

引用格式: 林魂, 孙新毅, 宋西翔, 等. 基于改进人工神经网络的页岩气井产量预测模型研究[J]. 油气藏评价与开发, 2023, 13(4): 467-473.  
LIN Hun, SUN Xinyi, SONG Xixiang, et al. A model for shale gas well production prediction based on improved artificial neural network [J]. Petroleum Reservoir Evaluation and Development, 2023, 13(4): 467-473.  
DOI: 10.13809/j.cnki.cn32-1825/te.2023.04.008

## 基于改进人工神经网络的页岩气井产量预测模型研究

林魂<sup>1,2</sup>, 孙新毅<sup>1</sup>, 宋西翔<sup>1</sup>, 蒙春<sup>2</sup>, 熊雯欣<sup>1</sup>, 黄俊和<sup>1</sup>, 刘洪博<sup>1</sup>, 刘成<sup>1</sup>  
(1. 重庆科技学院安全工程学院, 重庆 401331; 2. 重庆地质矿产研究院, 重庆 401120)

**摘要:** 传统页岩气井产量预测方法难以对储层参数、压裂参数与产量的关系做出有效分析, 而机器学习方法具有解决这一问题的能力。提出了基于物理意义和随机组合的方法构建特征参数, 并采用小批量梯度下降法(MBGD)作为训练函数, 建立了针对页岩气井产量预测的改进神经网络预测模型。然后结合实例, 利用改进后的人工神经网络模型对页岩气井产量进行预测, 并通过计算均方误差(MSE)和修正决定系数(T)的值对模型的优劣程度和预测精度进行评价。结果表明, 建立的改进神经网络模型预测产量结果与实际产量吻合度较高, 且相比传统的BP(误差反向传播算法)神经网络模型, 在预测精度和稳定性方面具有明显优势。该模型能为页岩气储层压裂优化设计以及产能评价提供重要支持。

**关键词:** 人工神经网络; 页岩气; 压裂参数; 产量预测; 特征构建

中图分类号: TE32

文献标识码: A

### A model for shale gas well production prediction based on improved artificial neural network

LIN Hun<sup>1,2</sup>, SUN Xinyi<sup>1</sup>, SONG Xixiang<sup>1</sup>, MENG Chun<sup>2</sup>, XIONG Wenxin<sup>1</sup>, HUANG Junhe<sup>1</sup>, LIU Hongbo<sup>1</sup>, LIU Cheng<sup>1</sup>

(1. School of Safety Engineering, Chongqing University of Science & Technology, Chongqing 401331, China;  
2. Chongqing Institute of Geology and Mineral Resources, Chongqing 401120, China)

**Abstract:** Traditional methods for predicting shale gas well production often struggle to effectively analyze the complex relationship between reservoir parameters, fracturing parameters and production. To address these challenges, a novel approach is introduced, involving the construction of characteristic parameters based on physical meaning and random combination. The small batch gradient descent method (MBGD) is adopted as the training function to develop an improved artificial neural network prediction model for shale gas well production. An example is utilized to demonstrate the effectiveness of the improved artificial neural network model in predicting shale gas well production. The model's performance is evaluated using the mean squared error (MSE) and the modified determination coefficient (T). The results indicate that the predictions from the improved network model align well with the actual production data. Moreover, the model exhibits superior prediction accuracy and stability compared to the traditional BP (error backpropagation algorithm) neural network model. With its high accuracy and reliability, the proposed model can provide valuable support for fracturing optimization design and productivity evaluation in shale gas reservoirs.

**Keywords:** artificial neural network; shale gas; fracturing parameter; production forecast; feature construction

收稿日期: 2022-03-30。

第一作者简介: 林魂(1988—), 男, 博士, 副教授, 从事油气田开发工程方面研究。地址: 重庆市沙坪坝区大学城东路20号, 邮政编码: 401331。E-mail: linhun016@cqust.edu.cn

通信作者简介: 孙新毅(1996—), 男, 在读硕士研究生, 从事机器学习方面研究。地址: 重庆市沙坪坝区大学城东路20号, 邮政编码: 401331。E-mail: 1017252954@qq.com

基金项目: 国家自然科学基金青年基金“基于低场核磁共振技术的页岩气储层‘焖井’增产机理研究”(51904050); 重庆市自然科学基金面上项目“深层页岩储层压裂液滞留水锁及其自动缓解机理”(cstc2020jcyj-msxmX1027); 重庆科技学院研究生科技创新项目“基于神经网络的套管损伤图像识别研究”(YKJXCX2120716)。

页岩气储层具有低孔、低渗的特点,且储层参数、压裂参数与产量之间具有复杂的非线性关系<sup>[1-2]</sup>。目前大部分页岩气井产量的预测方法主要基于传统的数学模型,不仅要耗费大量的精力和时间去分析井的情况,而且受页岩气储层不确定性和复杂性影响,预测效率和准确率很难达到一个理想的效果<sup>[3-4]</sup>。

随着人工智能技术的发展,在油气领域引入机器学习方法已成为一种趋势<sup>[5-6]</sup>。神经网络作为机器学习技术方法的一种,已在非常规油气生产中显示出巨大潜力<sup>[7-8]</sup>。在神经网络模型训练函数选取中,随机梯度下降算法(SGD)为求解常用方法,其可以快速地收敛到一个可接受的解,但缺点在于收敛方向有一定的偏差,且稳定性差、计算效率低<sup>[9-11]</sup>;另一种常见的训练函数为批量梯度下降算法(BGD),该函数根据全部样本构建出代价函数的梯度,能沿着当前最优的下降方向收敛,但缺点在于计算代价较高、耗时长<sup>[12-14]</sup>。目前利用神经网络在油气产量预测领域中,以测井参数、压力参数等作为研究对象居多,而对压裂参数与产量之间的关系研究较少<sup>[15-16]</sup>。

研究在分析页岩气储层参数和压裂参数特点的基础上,提出基于物理意义和随机组合的方法构建特征参数,并采用小批量梯度下降算法(MBGD),建立针对页岩气井产量预测的改进神经网络预测模型<sup>[17-19]</sup>。与传统的BP神经网络预测模型相比,建立的改进模型在精确度和有效性方面都有较大提升,能为页岩气储层压裂优化设计以及产能评价提供重要支持。

## 1 方法介绍

页岩气储层参数、压裂参数与产量之间具有复杂的非线性关系,常规的模拟方法难以建立各参数与产量之间的关系,而神经网络对于这种复杂的非线性映射问题具有很好的处理能力<sup>[20-22]</sup>。

### 1.1 模型描述

网络模型为多层结构模型,由输入层、隐藏层和输出层构成,各层之间通过神经元激活函数进行信号传递。网络模型经过多组数据样本的学习训练,通过根据实际输出值与期望输出值之差,自适应确定各神经元的连接权重,最终达到对目标参数的准

确预测。在进行产量预测时,通过输入单井各特征参数,根据设定的网络层数、隐藏层神经元个数、学习率以及迭代次数等参数,输入样本参数即可得到预测的产量值。

通过将页岩气储层参数和压裂参数作为网络模型的输入参数,其中工程参数包括水平井段长、完井井段长、压裂段数、总液量、砂量;地质参数包括含气量、孔隙度和渗透率等,这些参数在一定程度上可以反映页岩气储层参数、压裂参数与产量之间的相关信息,可以满足网络模型研究的需求。

首先将特征参数作为网络模型的输入层的神经元:

$$X_n = \{x_{n1}, x_{n2}, \dots, x_{nj}\} \quad (1)$$

式中: $X$ 为输入数组; $n$ 为样本数量; $x$ 为样本参数数据; $j$ 为输入参数个数。

参数通过各层神经元向后传递,上一层输出神经元的值为下一层输入的神经元的值, $k$ 层各神经元输出值为:

$$Y^{(k)} = f\left(\sum_{i=1}^j \omega_{ih} x_i + b_h\right) \quad (2)$$

式中: $Y$ 为神经元输出值; $k$ 为第 $k$ 层神经元; $\omega$ 为权重系数; $b$ 为偏置系数; $h$ 为对应层神经元个数。

激活函数 $f(x)$ 为Sigmoid(S型函数)函数如下:

$$f(x) = \frac{1}{1 + e^{-x}} \quad (3)$$

通过以页岩气储层参数和压裂参数为输入神经元,前3个月平均日产量为输出神经元,建立合适的人工神经网络模型进行预测。

### 1.2 数据处理

研究以国外某页岩气区块生产井的各参数为数据集,包括水平井段长、完井井段长、压裂段数、总液量、总砂量等工程参数,含气量、孔隙度、渗透率等地质参数。

在数据清洗阶段,通过可视化方式对各个参数进行分析处理,包括数据的异常值处理、缺失值处理和标准化等操作。在异常值处理时,利用箱线图对压裂段数、总液量等参数进行分析,对数量较少且明显的异常值可直接删除;在缺失值处理时,由于数据集充足,且缺失值样本占整个样本的比例相对较小,所以将存在缺失值的样本直接丢弃。为使模型在学习训练时可以更好地收敛,采用Z-Score(标准分数)

方法对数据进行标准化处理,如下:

$$z_i = \frac{x_i - u}{\sqrt{\frac{1}{N} \sum_{i=1}^N (x_i - u)^2}} \quad (4)$$

式中: $z_i$ 为标准化后数据; $x_i$ 为原始数据; $u$ 为样本参数均值; $N$ 为样本总数。

通过上述数据清洗过程,为后续构建特征参数奠定基础。

### 1.3 模型评价

通过均方误差(MSE)(式5)和修正决定系数( $T$ )(式7)对网络模型的预测泛化能力进行评价。

均方误差为输出值与目标值之间的平均平方误差,其值越小,说明预测模型精确度越高。

$$MSE = \frac{1}{n} \sum_{i=1}^n [f(x_i) - y_i]^2 \quad (5)$$

式中: $f(x_i)$ 为输出值; $y_i$ 为目标值。

通常使用决定系数( $R^2$ )(式6)对网络模型进行评价。

$$R^2 = 1 - \frac{\sum_{i=1}^n (Y_a - Y_p)^2}{\sum_{i=1}^n (Y_a - Y_m)^2} \quad (6)$$

式中: $R^2$ 为决定系数; $Y_a$ 为真实值; $Y_p$ 为预测值; $Y_m$ 为真实值的平均值; $\sum_{i=1}^n (Y_a - Y_m)^2$ 为残差平方和。

由于构建了新的特征参数,增加了样本数量和特征数量,导致残差平方和减少,决定系数( $R^2$ )增大,而网络模型本身效果并非得到提升,导致模型评价具有欺骗性。为了消除模型评价的欺骗性,根据构建特征参数的方法和特点,采用修正决定系数( $T$ )对网络模型的泛化能力进行评价。修正决定系数( $T$ )衡量各个自变量对因变量变动的解释程度,其取值越接近1,则变量的解释程度就越高,即预测模型拟合越好、精确度越高。

$$T = 1 - (1 - R^2) \frac{n - 1}{n - p - 1} \quad (7)$$

式中: $T$ 为修正决定系数; $p$ 为样本特征数量。

### 1.4 模型改进

网络模型的训练样本和训练函数对模型的最终预测精度有重要的影响。根据页岩气储层参数和压裂参数的特点,从构建特征参数和训练函数两个方

面对网络模型进行了优化改进。

#### 1.4.1 构建特征参数

样本数据代表性的强弱决定了网络模型学习效果的好坏。通过对页岩气储层参数和压裂参数的特点进行分析,采用两种方式进行构建特征参数:一种是基于压裂参数的物理意义,将现有特征参数转换成具有新物理意义的特征参数,如通过总液量和完井井段长倍数之比得到新的特征参数每米液量,总砂量与总液量之比得到新的特征参数视砂比等;另一种是通过运用现有特征参数进行随机组合方式得到新特征参数,随机组合得到的新特征参数不具有实际物理意义。通过对新构建的特征参数进行测试,选取可以提高网络模型训练效果的特征参数作为训练样本。

数据集中,原始特征参数包含水平井段长等8个工程和地质参数,如表1所示。

通过基于物理意义转换和随机组合后,构建了每米液量等5个新的特征参数,如表2所示。

通过修正决定系数( $T$ )和均方误差(MSE)对构建特征参数前后模型的预测效果进行分析,结果见表3。由表3可知,构建特征参数后的修正决定系数值为0.95,远高于构建特征参数前的0.68。构建特征参数后的均方误差值为0.025,远低于构建特征参数前的0.536。

以样本外10口井作为验证集来检验网络模型预测效果(图1)。由图1可知,相比构建特征参数前,构建特征参数后的预测产量与实际产量交会图与45°线更贴近。

通过比较构建特征参数前后的修正决定系数、

表1 原始特征参数  
Table 1 Original feature parameters

序号	参数名称	参数符号
1	水平井段长/m	SP
2	完井井段长/m	WJ
3	总液量/m <sup>3</sup>	ZY
4	总砂量/m <sup>3</sup>	ZS
5	压裂段数	YL
6	含气量/(m <sup>3</sup> /t)	HT
7	孔隙度/%	KX
8	渗透率/10 <sup>-3</sup> μm <sup>2</sup>	ST

均方误差、拟合效果等方面可以得出,通过构建特征参数后能明显提高网络模型的预测效果。

### 1.4.2 训练函数优化

研究针对样本数据集较多且代表性强的特点,采用小批量梯度下降算法(MBGD)。该算法以损失较小部分精确度和增加一定数量的迭代次数为代价,能够有效提升网络模型的总体优化效率。

梯度下降的代价函数关于 $\omega$ 和 $b$ 的偏导数公式如下:

$$\frac{\partial \text{cost}(\omega, b)}{\partial \omega} = \frac{1}{n} \left( \sum_{i=1}^n \omega x_i + b - y_i \right) x_i \quad (8)$$

$$\frac{\partial \text{cost}(\omega, b)}{\partial b} = \frac{1}{n} \left( \sum_{i=1}^n \omega x_i + b - y_i \right) \quad (9)$$

式(8)一式(9)中: $\omega$ 为权重系数; $b$ 为偏置系数; $x$ 为

输入值; $y$ 为真实值。

当 $n$ 为1时,此计算代价函数梯度使用一个样本数据;当 $n$ 为样本总量时,计算代价函数梯度使用全部样本数据;当 $n$ 为部分数量时,计算代价函数梯度使用一小批量样本数据。研究将小批量样本数 $n$ 设置为128。

图2给出了分别使用随机梯度下降算法(SGD)(图2a)和小批量梯度下降算法(MBGD)(图2b)的代价函数趋势。由图2a可知,在训练集和测试集上,随着迭代次数的增加,均方误差值虽然整体呈下降趋势,但代价函数曲线震荡幅度较大,梯度下降稳定性差、偏差大;由图2b可知,在训练集和测试集上,随着迭代次数的增加,代价函数曲线非常平滑地下降,即梯度下降稳定性好、偏差小,并且可以快速达到最优值。通过结果比较可知,针对页岩气储层各参数数据集特点,采用的小批量梯度下降算法(MBGD)可以有效地提升网络模型的总体稳定性和预测精度。

表2 新构建特征参数

Table 2 Newly constructed feature parameters

序号	参数名称	构建形式
1	每米液量/ $\text{m}^3$	$ZY/(WJ \times 0.3)$
2	每米砂量/ $\text{m}^3$	$ZS/(WJ \times 0.3)$
3	视砂比/ $\text{m}^3$	$ZS/ZY$
4	压裂单段长/ $\text{m}$	$(WJ/YL) \times 0.3$
5	随机组合	$(ZY-ZS)/YL$

表3 构建特征参数前后对比

Table 3 Comparison of feature structures

特征参数类型	修正决定系数( $T$ )	均方误差( $MSE$ )
构建特征参数前	0.68	0.536
构建特征参数后	0.95	0.025






图1 构建特征参数前后预测产量与实际产量交会图  
Fig. 1 Crossplot of actual and predicted yield before and after constructing feature parameters



a. 随机梯度下降算法



b. 小批量梯度下降算法

图2 随机梯度下降算法和小批量梯度下降算法的代价函数趋势

Fig. 2 Cost function trend graph of stochastic gradient descent algorithm and small batch gradient descent algorithm

### 1.5 模型结构

隐藏层神经元个数对网络模型的拟合效果有重要影响。研究采取公式法(式10)和试算法结合的方式进行选择。图3为不同隐藏层神经元个数的均方误差(MSE)值折线。由图3可知,当隐藏层神经元个数为25时均方误差(MSE)值最低,则选取隐藏层神经元个数为25。

$$S = 2m + 1 \quad (10)$$

式中: $S$ 为隐藏层神经元个数, $m$ 为输入层神经元个数。

通过构建特征参数后,网络模型的输入神经元由原始特征参数和新构建的特征参数组成,分别包含水平井段长等8个原始特征参数,以及每米液量等5个新构建特征参数,共13个参数。隐藏层神经元个数选取为均方误差(MSE)值最小时的神经元个数25,最后输出层为前3个月平均日产量参数,则建立的人工神经网络模型的最终结构为13—25—1(图4)。




图3 不同隐藏层神经元个数的均方误差(MSE)值折线

Fig. 3 Mean square error (MSE) curves of neurons in different hidden layers

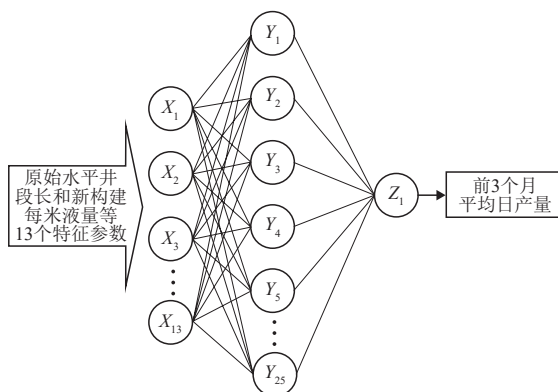


图4 网络模型结构

Fig. 4 Network model structure

## 2 实例应用

### 2.1 模型训练

研究以国外某页岩气区块多口井的储层参数、压裂参数和产量作为数据集,共10 000组数据,页岩气区块孔隙度平均为1.5%,渗透率平均为 $0.0028 \times 10^{-3} \mu\text{m}^2$ ,含气量平均为 $3.1 \text{ m}^3/\text{t}$ 。将整个数据集划分为训练集、测试集和验证集。训练集数据用于训练确定网络模型各层的训练权值,约占整个数据集的80%;测试集数据用于测试网络模型在训练集以外的泛化性和可靠性,约占整个数据集的20%;验证集数据将作为样本外数据对整体模型的准确性进行验证。另选样本外10口井作为验证集,用于检验预测值与真实值之间的匹配程度。

网络预测模型采用典型的三层神经网络模型,将原始特征参数和新构建特征参数共13个特征参数作为网络模型的输入层神经元,隐藏层神经元为25个,前3个月平均日产量作为输出层神经元。根据多次学习训练较好的结果为参考,将网络模型最大迭代次数设定为1 000,将学习率设定为0.07,每次学习最小数据集设定为128。

### 2.2 预测结果

通过利用验证集数据,对比分析了改进人工神经网络模型和传统BP神经网络模型的预测效果。

表4为验证集10口井前3个月实际平均日产量

表4 日实际产量与改进的网络模型方法和传统BP方法预测结果对比

Table 4 Comparison of daily actual yield with prediction results of proposed method and traditional BP method

序号	实际日产量/ $10^3 \text{ m}^3$	传统BP方法预测值/ $10^3 \text{ m}^3$	相对误差/ %	改进的网络模型方法预测值/ $10^3 \text{ m}^3$	相对误差/ %
1	9.184	7.632	-16.89	8.863	-3.49
2	2.651	3.594	35.57	2.889	8.97
3	3.706	4.356	17.53	3.836	3.51
4	5.907	4.986	-15.59	6.106	3.36
5	5.678	6.723	18.40	5.852	3.06
6	3.188	3.976	24.72	2.901	-9.00
7	5.729	6.932	20.99	5.665	-1.12
8	9.740	8.134	-16.49	9.985	2.52
9	2.403	1.688	-29.75	2.565	6.74
10	5.374	6.266	16.59	5.594	4.09

值与改进的网络模型方法预测产量值和传统BP神经网络方法预测产量值的对比。由表4可知,首先,通过比较每口井的实际产量值和预测产量值,结果显示,相比传统BP神经网络模型方法预测产量值,改进的网络模型方法预测产量值更加接近实际产量值;其次,通过比较分析表中相对误差值可知,传统BP神经网络模型方法的预测值最大偏差程度为35.57%,最小为15.59%,而改进网络模型方法预测值的最大、最小偏差程度分别为9.00%、1.12%,均远低于传统BP神经网络模型预测值的偏差程度。这表明,相比于传统的BP神经网络模型,改进的神经网络模型预测结果最大、最小相对误差值的振幅有较大的降低,建立的改进网络模型方法在预测精度及稳定性方面明显得到提升。

图5为实际产量值与改进的网络模型方法预测产量值和传统BP神经网络方法预测产量值的折线。由图5可知,改进后的网络模型预测的产量值与实际产量值折线更加贴合,其预测精确度远高于传统BP神经网络模型的预测产量值。

表5给出了改进的网络模型和传统BP神经网络模型的均方误差(MSE)和修正决定系数(T)对比结果。由表5可知,改进的网络模型方法均方误差值为0.006,远低于传统BP神经网络模型均方误差值0.132;修正决定系数值为0.95,远远高于传统BP神经网络模型的修正决定系数值0.73。




图5 实际产量值与改进的网络模型方法预测产量值和传统BP神经网络方法预测产量值的折线

Fig. 5 The line chart of actual yield value and the improved network model method to predict the yield value and traditional BP neural network method

表5 2种模型结果评价

Table 5 Evaluation of two models

模型类型	均方误差(MSE)	修正决定系数(T)
传统BP神经网络模型	0.132	0.73
改进的网络模型	0.006	0.95

综上所述,通过验证结果显示,改进的网络模型方法在分析页岩气储层参数、压裂参数与产量关系时,其预测产量值与实际产量值吻合度较高,并且在相对误差、均方误差(MSE)和修正决定系数(T)结果对比后发现,其准确率和稳定性均高于传统BP神经网络模型。

### 3 结论

1) 研究设计了基于物理意义和随机组合两种构建特征参数的方法,使训练样本特征参数数据代表性更强,且更加拟合网络模型,可以进一步提高网络模型的学习效果。通过对比构建特征参数前后的修正决定系数、均方误差以及拟合效果,可得构建特征参数后的预测产量值与实际产量值更贴近。

2) 针对页岩气储层参数和压裂参数的数据集特点,采用了小批量梯度下降法(MBGD)作为训练函数,可以有效提升网络预测模型的稳定性和总体优化效率。

3) 建立的改进人工神经网络模型能较好地拟合页岩气储层参数、压裂参数与产量之间复杂的非线性关系。且相比传统的BP神经网络模型,改进人工神经网络模型的预测精度和稳定性都具有明显优势。

#### 参考文献

- [1] 何叶,张涵冰,郑儒,等.基于元素录井的页岩气水平井钻遇小层分析及储层评价参数计算[J].天然气工业,2021,41(增刊1):110-117.  
HE Ye, ZHANG Hanbing, ZHENG Ru, et al. Analyzing the sublayers drilled by shale-gas horizontal wells and calculating reservoir evaluation parameters based on element logging[J]. Natural Gas Industry, 2021, 41(sup.1): 110-117.
- [2] 王燕,雷有为,付小平,等.涪陵区块凉高山组页岩气储层特征及关键参数评价[J].复杂油气藏,2020,13(4):23-28.  
WANG Yan, LEI Youwei, FU Xiaoping, et al. Characteristics and key parameter evaluation of shale gas reservoirs in Lianggaoshan Formation in Fuling Block[J]. Complex Hydrocarbon Reservoirs, 2020, 13(4): 23-28.
- [3] 李亚龙,刘先贵,胡志明,等.页岩气水平井产能预测数值模型综述[J].地球科学进展,2020,35(4):350-362.  
LI Yalong, LIU Xiangui, HU Zhiming, et al. Summary of numerical models for predicting productivity of shale gas horizontal wells[J]. Advances in Earth Science, 2020, 35(4): 350-362.
- [4] 陈元千,徐佳倩,傅礼兵.预测页岩气井产量和可采储量泛指数递减模型的建立及应用[J].油气地质与采收率,2021,28(1):132-136.

- CHEN Yuanqian, XU Jiaqian, FU Libing. Establishment and application of pan exponential decline model for forecasting production rate and recoverable reserves of shale gas wells[J]. *Petroleum Geology and Recovery Efficiency*, 2021, 28(1): 132-136.
- [5] 王清媛, 黄全舟. 浅析机器学习在石油测井领域的研究进展[J]. *清洗世界*, 2021, 37(3): 120-122.
- WANG Qingyuan, HUANG Quanzhou. Research progress of machine learning in oil logging[J]. *Cleaning world*, 2021, 37(3): 120-122.
- [6] 闵超, 代博仁, 张馨慧, 等. 机器学习在油气行业中的应用进展综述[J]. *西南石油大学学报(自然科学版)*, 2020, 42(6): 1-15.
- MIN Chao, DAI Boren, ZHANG Xinhui, et al. A review of the application progress of machine learning in oil and gas industry[J]. *Journal of Southwest Petroleum University (Science & Technology Edition)*, 2020, 42(6): 1-15.
- [7] NEGASH Berihun Mamo, YAW Atta Dennis. 基于人工神经网络的注水开发油藏产量预测[J]. *石油勘探与开发*, 2020, 47(2): 357-365.
- NEGASH Berihun Mamo, YAW Atta Dennis. Artificial neural network based production forecasting for a hydrocarbon reservoir under water injection[J]. *Petroleum Exploration and Development*, 2020, 47(2): 357-365.
- [8] 林年添, 张栋, 张凯, 等. 地震油气储层的小样本卷积神经网络学习与预测[J]. *地球物理学报*, 2018, 61(10): 4110-4125.
- LIN NianTian, ZHANG Dong, ZHANG Kai, et al. Predicting distribution of hydrocarbon reservoirs with seismic data based on learning of the small-sample convolution neural network[J]. *Chinese Journal of Geophysics*, 2018, 61(10): 4110-4125.
- [9] ZHANG H Q, YU F S, SUN J C, et al. Deep learning for sea cucumber detection using stochastic gradient descent algorithm[J]. *European Journal of Remote Sensing*, 2020, 53(sup.1): 53-62.
- [10] 李英, 贺春林. 面向深度神经网络训练的数据差分隐私保护随机梯度下降算法[J]. *计算机应用与软件*, 2020, 37(4): 252-259.
- LI Ying, HE Chunlin. Data differential privacy protection stochastic gradient descent algorithm for deep neural network training[J]. *Computer Applications and Software*, 2020, 37(4): 252-259.
- [11] 穆翔宇, 范钰, 李苏吉, 等. 一种基于梯度下降算法的蜕变关系生成方法[J]. *吉林大学学报(理学版)*, 2020, 58(6): 1429-1435.
- MU Xiangyu, FAN Yu, LI Suji, et al. Method of generating metamorphic relationship based on gradient descent algorithm[J]. *Journal of Jilin University (Science Edition)*, 2020, 58(6): 1429-1435.
- [12] 黎静华, 黄乾, 韦善阳, 等. 基于S-BGD和梯度累积策略的改进深度学习方法及其在光伏出力预测中的应用[J]. *电网技术*, 2017, 41(10): 3292-3300.
- LI Jinghua, HUANG Qian, WEI Shanyang, et al. Improved deep learning algorithm based on S-BGD and gradient pile strategy and its application in PV power forecasting[J]. *Power System Technology*, 2017, 41(10): 3292-3300.
- [13] 李兴怡, 岳洋. 梯度下降算法研究综述[J]. *软件工程*, 2020, 23(2): 1-4.
- LI Xingyi, YUE Yang. Survey of gradient descent algorithm[J]. *Software Engineer*, 2020, 23(2): 1-4.
- [14] 陈泽坤, 程晓荣. 基于梯度下降算法的房价回归分析与预测[J]. *信息技术与信息化*, 2020, 5(5): 10-13.
- CHEN Zekun, CHENG Xiaorong. Housing price regression analysis and prediction based on gradient descent algorithm[J]. *Information Technology & Informatization*, 2020, 5(5): 10-13.
- [15] 耿晓燕, 何畅, 万玉金. 基于灰色关联法的页岩气水平井产能评价及预测[J]. *数学的实践与认识*, 2020, 50(19): 100-106.
- GENG Xiaoyan, HE Chang, WAN Yujin. Production evaluation and prediction of horizontal shale gas wells based on grey correlation method[J]. *Mathematics in Practice and Theory*, 2020, 50(19): 100-106.
- [16] 郑亚军, 刘宝成, 张旭泽, 等. 数据驱动与地质规律融合的超低渗油藏产能预测方法[J]. *石油地质与工程*, 2022, 36(4): 75-81.
- ZHENG Yajun, LIU Baocheng, ZHANG Xuze, et al. Productivity prediction method of ultra-low permeability reservoir based on data-driven and geological law[J]. *Petroleum Geology & Engineering*, 2022, 36(4): 75-81.
- [17] 田媛, 梁永全. 基于小批量梯度下降的布谷鸟搜索算法[J]. *山东科技大学学报(自然科学版)*, 2020, 39(5): 56-67.
- TIAN Yuan, LIANG Yongquan. Cuckoo search algorithm based on mini-batch gradient descent[J]. *Journal of Shandong University of Science and Technology (Natural Science)*, 2020, 39(5): 56-67.
- [18] 宋杰, 朱勇, 许冰. 批量减数更新方差缩减梯度下降算法BSUG[J]. *计算机工程与应用*, 2020, 56(22): 117-123.
- SONG Jie, ZHU Yong, XU Bing. Batch subtraction update variance reduction gradient descent algorithm BSUG[J]. *Computer Engineering and Applications*, 2020, 56(22): 117-123.
- [19] 李英, 贺春林. 面向深度神经网络训练的数据差分隐私保护随机梯度下降算法[J]. *计算机应用与软件*, 2020, 37(4): 252-259.
- LI Ying, HE Chunlin. Data differential privacy protection stochastic gradient descent algorithm for deep neural network training[J]. *Computer Applications and Software*, 2020, 37(4): 252-259.
- [20] 王一鸣, 宋先海, 张学强. 应用人工神经网络算法的地震面波非线性反演[J]. *石油地球物理勘探*, 2021, 56(5): 979-991.
- WANG Yiming, SONG Xianhai, ZHANG Xueqiang. Research on nonlinear inversion of seismic surface waves based on artificial neural network algorithm[J]. *Oil Geophysical Prospecting*, 2021, 56(5): 979-991.
- [21] 许泽坤, 陈隽. 非线性结构地震响应的神经网络算法[J]. *工程力学*, 2021, 38(9): 133-145.
- XU Zekun, CHEN Jun. Neural network algorithm for nonlinear structural seismic response[J]. *Engineering Mechanics*, 2021, 38(9): 133-145.
- [22] 卫浪, 蒲红宇, 向辉, 等. 基于改进神经网络的丙烷回收流程多目标优化[J]. *石油与天然气化工*, 2021, 50(1): 66-71.
- WEI Lang, PU Hongyu, XIANG Hui, et al. Multi-objective optimization of propane recovery process based on improved BP neural network[J]. *Chemical Engineering of Oil & Gas*, 2021, 50(1): 66-71.