

引用格式:余洋,董银涛,李云波,等.基于改进SSA-BPNN的煤层气直井井底流压预测研究[J].油气藏评价与开发,2025,15(2):250-256.

YU Yang, DONG Yintao, LI Yunbo, et al. Research on prediction of bottom hole flowing pressure for vertical coalbed methane wells based on improved SSA-BPNN[J]. Petroleum Reservoir Evaluation and Development, 2025, 15(2): 250-256.

DOI: 10.13809/j.cnki.cn32-1825/te.2025.02.009

基于改进SSA-BPNN的煤层气直井井底流压预测研究

余洋¹,董银涛²,李云波¹,包宇¹,张立侠¹,孙浩¹

(1. 中国石油勘探开发研究院,北京 100083;2. 中海油研究总院有限责任公司,北京 100028)

摘要:煤层气资源广泛应用直井开发,采用控压控水的排采制度,井底流压是排采方案设计与设备选型的重要参数,因此,煤层气直井井底流压预测具有重要的意义。为了便捷、准确地预测煤层气直井井底流压,指导煤层气井的控压排采,引入机器学习领域中的反向传播神经网络(BPNN)模型,同时对麻雀搜索算法(SSA)进行改进,耦合构建基于改进麻雀搜索算法-反向传播神经网络(SSA-BPNN)的煤层气直井井底流压预测模型。选取了生产现场常规测量的5个影响井底流压的参数作为井底流压预测模型的输入参数,相对应的井底流压数值作为井底流压预测模型的输出参数。将600组实测数据划分为训练集、验证集与测试集,完成了煤层气直井井底流压预测模型的建立与校验工作。BPNN模型与改进SSA-BPNN模型的验证集平均绝对百分比误差分别为3.10%与0.53%,可以看出利用改进SSA与BPNN的耦合建模,能够解决BPNN易陷于局部最优的问题,提高了煤层气直井井底流压的预测精度。同时将改进SSA-BPNN模型与遗传算法-支持向量回归机(GA-SVR)模型和物理模型解析方法进行对比,结果显示:3种不同模型的平均绝对百分比误差分别为1.318%、4.971%、18.156%,改进SSA-BPNN模型的误差最低,且在井底流压较低时,改进SSA-BPNN模型的预测精度显著提高,展现出较高的准确性与良好的适用性。改进SSA-BPNN模型仅需5个输入参数,减少了输入与计算参数的复杂度,且无须考虑井筒内流体分布情况,可覆盖排采各阶段,在不同压力区间都有较高准确性。

关键词:煤层气;麻雀搜索算法;神经网络;井底流压;预测模型

中图分类号:TE37

文献标识码:A

Research on prediction of bottom hole flowing pressure for vertical coalbed methane wells based on improved SSA-BPNN

YU Yang¹, DONG Yintao², LI Yunbo¹, BAO Yu¹, ZHANG Lixia¹, SUN Hao¹

(1. PetroChina Research Institute of Petroleum Exploration and Development, Beijing 100083, China;

2. CNOOC Research Institute Co., Ltd., Beijing 100028, China)

Abstract: Coalbed methane resources are extensively developed using vertical wells, with controlled-pressure and controlled-water drainage systems. The flowing bottom hole pressure is a crucial parameter in the design of drainage schemes and equipment selection. Therefore, it is of great significance to predict the flowing bottom hole pressure for vertical coalbed methane wells. To conveniently and accurately forecast the flowing bottom hole pressure of vertical coalbed methane and guide their pressure control and drainage, a Backpropagation Neural Network (BPNN) algorithm from the field of machine learning was introduced. Additionally, the Sparrow Search Algorithm (SSA) was improved. These were coupled to establish a forecasting model for flowing bottom hole pressure based on the improved SSA-BPNN approach. Five routinely measured parameters that influence flowing bottom hole pressure were selected as the input parameters for the prediction model, with corresponding bottom hole pressure values as the output parameters. A total of 600 sets of field-measured data were partitioned into training, validation, and testing datasets to develop and validate the forecasting model for vertical coalbed methane wells. The validation set showed that the mean absolute percentage errors for the BPNN model and the Improved SSA-BPNN model on the validation set were 3.10% and 0.53%, respectively. This demonstrated that coupling the Improved SSA and BPNN effectively overcame the propensity of BPNN to converge to local optima, thereby improving the prediction accuracy of flowing bottom hole pressure in a vertical

收稿日期:2024-01-08。

第一作者简介:余洋(1992—),男,博士,工程师,主要从事油气田开发研究工作。地址:北京市海淀区学院路20号,邮政编码:100083。E-mail: yuyang2022@petrochina.com.cn

基金项目:中国石油科学研究与技术开发项目“海外大型碳酸盐岩油藏高效上产关键技术研究”(2023ZZ19-04)。

coalbed methane well. Furthermore, the improved SSA-BPNN model was compared with the Genetic Algorithm-Support Vector Regression (GA-SVR) method and the physical model-based analytical method. The results revealed that the mean absolute percentage errors for these three different models were 1.318%, 4.971%, and 18.156%, respectively. The Improved SSA-BPNN model had the lowest error, and its prediction accuracy significantly improved when the flowing bottom hole pressure was low, demonstrating its higher accuracy and strong applicability. The Improved SSA-BPNN model requires only five input parameters, reducing the complexity of input and calculation parameters. It does not require consideration of the fluid distribution within the wellbore and can cover all stages of drainage, maintaining high accuracy across different pressure ranges.

Keywords: coalbed methane; sparrow search algorithm; neural network; bottom hole flowing pressure; prediction model

随着常规油气资源的逐渐枯竭,非常规油气资源将成为化石能源领域的重要接替力量。煤层气是一种十分重要的非常规天然气资源^[1-2],其资源潜力巨大,经过30余年的探索,煤层气产业已经初具规模^[3]。中国煤层气资源多应用直井开发,同时采用控压控水的排采制度^[4-6],煤层气直井的井底流压对于排采方案设计和管具有的重要意义。建立煤层气直井井底流压的预测模型,可为煤层气直井开发的举升设计、控压生产与工程措施等方面提供一定的依据,进而可为煤层气藏开发方案的编制奠定基础。

煤层气直井通常采用排水采气的生产方式,井筒内的流体分布与流动直接决定着井底流压的大小。在排采的不同阶段,井筒内涉及的流动类型存在差异,如在排采初期,产水量大而产气量极少,液体单相流动可能出现在煤层气解吸产出后,存在气液两相流动;排采中后期亦可能存在环空气体单相流动,井底流压计算时甚至需要考虑上部气柱、下部混气液柱的情形,增加了计算的复杂程度。目前,在煤层气直井井底流压预测研究方面,不同学者从不同的角度出发,开展了煤层气井井底流压预测研究,研究模型涵盖了能量与质量守恒方法、经验回归法、基于水动力学的环空压力计算方法等^[7-14],均取得了较好的研究成果。上述预测方法在实际应用过程中,需要根据实际的排采阶段结合生产数据判断井筒内流动类型,分别选择适用的模型(如单相流模型或气液两相流模型)计算井底流压。但以上各模型计算过程相对复杂、计算参数较多,部分参数依据经验取值或经验公式计算,如煤层气柱中点压力需反复迭代求取,压力梯度校正系数通过实验的方法确定,两相流持液率直接赋予经验值等,大量迭代计算比较耗时且不同模型适用的排采阶段不同,使得现有模型的适用范围受到一定限制。

近年来,机器学习方法由于其独特的优势,在石油工程领域的应用愈发广泛^[15]。其中,反向传播神经网络(Back Propagation Neural Network,简称BPNN)是一种非线性映射处理系统,具有强大的自组织、自学习、自适应能力,对非线性函数有较强的逼近能力,能够进行科学学习与合理预测^[16-18]。但同时,在BPNN的实际应用过程中,也存在一些问题,如预测结果易陷入局部最优、训练迭代收敛速度慢等^[19-20]。而麻雀搜索算法^[21](Sparrow

Search Algorithm,简称SSA)作为一种新兴的群体智能优化算法,具有不易陷入局部最优、全局寻优能力强、实现简单、鲁棒性强等优点。

煤层气直井井底流压解析模型存在计算复杂、不同解析模型适用范围受限的难题,而机器学习方法具有无须识别井筒内流动类型,可同时覆盖排采各阶段的优势,因此,研究采用机器学习方法中的BPNN预测煤层气直井井底流压,以达到便捷、准确预测井底流压的目的。同时,针对常规BPNN存在的预测易陷入局部最优的难题,通过耦合群体智能优化算法中的SSA来提高预测精度。

综上所述,基于SSA,提出改进的SSA优化BPNN的初始权值与阈值,建立了基于改进的SSA-BPNN的煤层气直井井底流压预测模型,利用煤层气直井现场生产数据进行检验,同时与机器学习领域中广泛应用的基于遗传算法-支持向量回归机(GA-SVR)和常规解析方法中考虑因素较为全面的煤层气直井井筒环空压力模型^[14]的预测结果进行对比,评估改进的SSA-BPNN模型的准确性与适应性。

1 基础理论

1.1 BPNN

BPNN是一种带有隐含层的多层前馈式神经网络^[22],由一个输入层、一个或多个隐含层和一个输出层组成,其信息由输入层向输出层正向传播,而误差则由输出层开始反向传播。关于BPNN的理论与实践已经证明,在不限制隐含层节点数的情况下,由输入层、隐含层和输出层构成的BPNN可以完成任意的非线性映射^[23-24]。由3层BPNN的拓扑结构示意图(图1)可知,在训练过程中信息完成从输入层至隐含层,再到输出层的一个传播过程。

设输入层共有 i 个神经元,输入层的输入信号为 I_i ,隐含层共有 j 个神经元,隐含层神经元接收到的输入信号为 H_j ,隐含层神经元的输出信号为 M_j ,输出层共有 k 个神经元,输出层神经元接收到的输入信号为 O_k ,最终输出




图1 3层BPNN的拓扑结构示意图

Fig. 1 Schematic diagram of topology for BP neural network with three layers

信号为 y_k 。则在信号正向传播的过程中,隐含层神经元接收到的输入信号计算公式为:

$$H_j = \sum_i \omega_{ij} I_i + \theta_j \quad (1)$$

隐含层神经元的输出信号计算公式为:

$$M_j = \varphi(H_j) = \varphi\left(\sum_i \omega_{ij} I_i + \theta_j\right) \quad (2)$$

输出层神经元接收到的输入信号计算公式为:

$$O_k = \sum_j \omega_{jk} M_j + \theta_k = \sum_j \omega_{jk} \varphi\left(\sum_i \omega_{ij} I_i + \theta_j\right) + \theta_k \quad (3)$$

最终的输出信号即为:

$$y_k = \phi(O_k) = \phi\left[\sum_j \omega_{jk} \varphi\left(\sum_i \omega_{ij} I_i + \theta_j\right) + \theta_k\right] \quad (4)$$

式中: $\varphi(\cdot)$ 、 $\phi(\cdot)$ 分别为隐含层与输出层的激活函数; ω_{ij} 、 ω_{jk} 为连接各层间的权值; θ_j 、 θ_k 为相关神经元节点的阈值。

在误差反向传播过程中,权值更新的计算公式为:

$$\Delta\omega_{ij} = l\delta_j I_i \quad (5)$$

$$\Delta\omega_{jk} = l\delta_k M_j \quad (6)$$

$$\Delta\theta_j = l\delta_j \quad (7)$$

$$\Delta\theta_k = l\delta_k \quad (8)$$

式中: $\Delta\omega_{ij}$ 、 $\Delta\omega_{jk}$ 分别为权值 ω_{ij} 与 ω_{jk} 的改变量; $\Delta\theta_j$ 、 $\Delta\theta_k$ 分别为阈值 θ_j 与 θ_k 的改变量; l 为误差反向传播过程中的学习率,通常取(0, 1]范围内的常数值; δ_j 、 δ_k 为各层的误差信号。

1.2 SSA及其改进算法

SSA是学者们受麻雀的觅食行为和反捕食行为的启发,于2020年提出的一种新型群智能优化算法^[21],该算法具有全局寻优能力强,收敛速度快的优点。SSA的优

化过程模仿了麻雀群觅食的过程,可以将该觅食过程抽象为存在侦查预警机制的发现者-加入者模型。麻雀群中找到食物较好的个体(即适应度较好的个体)为发现者,其他个体作为加入者,并选取一定比例的麻雀展开侦查预警,若发现危险则放弃食物。具体算法如下^[21]:

麻雀群中发现者的位置更新公式为:

$$X_{s,d}^{t+1} = \begin{cases} X_{s,d}^t \exp\left(\frac{-s}{\alpha M}\right), R_2 < T \\ X_{s,d}^t + QL, R_2 \geq T \end{cases} \quad (9)$$

式中: t 为当前迭代次数; M 为最大迭代次数; $X_{s,d}^t$ 为第 t 代时第 s 只麻雀在第 d 维的位置; $X_{s,d}^{t+1}$ 为第 $t+1$ 代时第 s 只麻雀在第 d 维的位置; α 为(0, 1]之间均匀分布的随机数; Q 为服从标准正态分布的随机数; L 为大小为 $1 \times d$ 的全1矩阵; R_2 为预警值,取值范围[0, 1]; T 为安全阈值,取值范围[0.5, 1]。

麻雀群中除了发现者外,其余麻雀作为加入者,其位置更新公式为:

$$X_{s,d}^{t+1} = \begin{cases} Q \exp\left(\frac{X_{\text{worst}}^t - X_{s,d}^t}{s^2}\right), i > \frac{N}{2} \\ X_p^{t+1} + |X_{s,d}^t - X_p^{t+1}| A^+ L, i \leq \frac{N}{2} \end{cases} \quad (10)$$

式中: X_{worst}^t 为第 t 代时的当前最差位置; X_p^{t+1} 为第 $t+1$ 代时被发现者占据的最佳位置; A 为大小为 $1 \times d$ 的矩阵,每个元素随机赋值1或-1, $A^+ = A^T / (AA^T)$, T 为转置符号。

当麻雀群觅食时,其中10%~20%的麻雀会负责侦查预警,其位置更新公式为:

$$X_{s,d}^{t+1} = \begin{cases} X_p^t + \beta(X_{s,d}^t - X_p^t), f_s \neq f_g \\ X_{s,d}^t + K \left(\frac{X_{s,d}^t - X_{\text{worst}}^t}{|f_s - f_w| + \varepsilon} \right), f_s = f_g \end{cases} \quad (11)$$

式中: β 为符合标准正态分布的随机数,用于控制步长; K 为[-1, 1]之间均匀分布的随机数; f_s 为当前第 s 只麻雀的适应度; f_g 、 f_w 分别为当前的最优适应度与最差适应度; ε 为给定的一个非常小的常数值,防止分母为零。

原始的SSA采用Logistic映射完成种群初始化过程,且未采用变异方法。当采用SSA寻优时,可以通过改变其映射与变异方法来达到增强种群多样性的目的,进一步提升算法全局寻优能力,采用Kent映射代替常用的Logistic映射来构造随机新解,利用其更优的均匀遍历性来改善寻优效果^[25-28]。

Kent映射的公式为:

$$Z_{s+1} = \begin{cases} Z_s / \lambda, 0 < Z_s \leq \lambda \\ (1 - Z_s) / (1 - \lambda), \lambda < Z_s < 1 \end{cases} \quad (12)$$

式中: Z_s 为随机序列; λ 为控制参数,取值范围(0,1)。

为提高麻雀种群的多样性,进一步改善寻优效果,在位置更新过程中,引入高斯变异^[27]的策略,具体公式为:

$$Y_a = Y_p[1 + N(0,1)] \quad (13)$$

式中: Y_a 、 Y_p 分别为变异后与变异前的参数值; $N(0,1)$ 为符合标准正态分布的随机数。

2 井底流压预测模型

在建立煤层气直井井底流压预测模型的过程中,首先需要确定模型的输入参数,其中地质参数的影响可由流量参数(日产气量、日产水量)间接反映,机器学习模型在学习过程中也包含了这种隐含信息的影响。基于前人的理论研究基础^[7-14],选取影响井底流压且在生产现场常规测量的5个参数作为改进的SSA-BPNN模型的输入参数:井口套压、动液面高度、动液面深度、日产气量、日产水量,并以煤层气直井井底流压的数值作为改进的SSA-BPNN的输出参数,完成改进的SSA-BPNN井底流压预测模型的构建。

模型具体的计算流程见图2。此次实例研究的数据集源自沁水盆地晋城矿区。晋城矿区煤层气开发的主要井型为直井,其开发方式主要为排水采气,不同直井所处的排采阶段不同。依据筛选相对稳定段生产数据,尽量保证输入、输出参数的范围较大,同时数据集中各组数据重复性较小的原则,筛选出井深介于286~1 062 m,套管内径为124 mm,油管外径为73 mm的27口

煤层气直井在不同排采阶段测得的共计600组实测数据来建立模型,部分数据见表1,输入参数范围:井口套压介于0~3 MPa,动液面高度介于1~302 m,动液面深度介于282~1 044 m,日产气量介于0~12 883 m³,日产水量介于0~90 m³。

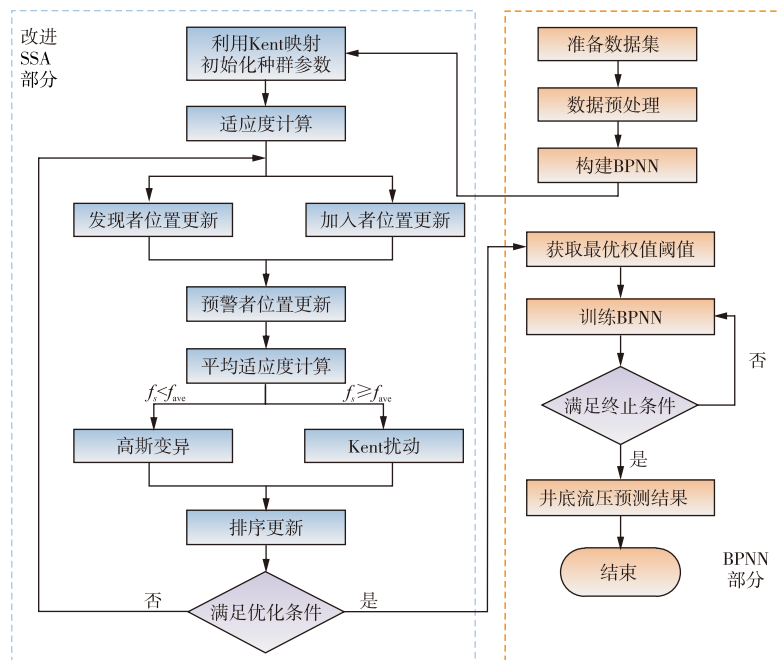
在整体数据集的基础上,开展数据预处理工作;由于5个输入参数的数值数量级不一致,为了提高预测精度,对整体数据集中的输入参数进行归一化处理,归一化所用公式为:

$$\bar{x} = 2 \frac{x - x_{\min}}{x_{\max} - x_{\min}} - 1, \bar{x} \in [-1, 1] \quad (14)$$

式中: \bar{x} 为归一化之后的输入参数值; x 为归一化之前的输入参数值; x_{\min} 为输入参数中的最小值; x_{\max} 为输入参数中的最大值。

输入参数归一化完成后,将600组数据按7:2:1的比例随机划分为训练集、验证集与测试集,其中训练集用于训练改进的SSA-BPNN,验证集用于调整模型的超参数和初步评估模型的能力,测试集则完全不参与训练过程,用于评估最终模型的应用精度。

数据集基础上,构建BPNN的网络结构。利用Kent映射初始化种群参数,在此基础上根据训练集数据开始训练,同时以验证集的预测结果误差作为适应度函数,利用改进的SSA展开寻优流程。首先,分配一定数量的麻雀发现者,其余为加入者,各自更新位置,同时开启预警机制,并计算当前平均适应度 f_{ave} ,若 $f_s < f_{ave}$ 则进行高斯变异^[28],如变异后的个体更优,则取代先前个体,否则不变,若 $f_s \geq f_{ave}$ 则进行Kent扰动,如变异后的个体更优,则取代



注: f_{ave} 为平均适应度。

图2 模型计算流程

Fig. 2 Flow chart of model

表1 煤层气直井井底流压实测数据(部分数据)

Table 1 Measured data of bottom hole flowing pressure for vertical coalbed methane well (partial data)

井口套压/MPa	动液面高度/m	动液面深度/m	日产气量/m ³	日产水量/m ³	井底流压/MPa
0.09	45.29	563.37	12 772.69	24.21	0.54
0.08	65.08	543.58	7 452.36	4.20	0.71
0.10	52.63	556.03	10 896.58	8.50	0.62
0.15	16.72	410.45	4 151.44	18.00	0.31
0.09	62.99	364.18	2 026.69	10.83	0.71
0.13	9.12	424.43	235.92	5.37	0.21
0.20	66.94	364.22	260.09	1.89	0.86
0.14	302.00	361.10	0	4.00	3.18
1.25	17.90	845.00	501.00	1.30	1.40
0.05	64.47	544.19	9 152.99	23.86	0.68
0.15	11.67	421.88	232.83	5.34	0.26
1.39	11.10	300.00	3 650.00	0.90	1.39
2.62	3.20	659.90	158.00	3.90	2.73
0.08	185.40	600.30	0	7.40	1.92

先前个体,否则不变;其次,排序更新,更新整个麻雀种群的最优位置及其适应度、最差位置及其适应度;最后,判断是否达到预设精度或者最大迭代次数,若是则输出最优初始权值、阈值,否则返回循环,进行重新计算。

在神经网络拓扑结构确定的过程中,调整隐含层神经元的个数,评估不同隐含层神经元个数下模型的表现(主要指验证集的表现),选择使性能最优的神经元个数。最终在BPNN部分,设置其输入层的神经元个数为5,隐含层的神经元个数为6,输出层的神经元个数为1,训练算法采用Levenberg-Marquardt算法,隐含层的激活函数采用对数S型logsig函数,目标误差为0.000 02,最大训练次数为500,学习率为0.01;在改进SSA部分,设置种群数量为20,发现者的比例为0.7,负责侦查预警的麻雀比例为0.2,安全阈值为0.6,最大迭代次数为20。

如图3所示,当模型迭代到第15代以后,适应度值与最初相比得到了明显改进(即误差已经很小)。得到寻优结果后,利用最优权值、阈值重新开始训练BPNN,满足终止条件时即停止运行。改进的SSA-BPNN模型的预测结果如图4所示,从图4中可以看出,无论是训练集还是验证集,其预测值与实测值基本均匀分布在45°线附近,并且训练集、验证集的决定系数(R^2)均大于0.999,这表明井底流压的预测值与实测值吻合程度较高。

根据上述设置,单独采用BPNN模型对相同数据集进行预测,通过对比2种方法的平均绝对百分比误差(Mean Absolute Percentage Error,简称MAPE)可知,改进的SSA-BPNN模型与BPNN模型的训练集MAPE分别为0.51%与3.46%,验证集MAPE分别为0.53%与3.10%,可以看出改进的SSA-BPNN模型的精度更高。




图3 适应度曲线

Fig. 3 Fitness value curve




图4 预测与实测井底流压对比

Fig. 4 Comparison diagram of predicted and measured bottom hole flowing pressure

3 模型对比验证

为了进一步评价改进的SSA-BPNN模型的应用精度,将未参与模型训练的测试集代入模型进行预测,得到相应的井底流压预测结果,检验模型的泛化能力。同时

利用机器学习领域中广泛应用的GA-SVR模型^[29-30],以及解析方法中考虑因素较为全面的煤层气直井井筒环空压力模型^[14]对同样的数据集展开预测,进一步检验模型的准确性与适应性。GA-SVR模型即为在SVR模型建立过程中采用GA寻找最优的结构超参数组合,待寻优的参数有3个,分别是惩罚因子、核函数的宽度参数与损失因子。对于文中数据集,最终确定出最佳的惩罚因子为558.928 5,核函数的宽度参数为0.066 9,损失因子为0.014 8。对于解析方法中考虑因素较为全面的煤层气直井井筒环空压力模型,则是利用文献[14]中所提出的解析模型,对测试集中的每一组数据,选取对应的井筒环空压力模型,按深度增量分段迭代,计算环空的压力分布直至煤层深度,最终得到煤层气直井井底流压。

为了反映不同模型预测效果的好坏,研究采用均方误差(Mean Squared Error,简称MSE)、平均绝对误差(Mean Absolute Error,简称MAE)与MAPE这3种常用的误差指标来度量预测结果的准确度。利用不同模型预测出的井底流压与实测流压间的误差对比见表2,由表2可知,改进的SSA-BPNN模型相应的MSE、MAE、MAPE分别为 2.52×10^{-4} 、0.013、1.318%,均为3种预测模型中最低。因此,改进的SSA-BPNN模型具有较高预测精度。

表2 不同预测模型的精度指标比较

Table 2 Comparative analysis of accuracy metrics for different predictive models

预测模型	均方误差	平均绝对误差	平均绝对百分比误差/%
改进SSA-BPNN模型	2.52×10^{-4}	0.013	1.318
GA-SVR模型	5.54×10^{-4}	0.027	4.971
文献[14]中解析模型	1.55×10^{-3}	0.087	18.156

通过进一步分析不同压力区间内3种不同模型的预测结果。如图5所示,在实测井底流压较高的范围内($1 \text{ MPa} < p_{\text{wf}} < 3.25 \text{ MPa}$),3种模型的预测能力相仿,而当实测井底流压较低时($p_{\text{wf}} < 1 \text{ MPa}$),研究模型的预测精度更高。




图5 3种不同模型预测结果对比

Fig. 5 Comparative analysis of prediction results by three different models

4 分析与结论

机器学习方法是建立在数据基础之上的,方法的精度与数据量以及输入数据的变化范围紧密相关,提升数据量可有效提升算法的使用精度,如在某片区域内某项特征值的数值超过了范围上限较多,则可测量更多具有代表性的特征样本,将其补充进之前的数据集,重复整体 workflow,增强预测模型的适应性。

1) 基于BPNN与改进的SSA,提出了一种预测煤层气直井井底流压的新模型。采用改进的SSA对BPNN的权值和阈值进行优化,解决BPNN易陷于局部最优等问题,提高了煤层气直井井底流压的预测精度。

2) 煤层气直井井底流压预测结果对比表明:相较于GA-SVR模型与解析模型,研究模型的MSE、MAE、MAPE分别为 2.52×10^{-4} 、0.013、1.318%,3项误差指标均最低,且在井底流压较低时($p_{\text{wf}} < 1 \text{ MPa}$),研究模型的预测精度显著提高,故研究模型具有较高的准确性与良好的适用性。

3) 研究模型在保证较常规模型具有更高计算精度的同时,仅需5个输入参数,减少了输入与计算参数的复杂度,且无须考虑井筒内流体分布情况,因而具有较好的实用性与更广的适用性。

参考文献

- [1] 邹才能,杨智,黄土鹏,等.煤系天然气的资源类型、形成分布与发展前景[J].石油勘探与开发,2019,46(3):433-442.
ZOU Caineng, YANG Zhi, HUANG Shipeng, et al. Resource types, formation, distribution and prospects of coal-measure gas[J]. Petroleum Exploration & Development, 2019, 46(3): 433-442.
- [2] 娄钰,潘继平,王陆新,等.中国天然气资源勘探开发现状、问题及对策建议[J].国际石油经济,2018,26(6):21-27.
LOU Yu, PAN Jiping, WANG Luxin, et al. Problems and countermeasures in the exploration and development of natural gas resources in China[J]. International Petroleum Economics, 2018, 26(6): 21-27.
- [3] 赵贤正,朱庆忠,孙粉锦,等.沁水盆地高阶煤层气勘探开发实践与思考[J].煤炭学报,2015,40(9):2131-2136.
ZHAO Xianzheng, ZHU Qingzhong, SUN Fenjin, et al. Practice of coalbed methane exploration and development in Qinshui Basin[J]. Journal of China Coal Society, 2015, 40(9): 2131-2136.
- [4] 张遂安,曹立虎,杜彩霞.煤层气井产气机理及排采控压控粉研究[J].煤炭学报,2014,39(9):1927-1931.
ZHANG Suian, CAO Lihu, DU Caixia, et al. Study on CBM production mechanism and control theory of bottom-hole pressure and coal fines during CBM well production[J]. Journal of China Coal Society, 2014, 39(9): 1927-1931.
- [5] 刘斌,杜海为,崔金榜,等.煤层气井排采控制技术发展现状与展望[J].石油钻采工艺,2019,41(4):489-493.
LIU Bin, DU Haiwei, CUI Jinbang, et al. Development status and prospect of CBM well production control technologies[J]. Oil Drilling & Production Technology, 2019, 41(4): 489-493.
- [6] 杜新锋,郭盛强,张群,等.多煤层煤层气井分层控压合层排采技术及装备[J].煤炭科学技术,2018,46(6):114-118.
DU Xinfeng, GUO Shengqiang, ZHANG Qun, et al. Separate-layer

- pressure control and multi-layer drainage technology and device for coalbed methane wells with multiple seams[J]. *Coal Science and Technology*, 2018, 46(6): 114-118.
- [7] 刘新福, 蔡耀光, 李延祥, 等. 单相流煤层气井井底流压预测方法研究[J]. *中国矿业大学学报*, 2010, 39(6): 876-880.
LIU Xinfu, QI Yaoguang, LI Yanxiang, et al. Prediction of flowing bottomhole pressures for single-phase coalbed methane wells[J]. *Journal of China University of Mining & Technology*, 2010, 39(6): 876-880.
- [8] 孙仁远, 宣英龙, 任晓霞, 等. 煤层气井井底流压计算方法[J]. *石油钻采工艺*, 2012, 34(4): 100-103.
SUN Renyuan, XUAN Yinglong, REN Xiaoxia, et al. Methods of bottom-hole flow pressure calculations for coalbed methane wells[J]. *Oil Drilling & Production Technology*, 2012, 34(4): 100-103.
- [9] 杨焦生, 王一兵, 王宪花. 煤层气井井底流压分析及计算[J]. *天然气工业*, 2010, 30(2): 66-68.
YANG Jiaosheng, WANG Yibing, WANG Xianhua. Analysis and computation of flowing bottom hole pressure in coalbed methane wells [J]. *Natural Gas Industry*, 2010, 30(2): 66-68.
- [10] 张永平, 孟召平, 刘贺, 等. 煤层气井排采初期井底流压动态模型及应用分析[J]. *煤田地质与勘探*, 2016, 44(2): 29-33.
ZHANG Yongping, MENG Zhaoping, LIU He, et al. Dynamic model for bottomhole flowing pressure in initial stage of CBM wells drainage and its application[J]. *Coal Geology & Exploration*, 2016, 44(2): 29-33.
- [11] 刘新福, 蔡耀光, 刘春花, 等. 气水两相煤层气井井底流压预测方法[J]. *石油学报*, 2010, 31(6): 998-1003.
LIU Xinfu, QI Yaoguang, LIU Chunhua, et al. Prediction of flowing bottomhole pressures for two-phase coalbed methane wells[J]. *Acta Petrolei Sinica*, 2010, 31(6): 998-1003.
- [12] 赵金, 张遂安. 煤层气井底流压生产动态研究[J]. *煤田地质与勘探*, 2013, 41(2): 21-24.
ZHAO Jin, ZHANG Suian. Production dynamics of CBM bottom hole pressure[J]. *Coal Geology & Exploration*, 2013, 41(2): 21-24.
- [13] 毛慧, 韩国庆, 吴晓东, 等. 确定煤层气井合理生产压差的新思路[J]. *天然气工业*, 2011, 31(3): 52-55.
MAO Hui, HAN Guoqing, WU Xiaodong, et al. A new discussion on the determination methods of reasonable drawdown pressure for a coalbed methane gas well[J]. *Natural Gas Industry*, 2011, 31(3): 52-55.
- [14] 董银涛, 鞠斌山, 张遂安. 煤层气直井筒环空压力模型[J]. *煤炭学报*, 2018, 43(9): 2534-2542.
DONG Yintao, JU Binshan, ZHANG Suian. Wellbore annulus pressure model of the vertical coalbed methane well[J]. *Journal of China Coal Society*, 2018, 43(9): 2534-2542.
- [15] 黄家宸, 张金川. 机器学习预测油气产量现状[J]. *油气藏评价与开发*, 2021, 11(4): 613-620.
HUANG Jiachen, ZHANG Jinchuan. Overview of oil and gas production forecasting by machine learning[J]. *Petroleum Reservoir Evaluation and Development*, 2021, 11(4): 613-620.
- [16] 韩力群, 施彦. 人工神经网络理论、设计及应用[M]. 北京: 化学工业出版社, 2002.
HAN Liqun, SHI Yan. Artificial neural network theory, design and application[M]. Beijing: Chemical Industry Press, 2002.
- [17] 沙林秀, 胥陈卓. 基于主成分分析的NCPSO-BP机械钻速预测[J]. *石油钻采工艺*, 2022, 44(4): 515-521.
SHA Linxiu, XU Chenzhuo. Prediction of NCPSO-BP ROP based on principal component ana[J]. *Oil Drilling & Production Technology*, 2022, 44(4): 515-521.
- [18] 王虹, 尤秀松, 李首滨, 等. 基于遗传算法与BP神经网络的支架跟机自动化研究[J]. *煤炭科学技术*, 2021, 49(1): 272-277.
WANG Hong, YOU Xiusong, LI Shoubin, et al. Research on automation of support based on genetic algorithm and BP neural network[J]. *Coal Science and Technology*, 2021, 49(1): 272-277.
- [19] 张金梦, 刘慧君. 遗传算法优化BP神经网络的泊车位数量预测[J]. *重庆大学学报*, 2018, 41(3): 80-85.
ZHANG Jinmeng, LIU Huijun. Prediction of spare parking spaces based on BP neural network optimized by genetic algorithm[J]. *Journal of Chongqing University*, 2018, 41(3): 80-85.
- [20] 臧子婧, 吴海波, 张平松, 等. 基于ABC-BP模型的煤层气含量预测[J]. *煤田地质与勘探*, 2021, 49(2): 152-158.
ZANG Zijing, WU Haibo, ZHANG Pingsong, et al. Prediction of coal seam gas content based on ABC-BP model[J]. *Coal Geology & Exploration*, 2021, 49(2): 152-158.
- [21] XUE J K, SHEN B. A novel swarm intelligence optimization approach: sparrow search algorithm[J]. *Systems Science & Control Engineering An Open Access Journal*, 2020, 8(1): 22-34.
- [22] 赵涛, 于师建. 基于GA-BP神经网络算法的高密度电法非线性反演[J]. *煤田地质与勘探*, 2017, 45(2): 147-151.
ZHAO Tao, YU Shijian. GA-BP neural network algorithm-based nonlinear inversion for high density resistivity method[J]. *Coal Geology & Exploration*, 2017, 45(2): 147-151.
- [23] LECUN Y, BENGIO Y, HINTON G. Deep learning[J]. *Nature*, 2015, 521(7553): 436-444.
- [24] 罗发强, 刘景涛, 陈修平, 等. 基于BP和LSTM神经网络的顺北油田5号断裂带地层孔隙压力智能预测方法[J]. *石油钻采工艺*, 2022, 44(4): 506-514.
LUO Faqiang, LIU Jingtao, CHEN Xiuping. Intelligent method for predicting formation pore pressure in No. 5 fault zone in Shunbei oilfield based on BP and LSTM neural network [J]. *Oil Drilling & Production Technology*, 2022, 44(4): 506-514.
- [25] 刘建军, 石定元, 武国宁. 基于Kent映射的混合混沌优化算法[J]. *计算机工程与设计*, 2015, 36(6): 1498-1503.
LIU Jianjun, SHI Dingyuan, WU Guoning. Hybrid chaotic optimization algorithm based on Kent map[J]. *Computer Engineering And Design*, 2015, 36(6): 1498-1503.
- [26] 周刘喜, 张兴华, 李纬. 一种改进的多目标粒子群优化算法[J]. *计算机工程与应用*, 2009, 45(33): 38-41.
ZHOU Liuxi, ZHANG Xinghua, LI Wei. Improved multi-objective particle swarm optimization algorithm[J]. *Computer Engineering and Applications*, 2009, 45(33): 38-41.
- [27] 李永恒, 赵志刚. 基于越界重置和高斯变异的蝙蝠优化算法[J]. *计算机工程与科学*, 2019, 41(1): 144-152.
LI Yongheng, ZHAO Zhigang. An improved bat algorithm based on cross-border relocation and Gaussian mutation[J]. *Computer Engineering & Science*, 2019, 41(1): 144-152.
- [28] 吕鑫, 慕晓冬, 张钧, 等. 混沌麻雀搜索优化算法[J]. *北京航空航天大学学报*, 2021, 47(8): 1712-1720.
LV Xin, MU Xiaodong, ZHANG Jun, et al. Chaos sparrow search optimization algorithm[J]. *Journal of Beijing University of Aeronautics and Astronautics*, 2021, 47(8): 1712-1720.
- [29] LUO Z, HASANIPANAH M, AMNIEH H B. GA-SVR: a novel hybrid data-driven model to simulate vertical load capacity of driven piles[J]. *Engineering with Computers*, 2021, 37(12): 823-831.
- [30] 孙雷, 罗强, 潘毅, 等. 基于GA-SVR的CO₂驱原油最小混相压力预测模型[J]. *大庆石油地质与开发*, 2017, 36(3): 123-129.
SUN Lei, LUO Qiang, PAN Yi, et al. Predicting model of the oil minimal miscible pressure for the CO₂ flooding based on GA-SVR [J]. *Petroleum Geology & Oilfield Development in Daqing*, 2017, 36(3): 123-129.