石油钻探技术
PETROLEUM DRILLING TECHNIQUES
中国科学引文数据库（CSCD）来源期刊
全国中文核心期刊
美国《化学文摘》（CA）收录期刊
俄罗斯《文摘杂志》（AJ）收录期刊
EBSCO学术数据库收录期刊（美）
AAPG协会期刊出版平台收录期刊（美）
中国科技论文统计源期刊
RCCSE中国核心学术期刊

多层水驱开发油田采收率快速预测方法

侯亚伟 刘超 徐中波 安玉华 李景玲

A Method for Rapidly Predicting Recovery of Multi-Layer Oilfields Developed by Water-Flooding

HOU Yawei, LIU Chao, XU Zhongbo, AN Yuhua, LI Jingling

在线阅读 View online: http://doi.org/10.11911/syztjs.2022102

您可能感兴趣的其他文章

Articles you may be interested in

深水浊积岩油藏提高采收率方法研究

Study on Enhanced Oil Recovery Method in Deep-Water Turbidite Reservoirs—A Case Study of X Reservoir in Angola

石油钻探技术. 2021, 49(2): 79-89 http://doi.org/10.11911/syztjs.2021025

青海油田尕斯$N_1N_2^1$超高盐油藏复合驱提高采收率技术

Oil Recovery Enhancement by Composite Flooding Technology for Gasi $N_1N_2^1$ Ultra-High-Salinity Reservoir in Qinghai Oilfield

石油钻探技术. 2021, 49(5): 81-87 http://doi.org/10.11911/syztjs.2021121

基于非均质大模型的特高含水油藏提高采收率方法研究

Research on Large Scale Heterogeneous Model Based EOR Methods for Ultra-High Water Cut Reservoirs

石油钻探技术. 2018, 46(5): 83-89 http://doi.org/10.11911/syztjs.2018078

注水开发油田水淹层混合液电阻率求取新方法

A New Method to Determine the Resistivity of Mixed Liquids in Water-flooded Layers of Oilfields by Water-flooding Development

石油钻探技术. 2017, 45(1): 120-126 http://doi.org/10.11911/syztjs.201701020

胡状集油田特高含水油藏剩余油水驱技术

Water Flooding Technology for the Residual Oil in the Ultra-High Water Cut Oil Reservoirs of the Huzhuangji Oilfield

石油钻探技术. 2018, 46(5): 95-101 http://doi.org/10.11911/syztjs.2018081

页岩油藏裂缝网络多相渗流数值模拟研究

Numerical Simulation of Multiphase Flow in Fracture Networks in Shale Oil Reservoir

石油钻探技术. 2021, 49(5): 94-100 http://doi.org/10.11911/syztjs.2021090

扫码关注公众号，获取更多信息！

◀油气开发▶

doi:10.11911/syztjs.2022102

引用格式：侯亚伟，刘超，徐中波，等. 多层水驱开发油田采收率快速预测方法 [J]. 石油钻探技术，2022, 50(5)：82-87.
HOU Yawei, LIU Chao, XU Zhongbo, et al. A method for rapidly predicting recovery of multi-layer oilfields developed by water-flooding [J]. Petroleum Drilling Techniques, 2022, 50(5): 82-87.

多层水驱开发油田采收率快速预测方法

侯亚伟， 刘 超， 徐中波， 安玉华， 李景玲

（中海石油（中国）有限公司天津分公司渤海石油研究院，天津 300459）

摘 要：为了快速准确预测水驱开发油田的采收率，在考虑储层特征、流体性质等影响原油采收率因素的基础上，建立了基于反向传播神经网络优化算法的采收率快速预测方法。首先，以蓬莱 19-3 油田地质特征和流体性质为依据，建立了油藏数值模拟地质模型，选取渗透率变异系数、原油黏度、油层净毛比和生产压差等 4 个关键因素，每个因素选取 5 个水平，采用油藏数值模拟方法对 625 组数据进行了模拟，建立了 625 组采收率及其影响因素关系数据库；然后，基于 BP 网络及优化理论，建立了快速预测采收率的人工神经网络方法。选取 500 组数据作为算法训练集，125 组数据进行测试，测试结果表明，125 组测试数据的预测采收率相对误差范围为−2.91%～5.07%，平均相对误差为 0.16%，满足工程精度要求。多层水驱开发油田采收率快速预测方法为蓬莱 19-3 油田及其他同类油田采收率快速预测提供了新的技术手段。

关键词：水驱油田；BP 神经网络；采收率；预测模型；油藏模拟；机器学习；数据库；蓬莱 19-3 油田

中图分类号：TE32^{+}7, TE341 **文献标志码：**A **文章编号：**1001–0890(2022)05–0082–06

A Method for Rapidly Predicting Recovery of Multi-Layer Oilfields Developed by Water-Flooding

HOU Yawei, LIU Chao, XU Zhongbo, AN Yuhua, LI Jingling

(*Bohai Petroleum Research Institute,Tianjin Branch of CNOOC Ltd., Tianjin,* 300459*, China*)

Abstract: In order to quickly and accurately predict the recovery of oilfields developed by water flooding, a method for rapidly predicting oil recovery was established based on a back propagation (BP) neural network optimization algorithm with consideration of factors influencing the recovery, such as reservoir characteristics and fluid properties. Firstly, geological models for numerical reservoir simulation were constructed according to the geological characteristics and fluid properties of Penglai 19-3 Oilfield. Four key factors including coefficient of permeability variation, oil viscosity, net to gross ratio of oil layers, and production pressure differential were selected, with each factor defined into five levels. 625 groups of reservoir simulation cases were analyzed numerically, and a database indicating the relationship between the oil recovery of the cases and the influencing factors was established. Secondly, an artificial neural network (ANN) method for rapidly predicting oil recovery was set up based on BP neural network and optimization theory. Finally, 500 groups of data were selected as the algorithm training set, and 125 groups of data were tested for recovery predicting. The test result showed that the predicted oil recovery of the tested data had a relative error ranging from −2.91% to 5.07% with an average relative error of 0.16%, which met the requirement for engineering accuracy. The method for rapidly predicting recovery of multi-layer oilfields developed by water-flooding provides a new technical approach to rapidly predict the recovery of Penglai 19-3 Oilfield and other similar oilfields.

Key words: oilfields developed by water-flooding; BP neural network; oil recovery; prediction model; reservoir simulation; machine learning; database; Penglai 19-3 Oilfield

收稿日期：2022-04-12；**改回日期：**2022-08-30。

作者简介：侯亚伟（1982—），男，陕西宝鸡人，2007 年毕业于大庆石油学院油气储运专业，2010 年获东北石油大学油气田开发工程专业硕士学位，高级工程师，主要从事油气田开发相关研究工作。E-mail: houyawei144@163.com。

基金项目：中国海油重大科技专项课题“渤海油田强化水驱及增产挖潜技术”（编号：CN00C-KJ 135ZDXM36TJ01TJ）部分研究内容。

蓬莱 19-3 是储量十亿吨级特大型油田[1]，目前采出程度 15.5%，综合含水率 82.5%。油层净毛比变化大，非均质强[2]，孔隙度 15.0%～35.4%，渗透率 18～3 619 mD，原油黏度 7～46 mPa·s[3]，生产压差变化大。影响采收率的因素复杂[4]，如何快捷而准确预测不同区块和不同储层的采收率是亟需解决的问题。目前预测采收率的方法有经验公式法[5]、水驱曲线法[6−7]和数值模拟法等[8−9]。采收率预测经验公式未充分考虑非均质性和生产压差等因素，预测可靠性差，适用范围小。水驱曲线法预测的采收率严重依赖生产数据的选取，不同开发阶段的数据反映的规律差异大，直线段不唯一[10]，计算结果差异大，实用性差。此外，水驱曲线在特高含水阶段出现“上翘”现象[11−13]，拐点和斜率难确定，方法失效。油藏数值模拟法虽然考虑因素全面，但存在动态、静态数据准确提取难度大、计算工作量大和历史拟合不唯一性等问题。

近年来，采用机器学习和人工神经网络（ANN）解决油田开发预测问题取得了一定进展[14−19]，但尚未见到综合考虑油藏因素和油井工作制度的 ANN 预测采收率方法。为此，笔者选取渗透率变异系数、原油黏度、净毛比和生产压差 4 个关键因素，采用油藏数值模拟方法对 625 组方案数据进行了模拟，建立了 625 组采收率及其影响因素关系数据库；采用基于机器学习的人工神经网络理论，构建了影响采收率的参数输入层、隐含层和输出层，建立了快速预测采收率的人工神经网络方法；选取 500 组数据进行机器学习训练，125 组数据进行测试检验，采收率预测结果的平均相对误差为 0.16%，在精度和计算速度上具有明显优势。

1　采收率与影响因素关系库建立

根据蓬莱 19-3 油田的地质、油藏和流体等数据[1,3]，构建了三维模型，网格数量为 60×60×7，平面网格尺寸为 10 m×10 m；纵向 7 层网格由上至下分别对应油组 L50、L54、L60、L62、L64、L72 和 L76，其主要参数见表 1。

该油田前期的研究表明，生产压差是影响渗流速度、油井产量、有效泄油面积和最终采收率最显著的动态参数，能较好地反映生产动态。层间渗透率变异系数是层间非均质性的定量表征参数，是影响合注合采多层非均质性油藏层间储量动用差异和采出程度的地质因素；水的黏度相对变化较小，因此原油黏度是影响油水流度比、含水率和对应含水率情况下采收率的最主要因素；净毛比定量表征了有效厚度和砂体厚度的比值，能够反映油层的品质和采收率。由此可见，渗透率变异系数、原油黏度和净毛比能较全面地反映油藏特性。因此，选取这 4 个关键因素，每个影响因素设置 5 个水平（见表 2）。

表 1　概念地质模型基本参数

Table 1　Basic parameters of conceptual geological model

层位编号	对应油组	层厚/m	顶深/m	孔隙度，%
1	L50	8.80	1 050.00	30.8
2	L54	2.50	1 058.80	23.1
3	L60	2.50	1 061.30	18.4
4	L62	13.70	1 063.80	20.7
5	L64	2.20	1 077.50	20.6
6	L72	7.80	1 079.70	16.7
7	L76	3.50	1 087.50	16.9

表 2　影响因素的不同水平取值

Table 2　The values of the level of different influencing factors

水平	影响因素			
	A：渗透率变异系数	B：原油黏度/（mPa·s）	C：净毛比	D：生产压差/MPa
1	0.1	5	0.6	0.7
2	0.2	15	0.7	1.4
3	0.5	25	0.8	2.1
4	0.7	35	0.9	2.8
5	0.8	45	1.0	3.5

根据蓬莱 19-3 油田地层流体性质，原油黏度在 5～45 mPa·s 范围内取 5 个水平值。渗透率变异系数作为反映渗透率非均质性的参数，能够定量表征渗透率非均质程度。考虑油田实际地质情况复杂，储层非均质性强，渗透率变异系数范围大，根据蓬莱 19-3 油田的非均质特征，渗透率变异系数选取 0～1.0 之间的 5 个水平值。净毛比是有效厚度与砂体厚度的比值，根据该油田砂体的净毛比，将净毛比设置为 0.6～1.0 之间的 5 个等差水平值。根据该油田单井的实际井底压力变化范围，将生产压差设置为 0.7～3.5 MPa 之间的 5 个水平值。此外，基于该油田不同渗透率岩心相对渗透率测试结果，建立并采用了不同渗透率储层相对应的相对渗透率曲线。

将设计的 625 组数据输入油藏数值模拟软件 Eclipse 进行模拟，提取采收率及其影响因素参数，建立 625 组采收率及其影响因素的数据库（见表 3）。

表 3　采收率及其影响因素关系的数据库

Table 3　Database indicating the relationship between oil recovery and influencing factors

序号	生产压差/MPa	渗透率变异系数	原油黏度/（mPa·s）	净毛比	采收率，%
1	2.8	0.7	5	0.7	64.93
2	3.5	0.8	5	0.9	62.95
3	3.5	0.1	25	0.7	66.85
4	1.4	0.5	25	1.0	49.81
5	1.4	0.8	5	0.6	58.69
6	2.8	0.2	5	0.9	71.54
7	0.7	0.8	35	0.6	42.98
8	2.8	0.5	15	0.9	61.67
9	2.8	0.5	25	0.8	57.07
10	2.1	0.2	15	0.8	65.91
⋮	⋮	⋮	⋮	⋮	⋮
623	3.5	0.5	45	0.6	56.43
624	1.4	0.8	5	0.8	56.58
625	2.8	0.8	35	0.6	52.52

2　采收率预测的神经网络方法及优化

采收率预测的神经网络原理见图 1，BP 算法学习过程分为 2 步：1）输入影响采收率因素的神经网络权值和阀值，经过隐含层，计算输出值（f 代表采收率），实现正向传递[20–21]；2）反向依次对权值和阀值进行修正[22]，2 个过程反复交替，直到收敛为止。

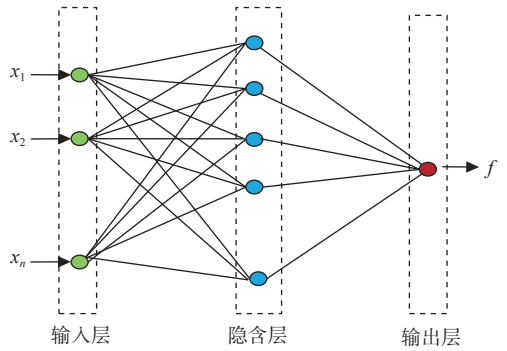

图 1　预测采收率的三层 BP 神经网络典型架构

Fig.1　Typical architecture of three-layer BP neural network predictiong oil recovery

2.1　正向传播原理

如图 1 中，输入向量为 $X=(x_1,\ x_2,\ x_3,x_4)$，其中 4 个因素分别代表渗透率变异系数、原油黏度、净毛比和生产压差。

隐含层各神经元的激活值：

$$S_j^1=\sum_{i=1}^{4}w_{ij}^1x_i-\theta_{ij}^1 \qquad j=1,2,3,...,m \tag{1}$$

激活函数采用 S 型的 sigmoid 函数[23]，得到的输出层的输出值：

$$y_k=f\left(S_k^2\right) \qquad k=1,2,...,n \tag{2}$$

式中：S_j^1 为隐含层的激活值；上标 1 代表隐含层；下标 j 代表隐含层节点；w_{ij}^1 为输入层至隐含层连接权；i 代表第 i 个因素；x_i 为第 i 个因素的影响采出程度；θ_{ij}^1 为隐含层节点的阀值；m 为隐含层节点总数；y_k 为实际输出采收率；k 为输出层节点；f 为输出层隐函数标记；S_k^2 为输出层的激活值；上标 2 代表输出层；n 为输出层节点总数。

2.2　反向传播原理

当计算输出的采收率与期望采收率不一致时要进行校正，校正误差表示为：

$$d_k^2=(t_k-y_k)f'\left(S_k^2\right) \qquad k=1,2,...,n \tag{3}$$

隐含层的校正误差为：

$$d_j^1=\left(\sum_{k=1}^{n}w_{jk}^2d_k^2\right)f'\left(S_j^1\right) \qquad j=1,2,3,...,m \tag{4}$$

网络全局误差为[24]：

$$E=\sum_{p=1}^{Q}E^p=\sum_{p=1}^{Q}\sum_{k=1}^{n}\frac{1}{2}\left(t_k^p-y_k^p\right)^2 \tag{5}$$

式中：d_k^2 为第 k 层期望采收率与实际输出采收率的误差；t_k 为第 k 输出层期望采收率；y_k 为第 k 输出层实际输出采收率；f' 为隐函数的导数；d_j^1 为第 j 隐含层校正误差；w_{jk}^2 为隐含层 j 至输出层 k 的连接权；E 为网络全局误差；E^p 为第 p 组逆传播误差；Q 为组数；t_k^p 为第 p 组、第 k 输出层期望采收率；y_k^p 为第 p 组、第 k 输出层实际输出采收率。

当 E 小于给定精度 ε 时，收敛到最优值。只有选取合适的权值和阈值，预测误差才能够快速达到预期，完成整个训练过程。

2.3　收敛优化方法

为了解决神经网络收敛速度慢和局部最小值的问题，需优化神经网络的权值和阈值，获取最优是

初始权值和阈值。S. Mirjalili 等人[25] 提出了一种基于仿生学的群智能优化算法（又称“蜻蜓算法（DA）”），其技术思路来源于自然界中蜻蜓群集的分离、对齐、内聚、寻觅和躲避等 5 种行为[26]，蜻蜓的位置和步长迭代式为：

$$\Delta X_{t+1} = (sS_i + aA_i + cC_i + fF_i + eE_i) + w\Delta X_t \quad (6)$$

$$X_{t+1} = X_t + \Delta X_{t+1} \quad (7)$$

式中：ΔX_{t+1} 为 t+1 代位置更新步长；a, c, e, f 和 s 分别为对齐、内聚、躲避、寻觅和分离等 5 种行为的权重系数；t 为当前迭代次数；w 为惯性权重；S_i 为第 i 个体的分离度；A_i 为第 i 个体的对齐度；C_i 为第 i 个体的内聚度；E_i 为第 i 个体对外排斥力；F_i 为第 i 个体对食物的吸引力；X_{t+1} 为 t+1 代种群位置；X_t 为当前 t 代种群位置。

上述算法解决了局部最优问题，可以得到全局最优解。为了便于快速计算，笔者利用 MATLAB 工具编制了以上算法的计算程序。

3　机器学习结果及检验

将 625 组油藏数值模拟方案的模拟结果作为学习样本的来源，提取 500 组数据用来建立采收率学习样本库（训练集），125 组数据作为测试检验样本（测试集），样本库如表 3 所示。对学习组的每个影响采收率因素对应的样本参数进行归一化处理，处理后数值范围为 [0, 1]；将归一化参数作为 BP 网络的参数输入，利用“蜻蜓”群智能优化算法对网络的权值和阈值进行优化；将优化得到的最优权值和阈值作为 BP 神经网络中权值和阈值的初始值，对 BP 网络进行学习训练；训练结束后，得到最佳的神经网络采收率预测模型 DA-BP，然后使用测试检验样本检验 DA-BP 的预测准确率。

将网络模型计算的采收率和油藏数值模拟计算的采收率进行对比可知，二者所对应的点很好地分布在直线 $y = x$ 附近（见图 2），均方误差为 0.48%，相关系数为 0.997 4，表明训练精度达到要求。

将 125 组测试数据的已知采收率值作为横坐标，将 DA-BP 模型预测采收率作为纵坐标，得到图 3。图 3 表明，经过机器学习和优化得到的神经网络预测的 125 组采收率与检验数据基本在对角线位置附近，二者吻合较好。蓬莱 19-3 油田不同岩样试验测定的水驱油效率为 62.9%～84.6%，根据该油田的储层物性和流体性质，波及系数取值范围为 65.0%～

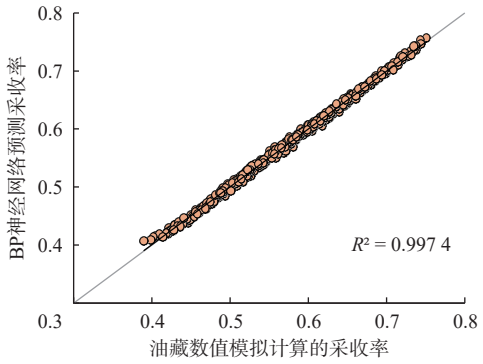

图 2　500 组训练集的数值模拟采收率与神经网络预测值交会图

Fig.2　Intersection of oil recovery values from numerical simulation and neural network prediction (500 groups of data from training set)

90.0%，计算得到不同小层的采收率范围为 40.8%～76.1%，平均为 58.5%；本方法预测的 125 组采收率范围为 40.5%～76.4%，平均为 57.3%；经验公式预测的采收率范围为 38.0%～45.0%，可以看出经验公式法预测的采收率明显偏低。

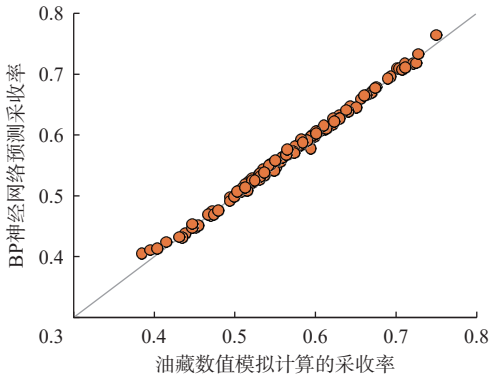

图 3　125 组测试集的数值模拟采收率与神经网络预测值交会图

Fig.3　Intersection of oil recovery values from numerical simulation and neural network prediction (125 groups of data from test set)

125 组测试集的预测采收率与数值模拟得到的采收率误差如图 4 所示。采收率绝对误差（预测采收率减去测试样本采收率）−1.70%～2.00%，均值为 0.08%；相对误差（绝对误差与测试样本采收率的比值）−2.91%～5.08%，均值为 0.16%。

预测的采收率相对误差区间的频数如图 5 所示，误差分布直方图呈近似正态分布，相对误差集中在−1.0～1.0%，占总样本的 81.6%，表明经过优化神经网络模型的预测精度较高，能够满足水驱开发油田采收率预测精度要求。

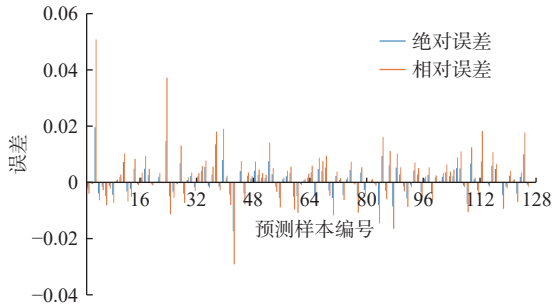

图 4　125 组测试集的 BP 神经网络预测结果误差分析

Fig.4　Error analysis of prediction by BP neural network (125 groups of data from test set)

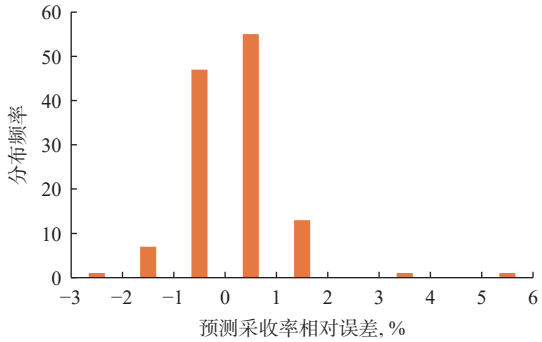

图 5　预测采收率相对误差分布直方图

Fig.5　Relative error distribution histogram of predicted oil recovery

4　结论与建议

1）引入了反映油井开发动态的生产压差，建立了基于 BP 网络优化算法的多层水驱开发油田采收率快速预测方法。

2）智能优化算法实现了合适的权值和阈值的初始化，加速了收敛速度，提高了神经网络预测采收率的精度，并解决了局部最小值问题。

3）建立的水驱油田采收率预测方法弥补了采收率预测经验公式法适用范围小，水驱曲线方法直线段选取难度大，数值模拟方法参数多、计算工作量大和历史拟合结果多解性等不足。

4）水驱开发油田采收率预测方法具有快速预测采收率的优势，但训练模型的精度受控于训练样本的质量、数量和来源，建议进一步扩大训练样本的来源和影响因素的参数取值范围，拓宽该方法的适用范围。

参　考　文　献

References

［1］　薛永安，邓运华，王德英，等. 蓬莱 19-3 特大型油田成藏条件及勘探开发关键技术 [J]. 石油学报，2019，40（9）：1125–1146.
XUE Yongan, DENG Yunhua, WANG Deying, et al. Reservoir formation conditions and key exploration & development technoloiges in PL 19-3 giant oilfield[J]. Acta Petrolei Sinica, 2019, 40(9): 1125–1146.

［2］　邓运华，李秀芬. 蓬莱 19-3 油田的地质特征及启示 [J]. 中国石油勘探，2001，6（1）：68–71.
DENG Yunhua, LI Xiufen. The geological characters and enlightenment of Penglai 19-3 Oilfield[J]. China Petroleum Exploration, 2001, 6(1): 68–71.

［3］　张章. 高含水期薄互层状油藏储层精细刻画研究 [D]. 西安：西北大学，2019：15-16.
ZHANG Zhang. Detail characterization study on thin-interbedded reservoirs at high water cut stage[D]. Xi’an: Northwest University, 2019: 15-16.

［4］　卢异，夏国朝，吕栋梁，等. 缝洞型火成岩油藏注水提高采收率研究 [J]. 特种油气藏，2020，27（1）：96–101.
LU Yi, XIA Guochao, LYU Dongliang, et al. Enhancing oil recovery by waterflooding in fracture-cave igneous reservoir[J]. Special Oil & Gas Reservoirs, 2020, 27(1): 96–101.

［5］　王清辉，朱明，冯进，等. 基于渗透率合成技术的砂岩油藏产能预测方法 [J]. 石油钻探技术，2021，49（6）：105–112.
WANG Qinghui, ZHU Ming, FENG Jin, et al. A method for predicting productivity of sandstone reservoirs based on permeability synthesis technology[J]. Petroleum Drilling Techniques, 2021, 49(6): 105–112.

［6］　耿昌浩，葛丽萍，构小婷. 童氏图版在采收率预测中的应用与修正 [J]. 中国石油和化工标准与质量，2013，33（16）：233–235.
GENG Changhao, GE Liping, GOU Xiaoting. Application and correction of Tong’s chart in oil recovery prediction[J]. China Petroleum and Chemical Standard and Quality, 2013, 33(16): 233–235.

［7］　孙强，黄世军，李权. 多层稠油油藏水驱动用程度评价方法 [J]. 断块油气田，2020，27（3）：323–326.
SUN Qiang, HUANG Shijun, LI Quan. Evaluation method of water driving degree of multi-layer heavy oil reservoir[J]. Fault-Block Oil & Gas Field, 2020, 27(3): 323–326.

［8］　咸玉席，陈超峰，封猛，等. 页岩油藏裂缝网络多相渗流数值模拟研究 [J]. 石油钻探技术，2021，49（5）：94–100.
XIAN Yuxi, CHEN Chaofeng, FENG Meng, et al. Numerical simulation of multiphase flow in fracture networks in shale oil reservoir[J]. Petroleum Drilling Techniques, 2021, 49(5): 94–100.

［9］　杨金辉，李立，李钟洋，等. 滑脱和应力敏感效应对页岩气开发动态影响的数值模拟研究 [J]. 石油钻探技术，2017，45（1）：83–90.
YANG Jinhui, LI Li, LI Zhongyang, et al. Numerical simulation on the effects of slippage and stress sensibility on the performance of shale gas development[J]. Petroleum Drilling Techniques, 2017, 45(1): 83–90.

［10］　王朝明，孔令军，袁凯旋，等. 特高含水后期油藏水驱效果评价方法 [J]. 石油钻探技术，2020，48（3）：108–113.
WANG Chaoming, KONG Lingjun, YUAN Kaixuan, et al. Evaluation method of water flooding effect in reservoirs with ultra-high water cut[J]. Petroleum Drilling Techniques, 2020, 48(3): 108–113.

［11］　孙成龙. 水驱曲线上翘时机的判定方法 [J]. 石油地质与工程，2014，28（3）：69–70.

SUN Chenglong. Determining method of water drive curve upturning timing[J]. Petroleum Geology and Engineering, 2014, 28(3): 69–70.

[12] 陈元千, 陶自强. 高含水期水驱曲线的推导及上翘问题的分析 [J]. 断块油气田, 1997, 4(3): 19–24.
CHEN Yuanqian, TAO Ziqiang. Derivation of water drive curve at high water-cut stage and its analysis of upwarding problem[J]. Fault-Block Oil & Gas Field, 1997, 4(3): 19–24.

[13] 孙红霞. 高含水期水驱特征曲线上翘新认识 [J]. 特种油气藏, 2016, 23(1): 92–95.
SUN Hongxia. New understanding of upward waterflooding characteristic curve in high water-cut stage[J]. Special Oil & Gas Reservoirs, 2016, 23(1): 92–95.

[14] 严子铭, 王涛, 柳占立, 等. 基于机器学习的页岩气采收率预测方法 [J]. 固体力学学报, 2021, 42(3): 221–232.
YAN Ziming, WANG Tao, LIU Zhanli, et al. Machine-learning-based prediction methods on shale gas recovery[J]. Chinese Journal of Solid Mechanics, 2021, 42(3): 221–232.

[15] 王涛. 人工神经网络在 CO_2 驱采收率预测中的应用 [J]. 特种油气藏, 2011, 18(4): 77–79.
WANG Tao. Application of artificial neural network in recovery factor forecast of carbon dioxide flooding[J]. Special Oil & Gas Reservoirs, 2011, 18(4): 77–79.

[16] 陈小龙, 李宜强, 管错, 等. 基于量纲分析的优化神经网络模型预测 GAGD 非混相开发油藏采收率 [J]. 石油科学通报, 2019, 4(3): 288–299.
CHEN Xiaolong, LI Yiqiang, GUAN Cuo, et al. An optimized neural network prediction model for gas assisted gravity drainage recovery based on dimensional analysis[J]. Petroleum Science Bulletin, 2019, 4(3): 288–299.

[17] 樊灵, 赵孟孟, 殷川, 等. 基于 BP 神经网络的油田生产动态分析方法 [J]. 断块油气田, 2013, 20(2): 204–206.
FAN Ling, ZHAO Mengmeng, YIN Chuan, et al. Analysis method of oilfield production performance based on BP neural network[J]. Fault-Block Oil & Gas Field, 2013, 20(2): 204–206.

[18] 何顺利, 田冷, 顾岱鸿. 改进的神经网络模型在储层敏感性预测中的应用 [J]. 石油钻探技术, 2006, 34(1): 28–31.
HE Shunli, TIAN Leng, GU Daihong. Improved neural network model predicts formation sensitivity[J]. Petroleum Drilling Techniques, 2006, 34(1): 28–31.

[19] 邢明海, 陈祥光, 王渝. 基于人工神经网络组合预测油田产量 [J]. 计算机仿真, 2004, 21(5): 116–120.
XING Minghai, CHEN Xiangguang, WANG Yu. Oilfield output's combined forecast based on artificial neural networks[J]. Computer Simulation, 2004, 21(5): 116–120.

[20] REN Ningning, FAN Le, ZHANG Zan. Sensorless PMSM control with sliding mode observer based on sigmoid function[J]. Journal of Electrical Engineering & Technology, 2021, 16(2): 933–939.

[21] ELFWING S, UCHIBE E, DOYA K. Sigmoid-weighted linear units for neural network function approximation in reinforcement learning[J]. Neural Networks, 2018, 107: 3–11.

[22] LI Rongyu, RUAN Yongfen, LI Shisheng, et al. Study on deformation prediction of landslide based on grey theory and BP neural network[J]. Applied Mechanics and Materials, 2012, 204/205/206/207/208: 520–525.

[23] YETILMEZSOY K, TURKDOGAN F I, TEMIZEL I, et al. Development of ANN-based models to predict biogas and methane productions in anaerobic treatment of molasses wastewater[J]. International Journal of Green Energy, 2013, 10(9): 885–907.

[24] 张良杰, 李衍达, 陈惠民. 基于变尺度寻优和遗传搜索技术的模糊神经网络全局学习算法 [J]. 电子学报, 1996, 24(11): 6–115.
ZHANG Liangjie, LI Yanda, CHEN Huimin. A new global learning algorithm for fuzzy neural networks based on modified quasi-newton method and genetic searching techniques[J]. Acta Electronica Sinica, 1996, 24(11): 6–115.

[25] MIRJALILI S. Dragonfly algorithm: a new meta-heuristic optimization technique for solving single-objective, discrete, and multi-objective problems[J]. Neural Computing and Applications, 2016, 27(4): 1053–1073.

[26] 吴伟民, 吴汪洋, 林志毅, 等. 基于增强个体信息交流的蜻蜓算法 [J]. 计算机工程与应用, 2017, 53(4): 10–14.
WU Weimin, WU Wangyang, LIN Zhiyi, et al. Dragonfly algorithm based on enhancing exchange of individuals' information[J]. Computer Engineering and Applications, 2017, 53(4): 10–14.

[编辑　滕春鸣]