delta_3 \cdot e^{-\lambda \cdot r_m^2} [x_{ij}(t) - y_{ij}(t)] & f(y_i) > f(x_i) \\ v_{ij}(t) + f_i \cdot r_m & f(y_i) \leq f(x_i) \end{cases} \quad (16)$$

将式(15)、式(16)的速度代入式(1)、式(2)中,进行位置更新,并根据式(3)、式(4)生成子代。

步骤④:计算适应度值。以均方误差作为适应度值,判断是否满足迭代结束的条件,满足则停止迭代,输出最优的权值 w_j 和阈值 b_j ,否则重复步骤②。

步骤⑤:将权值和阈值传入多层感知机中。构建完整的 IMA-AmMLP 模型,输出最小混相压力预测结果。

为了验证模型效果,选取平均绝对误差值(δ_{MAE})、均方根误差(δ_{RMSE})、平均绝对百分误差(δ_{MAPE})指标对模型性能优劣进行评价:

$$\delta_{MAE} = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (17)$$

$$\delta_{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (18)$$

$$\delta_{MAPE} = \frac{1}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \quad (19)$$

具体模型流程如图 4 所示。




图 4 IMA-AmMLP 模型流程

Fig. 4 Flow chart of the IMA-AmMLP model

3.2 数据来源

模型训练数据来源于已发表的实验数据^[26-28]。

由于指标间单位存在差异,需要消除量纲不一致。设有 n 个输入样本(z_i, y_i), $i \in [1, n]$, 输入集为 $z_i = [z_{i1}, z_{i2}, \dots, z_{im}]$, m 为影响因素个数。将原始数据进行归一化处理:

$$z_{ih}^* = \frac{z_{ih} - z_{imin}}{z_{imax} - z_{imin}} \quad (20)$$

3.3 IMA 模型参数寻优分析

以 python 软件为仿真实验平台,将最小混相压力样本数据按照 7:1:1 的比例划分训练集、验证集和测试集。由于样本量小,采用交叉验证的方式进行训练。原始数据通过输入层传入注意力机制中进行权重提取赋值,因此输入层节点数设置为 7 个,输出层为最小混相压力。

为检验优化后的蜉蝣性能,设置蜉蝣种群个体数为 30,最大迭代次数为 100,获得 MA 和 IMA 模型在迭代过程中适应度的对比(图 5)。






图 5 种群迭代过程

Fig. 5 Population iteration process



(a) 预测结果对比



(b) 相对误差对比

图 6 各模型预测结果以及相对误差对比

Fig. 6 Comparison of prediction result and relative errors of each model

表 1 模型评估指标对比

Table 1 Comparison of evaluation indexes

模 型	δ_{MAE}/MPa	δ_{MAPE}	δ_{RMSE}
PSO-MLP	2.642	0.099	2.751
MA-MLP	1.984	0.073	2.171
MA-AmMLP	1.349	0.051	1.168
IMA-AmMLP	1.036	0.024	0.835

与真实值最接近,预测精度最高,预测值和真实值更加贴合,说明模型在训练时的拟合效果最优。与 MA-MLP 模型相比,由于缺少注意力机制的提取,局部搜索能力有限,致使最优解未被开发出来;与 MA-AmMLP 模型相比,解决了 MA 容易陷入局部最优而早熟的问题。IMA-AmMLP 模型的平均绝对误差

IMA 模型在第 51 次迭代达到收敛状态,MA 模型在第 72 次才实现收敛,因此 IMA 模型在搜寻最优参数的效率和效果方面均优于 MA 模型。

4 预测模型的应用

为了进一步验证 IMA-AmMLP 的适用性,选取吉林油田 8 口井油样进行实验,按照 SY/T 6573—2016^[29]标准进行细管实验测定最小混相压力的真实值,和 IMA-AmMLP 模型的预测值进行比较,以验证其效果。为了验证注意力机制的特征赋值效果和蜉蝣算法的参数寻优效果,选取未改进的模型和优化算法中最普遍的 PSO 算法优化的模型,经过同一组数据训练后进行预测,并与 IMA-AmMLP 模型预测结果进行对比,PSO 算法的参数设置参照文献[30]。

各模型的结果对比如图 6 所示,各评价指标见表 1。由表 2 和图 6 可以看出,IMA-AmMLP 模型预测结果

为 1.036,平均绝对百分误差为 0.024,均方根误差为 0.835,实现将最小混相压力预测误差控制在 3% 以下。

表 2 IMA-AmMLP 模型与国外模型误差对比

Table 2 Error comparison between IMA-AmMLP model and foreign models

编号	真实值	误差 / %		
		本文模型	Yellig 等 ^[31]	Kamari 等 ^[32]
1	20.14	3.63	18.31	16.54
2	22.09	2.76	12.45	10.51
3	22.22	1.98	13.26	12.22
4	26.84	2.74	14.03	10.19
5	37.88	1.91	14.56	13.17
6	33.41	2.56	19.82	15.45
7	28.76	1.87	16.37	14.41
8	26.95	2.03	10.51	7.61

5 结 论

(1) 将注意力机制引入模型中, 克服了传统神经网络中系统缺乏对输入特征的提取和强化致使计算效率低下的缺陷, 使模型具有从大量信息中精准捕捉有效信息的能力, 降低运算时间。

(2) 引入改进的 Sobol 序列初始化种群增加探索空间的灵活性和多样性, 引入非线性惯性权重对 MA 进行改进, 能使蜉蝣个体的位置更新跳出陷入局部最优的循环, 并构造反向解空间, 扩大种群搜索空间, 提升找到全局最优解的概率, 有效避免陷入局部最优解, 提高算法全局开发性能及实现快速收敛, 在实际应用中将平均误差降至 2.435%, 可以有助于改善 CO₂ 驱效果、有效提升采收率。

符号注释: $x_{ij}(t)$ —第 i 个雄性蜉蝣在第 j 维的第 t 次迭代时的位置; $v_{ij}(t)$ —第 i 个雄性蜉蝣在第 j 维的第 t 次迭代时的移动速度; $y_{ij}(t)$ —第 i 个雌性蜉蝣在第 j 维的第 t 次迭代时的位置; $u_{ij}(t)$ —第 i 个雌性蜉蝣在第 j 维的第 t 次迭代时的移动速度; o_1 、 o_2 —蜉蝣交配产生的子代; M 、 F —父系和母系; L —交配系数, 取值范围 $[-1, 1]$; x_n —生成种群的第 n 个个体; $x_{\min}$ 、 $x_{\max}$ —整个种群的范围上下界限; k_n —经过 Tent 混沌算法随机生成的混沌序列; μ —混沌参数, 取值 $[0, 2]$, μ 越大, 混沌性越好, 本文取 $\mu = 2$; k —反向系数, 取值为 $(0, 1)$ 的随机数; $x_{ij}^*(t)$ —雄性个体第 t 代反向解; $a_j(t)$ 、 $b_j(t)$ — $x_{ij}(t)$ 在 j 维的最小值和最大值; $x_{1j}(t)$ 、 $x_{mj}(t)$ — $x_{ij}(t)$ 在 j 维的第一个值和最后一个值; $y_{ij}^*(t)$ —雌性个体第 t 代反向解; $c_j(t)$ 、 $d_j(t)$ — $y_{ij}(t)$ 在 j 维的最小值和最大值; $y_{1j}(t)$ 、 $y_{mj}(t)$ — $y_{ij}(t)$ 在 j 维的第一个值和最后一个值; ω_0 —惯性权重的初始值; $\omega(t)$ —第 t 次迭代时的惯性权重; $\omega_{\max}$ 、 $\omega_{\min}$ —惯性权重的最大值和最小值; t —当前迭代次数; $T_{\max}$ —总迭代次数; $x'_{ij}(t)$ 、 $y'_{ij}(t)$ — $x_{ij}(t)$ 、 $y_{ij}(t)$ 、 $x_{ij}^*(t)$ 、 $y_{ij}^*(t)$ 中各自适应度前一半的个体; z —特征向量的维度; a_i —对应的注意力分布; h_i —原始信息输入; β —对目标的查询向量; $s(h_i, \beta)$ —注意力打分函数; Y —注意力分数; $\Delta w(t)_{ij}$ —权重更新值; $\Delta(t)_{ij}$ —原始更新值; $E(t)$ —均方误差; $\frac{\partial E(t)}{\partial w_{ij}}$ —均方误差梯度; δ_1 、 δ_2 —个体学习系数和全局学习系数; λ —能见度系数; r_p 、 r_g —个体位置和个体极值、全局极值间的距离; p_{ij} 、 g_j —个体极值和全局极值; $f(x_i)$ 、 $f(y_i)$ —雄性蜉蝣 i 和雌性蜉蝣 i 的适应度值; f_i —随机飞行系数; δ_3 —吸引系数; r_m —雌雄个体间距; d —雄性舞蹈系数; w_j —第 j 次迭

代多层感知机权值; b_j —第 j 次迭代多层感知机阈值; z_i —第 i 个样本特征值; y_i —第 i 个样本目标值; $\hat{y}_i$ —模型的输出值; z_{ih} —第 i 条数据的第 h 种影响因素; $z_{\min}$ 、 $z_{\max}$ —第 h 种因素的最小值和最大值; z_{ih}^* —归一化处理后的数据; m —影响因素个数; δ_{MAE} —平均绝对误差, MPa; δ_{RMSE} —均方根误差; δ_{MAPE} —平均绝对百分误差。

参 考 文 献

[1] 杨勇. 中国碳捕集、驱油与封存技术进展及发展方向[J]. 石油学报, 2024, 45(1): 325-338.
YANG Yong. Technology progress and development direction of carbon capture, oil-flooding and storage in China[J]. Acta Petrolei Sinica, 2024, 45(1): 325-338.

[2] JIANG Lili, TIAN Leng, ZHOU Yutao, et al. Prediction of minimum miscibility pressure for CO₂ flooding based on microscopic pore-throat structure[J]. Frontiers in Energy Research, 2022, 10: 834951.

[3] 黄兴, 倪军, 李响, 等. 致密油藏不同微观孔隙结构储层 CO₂ 驱动用特征及影响因素[J]. 石油学报, 2020, 41(7): 853-864.
HUANG Xing, NI Jun, LI Xiang, et al. Characteristics and influencing factors of CO₂ flooding in different microscopic pore structures in tight reservoirs[J]. Acta Petrolei Sinica, 2020, 41(7): 853-864.

[4] SUN Renyuan, CHEN Haotian, KOU Gen, et al. Evaluation methods of minimum miscibility pressure for crude oil and CO₂ in glutenite reservoir[C]//Proceedings of 2019 International Conference on Energy, Power, Environment and Computer Application (ICEPECA 2019). Wuhan: DEStech Publications, 2019: 14-18.

[5] 刘小杰, 黄帅帅, 美合日阿依·穆泰力普, 等. CO₂ 与混合烷烃最小混相压力的界面张力法实验研究[J]. 石油与天然气化工, 2020, 49(3): 87-92.
LIU Xiaojie, HUANG Shuaishuai, MUTAILIPU M, et al. Experiments on the minimum mixing pressure of CO₂ and mixed alkane by using the interfacial tension regression method[J]. Chemical Engineering of Oil & Gas, 2020, 49(3): 87-92.

[6] 刘瑜. 一种应用 CT 测量油气最小混相压力的装置与方法: 103900755A[P]. 2014-07-02.
LIU Yu. Device and method for measuring minimum miscibility pressure of oil and gas through CT: 103900755A[P]. 2014-07-02.

[7] 赵跃军, 宋考平, 范广娟. 经验公式法预测试验区最小混相压力适应性研究[J]. 数学的实践与认识, 2017, 47(18): 285-289.
ZHAO Yuejun, SONG Kaoping, FAN Guangjuan. The adaptability research of experience formula method for predicting the minimum miscible pressure in test area[J]. Mathematics in Practice and Theory, 2017, 47(18): 285-289.

[8] 王香增, 高瑞民, 江绍静, 等. 最小混相压力修正方法研究[J]. 石油化工高等学校学报, 2017, 30(1): 42-44.
WANG Xiangzeng, GAO Ruimin, JIANG Shaojing, et al. Modified method for minimum miscible pressure prediction[J]. Journal of Petrochemical Universities, 2017, 30(1): 42-44.

[9] 李菊花, 王洁, 梁成钢, 等. 新疆吉木萨尔页岩油藏注 CO₂ 驱最小混相压力的确定[J]. 长江大学学报(自然科学版), 2022, 19(5): 37-44.

LI Juhua, WANG Jie, LIANG Chenggang, et al. Determination of minimum miscible pressure for CO₂ flooding in Jimsar shale reservoir of Xinjiang[J]. Journal of Yangtze University(Natural Science Edition), 2022, 19(5): 37-44.

[10] 汪芳, 周体尧, 杨思玉. CO₂ 驱最小混相压力预测新方法[J]. 内蒙古石油化工, 2018, 44(4): 95-97.

WANG Fang, ZHOU Tiyaoyao, YANG Siyu. A new minimum miscibility pressure prediction method of CO₂ flooding[J]. Inner Mongolia Petrochemical Industry, 2018, 44(4): 95-97.

[11] SHOKIR E M. CO₂-oil minimum miscibility pressure model for impure and pure CO₂ streams[J]. Journal of Petroleum Science and Engineering, 2007, 58(1/2): 173-185.

[12] 宋兆杰, 邓森, 宋宜磊, 等. 大庆油田古龙页岩油-CO₂ 高压相态及传质规律[J]. 石油学报, 2024, 45(2): 390-402.

SONG Zhaojie, DENG Sen, SONG Yilei, et al. High-pressure phase behavior and mass transfer law of Gulong shale oil and CO₂ in Daqing oilfield[J]. Acta Petrolei Sinica, 2024, 45(2): 390-402.

[13] HORNIK K, STINCHCOMBE M, WHITE H. Multilayer feed-forward networks are universal approximators[J]. Neural Networks, 1989, 2(5): 359-366.

[14] 倪小峰, 曹斌. 基于 MLP 神经网络的铝电解槽出铝量预测[J]. 智能计算机与应用, 2021, 11(8): 139-142.

NI Xiaofeng, CAO Bin. Prediction of aluminum output in aluminum electrolytic cell based on MLP neural network[J]. Intelligent Computer and Applications, 2021, 11(8): 139-142.

[15] 李祯, 郭奇, 卜亚辉, 等. 基于深度学习的饱和度场样本库建立及预测[J]. 石油学报, 2024, 45(4): 698-707.

LI Zhen, GUO Qi, BU Yahui, et al. Establishment and prediction of sample pool of saturation field based on deep learning[J]. Acta Petrolei Sinica, 2024, 45(4): 698-707.

[16] 龚斌, 王虹雅, 王红娜, 等. 基于大数据分析算法的深部煤层气地质—工程—一体化智能决策技术[J]. 石油学报, 2023, 44(11): 1949-1958.

GONG Bin, WANG Hongya, WANG Hongna, et al. Integrated intelligent decision-making technology for deep coalbed methane geology and engineering based on big data analysis algorithms[J]. Acta Petrolei Sinica, 2023, 44(11): 1949-1958.

[17] 陈伟超, 符强. 基于倒位变异的蜉蝣优化算法[J]. 计算机系统应用, 2021, 30(8): 157-163.

CHEN Weichao, FU Qiang. Mayfly optimization algorithm based on inversion variation[J]. Computer Systems & Applications, 2021, 30(8): 157-163.

[18] 杨建新, 兰小平, 冯亚东, 等. 基于改进樽海鞘群和最小二乘支持向量机算法的新型弹药质量评估方法[J]. 兵工学报, 2022, 43(5): 1012-1022.

YANG Jianxin, LAN Xiaoping, FENG Yadong, et al. An ammunition quality evaluation method based on least squares support vector machine[J]. Acta Armamentarii, 2022, 43(5): 1012-1022.

[19] 陈忠云, 张达敏, 辛梓芸. 正弦余弦算法的樽海鞘群算法[J]. 计算机应用与软件, 2020, 37(9): 209-214.

CHEN Zhongyun, ZHANG Damin, XIN Ziyun. Salp swarm algorithm using sine cosine algorithm[J]. Computer Applications and Software, 2020, 37(9): 209-214.

[20] 王梦璐, 李连忠. 动态反向搜索更新位置的改进灰狼优化算法[J]. 计算机工程与应用, 2021, 57(18): 86-96.

WANG Menglu, LI Lianzhong. Improved grey wolf optimization algorithm based on dynamic reverse search for updated position[J]. Computer Engineering and Applications, 2021, 57(18): 86-96.

[21] 王义, 张达敏, 邹诚诚. 增强全局搜索和自适应蜉蝣算法[J]. 哈尔滨工业大学学报, 2022, 54(11): 137-150.

WANG Yi, ZHANG Damin, ZOU Chengcheng. Enhance global search and adaptive mayfly algorithm[J]. Journal of Harbin Institute of Technology, 2022, 54(11): 137-150.

[22] 徐焕增, 徐文倩, 孔政敏. 基于 Tent 混沌序列改进的蜉蝣算法及其应用[J]. 控制工程, 2022, 29(3): 435-440.

XU Huanzeng, XU Wenqian, KONG Zhengmin. Mayfly algorithm based on tent chaotic sequence and its application[J]. Control Engineering of China, 2022, 29(3): 435-440.

[23] 王义, 张达敏, 张琳娜, 等. 基于黄金正弦与自适应融合的蜉蝣优化算法[J]. 计算机应用研究, 2021, 38(10): 3072-3077.

WANG Yi, ZHANG Damin, ZHANG Linna, et al. Mayfly optimization algorithm based on gold sine and adaptive merge[J]. Application Research of Computers, 2021, 38(10): 3072-3077.

[24] TUPPADUNG Y, KURUTACH W. Comparing nonlinear inertia weights and constriction factors in particle swarm optimization[J]. International Journal of Knowledge-based and Intelligent Engineering Systems, 2011, 15(2): 65-70.

[25] 郭玲, 于海雁, 周志权. 基于 SimAM 注意力机制的近岸船舶检测方法[J]. 哈尔滨工业大学学报, 2023, 55(5): 14-21.

GUO Ling, YU Haiyan, ZHOU Zhiqian. Nearshore ship detection method based on SimAM attention mechanism[J]. Journal of Harbin Institute of Technology, 2023, 55(5): 14-21.

[26] LI Huazhou, QIN Jishun, YANG Daoyong. An improved CO₂-oil minimum miscibility pressure correlation for live and dead crude oils[J]. Industrial & Engineering Chemistry Research, 2012, 51(8): 3516-3523.

[27] 孙业恒, 吕广忠, 王延芳, 等. 确定 CO₂ 最小混相压力的状态方程法[J]. 油气地质与采收率, 2006, 13(1): 82-84.

SUN Yeheng, LÜ Guangzhong, WANG Yanfang, et al. A method of state equation for determining minimum miscible pressure of CO₂[J]. Petroleum Geology and Recovery Efficiency, 2006, 13(1): 82-84.

[28] YUAN H, JOHN R T, EGWUENU A M, et al. Improved MMP correlations for CO₂ floods using analytical gas flooding theory[J]. SPE Reservoir Evaluation & Engineering, 2005, 8(5): 418-425.

[29] 国家能源局. 最低混相压力实验测定方法-细管法: SY/T 6573—2016[S]. 北京: 石油工业出版社, 2016.

National Energy Administration. Minimum mixed phase pressure experimental determination method-thin tube method: SY/T 6573-2016[S]. Beijing: Petroleum Industry Press, 2016.

[30] 骆正山, 李蕾. 基于 PCA-IBAS-ELM 的海底多相流管道内腐蚀速率预测[J]. 科学技术与工程, 2022, 22(22): 9566-9573.

LUO Zhengshan, LI Lei. Prediction of corrosion rate in subsea multiphase flow pipelines based on PCA-IBAS-ELM[J]. Science Technology and Engineering, 2022, 22(22): 9566-9573.

[31] YELLIG W F, METCALFE R S. Determination and prediction of CO₂ minimum miscibility pressures (includes associated paper 8876)[J]. Journal of Petroleum Technology, 1980, 32(1): 160-168.

[32] KAMARI A, ARABLOO M, SHOKROLLAHI A, et al. Rapid method to estimate the minimum miscibility pressure (MMP) in live reservoir oil systems during CO₂ flooding[J]. Fuel, 2015, 153: 310-319.