

基于物性预测相对渗透率的改进神经网络方法

张言辉

中海石油(中国)有限公司天津分公司, 天津 300459

摘要:油水两相相对渗透率曲线对油藏含水上升规律和产量变化规律有重要影响,是油藏开发的基础数据。为更准确预测相对渗透率曲线端点值、建立储层物性和相对渗透率曲线端点值之间的关系、提高油藏数值模拟精度,以 149 条相对渗透率曲线的渗透率和孔隙度为输入变量,以相对渗透率曲线端点值(束缚水饱和度、残余油饱和度、残余油饱和度下的水相渗透率)为输出变量,建立了一种基于储层物性预测相对渗透率曲线端点值的 BP 神经网络预测模型。经未参与建模的 14 条相对渗透率曲线数据检验,新模型预测绝对误差在 0.03 以内,相对误差小于 9%,满足相对渗透率曲线计算要求;利用该模型预测的 BZ 油藏不同物性级别下的相对渗透率曲线能够反映 BZ 油藏的渗流特征。该研究成果对相对渗透率预测及提高数值模拟精度具有一定借鉴意义。

关键词:相对渗透率曲线;束缚水饱和度;残余油饱和度;BP 神经网络;渗透率;孔隙度

DOI:10. 3969 /j. issn. 1006 - 5539. 2020. 03. 009

Improved Neural Network Method for Predicting Relative Permeability Based on Physical Properties

Zhang Yanhui

CNOOC (China) Tianjin Branch, Tianjin, 300459, China

Abstract: The oil-water two-phase relative permeability curve has important influence on water cut and the oil production decline, which is the basic data of reservoir development. Correcting and predicting the endpoint value of relative permeability curve based on reservoir physical property is one of the keys to improve the accuracy of reservoir numerical simulation. In order to accurately predict the endpoint value of the relative permeability curve, the relationship between the reservoir physical property and the endpoint value of the relative permeability curve was established which is important to improve the reservoir numerical simulation accuracy. Porosity and permeability of the 149 relative permeability curves are taken as the input variables, while the endpoint values of relative permeability curves (bound water saturation, residual oil saturation and residual oil saturation of water phase permeability) as the output variables. On the above basis, a BP neural network prediction model is established to predict the endpoint of relative permeability curve upon reservoir physical property. The accuracy of the model is tested with 14 other

收稿日期:2020 - 02 - 10

基金项目:“十三五”国家科技重大专项“渤海油田加密调整及提高采收率油藏工程技术示范”(2016 ZX 05058001)

作者简介:张言辉(1987 -),男,山东济宁人,工程师,硕士,主要从事海上油田开发生产研究。E-mail:zhangyh27@cnooc.com.cn

relative permeability curve data. The results show that the absolute error of the model is within 0.03 and the relative error is within 9%, which meets the calculation requirements of the relative permeability curve. This method is used to predict the relative permeability curves of BZ reservoir under different physical properties, and the results can reflect the seepage characteristics of actual oil field and provide reference for the prediction of relative permeability and improvement of numerical simulation accuracy.

Keywords: Relative permeability curve; Bound water saturation; Residual oil saturation; BP neural network; Permeability; Porosity

0 前言

油水两相相对渗透率曲线对油藏的含水上升规律及产量变化规律有重要影响,是油藏开发过程中重要的基础数据。对于非均质性较强的油藏,不同油藏部位的物性、润湿性等特征的差异,导致其不同沉积相或微相的渗流特征差异较大,因此油水相对渗透率曲线也存在显著差异^[1-4]。为此,油藏工作者在油藏数值模拟中也常常对相对渗透率曲线中的饱和度端点值和相对渗透率端点值进行端点标定,以达到提高历史拟合精度和预测精度的目的。然而,对于相对渗透率曲线端点值的修改幅度和修改规律,目前仍靠人为经验来确定。储层物性是影响相对渗透率的主要影响因素之一,如果建立储层物性和相对渗透率曲线端点值之间的关系,就可以根据物性的差异实现对相对渗透率端点值的定量调节^[5-6]。目前对于储层物性和相对渗透率关系的研究,限于采用简单的统计方法进行;研究得到两者间的关系为简单的线性关系或者指数关系,且是单一因素(渗透率或孔隙度)与端点值之间的关系。实际上,相对渗透率曲线端点值受渗透率和孔隙度的共同影响,影响规律较为复杂,因此它们之间的定量关系为十分复杂的非线性关系^[7]。

人工神经网络可以逼近错综复杂的非线性映射,是解决复杂非线性关系难于预测问题^[8-13]的有效方法。

1 相对渗透率曲线数据及影响因素

1.1 相对渗透率曲线数据

统计渤海油区中高渗透层整装砂岩油藏油水相渗曲线,得到163条典型油水相渗曲线作为本次研究的相渗曲线基础数据,其对应的实验数据及曲线特征参数范围见表1。

1.2 影响因素

1.2.1 储层空气渗透率

空气渗透率不同的储层,其相对渗透率曲线也不同。俞启泰等人^[14]对国内河流相和三角洲相油藏的相对渗透率曲线进行统计,建立了残余油饱和度下水相相对渗透率与空气渗透率的关系。水相相对渗透率随空

气渗透率的增大而增大,两者呈对数关系,其中河流相油藏的回归关系见式(1)、三角洲相油藏的回归关系见式(2):

$$K_{rwor} = 0.0786 \log K - 0.0243 \quad (1)$$

$$K_{rwor} = 0.0499 \log K + 0.0798 \quad (2)$$

式中: K 为空气渗透率, $10^{-3} \mu\text{m}^2$; K_{rwor} 为残余油饱和度下水相相对渗透率,小数。

表1 油水相对渗透率曲线特征参数表

Tab. 1 Characteristic parameters of oil-water relative permeability curve

数值	相渗特征参数			
	束缚水 饱和度 / (%)	残余油 饱和度 / (%)	两相共流 区宽度 / (%)	残余油饱和度 下水相相对 渗透率
最小值	9.3	17.3	41.5	0.15
最大值	47.7	47.3	60.3	0.66
平均值	23.9	27.6	52.8	0.38

1.2.2 储层孔隙度

储层的孔隙度不同,其相对渗透率曲线也不同。王曙光等人^[7]对大庆油田非稳定流法测量的617条油水相对渗透率曲线数据进行了统计,发现储层的孔隙度与束缚水饱和度下油相渗透率存在较好的统计关系,束缚水饱和度下油相渗透率随孔隙度的增大而增大,两者之间存在对数关系:

$$\phi = 0.01246 \ln K_{oc} + 0.3162 \quad (3)$$

式中: ϕ 为孔隙度,小数; K_{oc} 为束缚水饱和度下油相渗透率,小数。

2 相对渗透率曲线预测模型的建立

2.1 BP 神经网络原理及改进

BP 神经网络由输入层、中间层和输出层组成,当输出层的输出与期望输出不相符时,按照误差梯度下降的方式依次修正各层权值,即误差反向传播,直至误差达到设定值,或者学习的次数达到设定次数。然而,BP 神经网络在学习时也容易出现一些问题,如陷入局部极小值及收敛稳定性低等^[15-17],为了解决以上问题,引入贝

叶斯正则化算法,该算法通过限制 BP 神经网络各神经元的权值来修正其训练性能函数,从而提高 BP 神经网络模型的泛化能力和预测精度。

2.2 预测模型的结构设计

影响相对渗透率曲线的因素较多,由于本次研究的主要目标是利用储层物性预测相对渗透率曲线端点值,因此本次模型的主要输入参数为储层的物性,即储层的渗透率和孔隙度。输出参数为储层的相对渗透率曲线端点值,即束缚水饱和度、残余油饱和度、残余油饱和度下的水相渗透率,模型的网络结构见图 1。

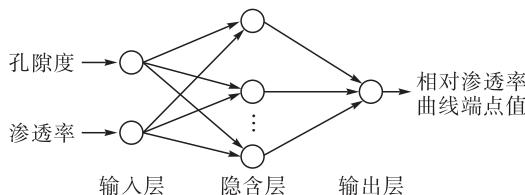


图 1 相对渗透率曲线预测模型结构设计图

Fig. 1 Structural design of relative permeability curve prediction model

2.3 预测模型输入数据的预处理

孔隙度的取值在 0~1 之间,而空气渗透率的取值上限达到上万,两者间的绝对数值相差较大,这会影响模型的预测精度。为解决该问题,需要对输入数据进行预处理。目前常用归一化方法进行预处理,依据该方法,输入数据转化为 0~1 之间的数:

$$K_j = (K_i - K_{\min}) / (K_{\max} - K_{\min}) \quad (4)$$

式中: K_j 为归一化处理后的空气渗透率,小数; K_i 为归一化处理前的空气渗透率, $10^{-3} \mu\text{m}^2$; K_{\min} 为渗透率最小值, $10^{-3} \mu\text{m}^2$; K_{\max} 为渗透率最大值, $10^{-3} \mu\text{m}^2$ 。

$$\phi_j = (\phi_i - \phi_{\min}) / (\phi_{\max} - \phi_{\min}) \quad (5)$$

式中: ϕ_j 为归一化后的孔隙度,小数; ϕ_i 为归一化前的孔隙度,小数; ϕ_{\max} 为孔隙度最大值,小数; ϕ_{\min} 为孔隙度最小值,小数。

2.4 预测模型的学习与训练

利用 MATLAB 编程建立相对渗透率预测模型,相对渗透率预测模型的输入数据为储层的孔隙度和渗透率数据,根据式(6)计算相对渗透率预测模型的隐含层:

$$Y_h = Q(\sum_{i=1}^N \varphi_{ih} M_i - \varepsilon_h), h = 1, 2, \dots, H \quad (6)$$

式中: M_i 为相对渗透率预测模型第 i 个输入层节点的输入数据,即为孔隙度和渗透率的值; N 为输入向量的维数,本文中输入数据包括孔隙度和渗透率,故 N 取值为 2; Q 为输入层和隐含层之间的映射,即为两者之间的函数; Y_h 为相对渗透率预测模型隐含层第 h 个节点的输出, H 表征相对渗透率预测模型隐含层节点的个数,本文中 H 取值为 3; ε_h 为相对渗透率预测模型第 h 个隐含层

节点的阈值; φ_{ih} 为相对渗透率预测模型第 i 个输入层的节点和第 h 个隐含层节点间权重值,该值在学习中不断调整和优化。

根据式(7)计算相对渗透率预测模型的输出层:

$$Z = Q(\sum_{h=1}^H \gamma_h Y_h - \mu) \quad (7)$$

式中: Z 为相对渗透率预测模型的输出值,即为相对渗透率曲线端点值的计算值; γ_h 为第 h 个隐含层节点和输出节点间的权重值,该值在学习中不断调整和优化; μ 为相对渗透率预测模型输出层节点的阈值。

在得到相对渗透率预测模型的输出值后,就可以计算输出值与期望输出之间的误差。传统 BP 神经网络模型是根据式(8)进行计算,计算后根据误差的大小进行不断调整。

$$\delta = 0.5(S - Z)^2 \quad (8)$$

式中: δ 为网络模型输出和样本值间的误差; S 为学习样本的实际值。

为进一步提升传统算法的计算效率和精度,本文对目标函数进行改进,即在贝叶斯正则化算法(Levenberg-Marquardt)^[18-20]中增加各个节点的权重值以及两个系数,如式(9)所示:

$$\nabla \in = a \sum_{i=1}^M \sigma_{ih} + b \delta \quad (9)$$

式中: $\nabla \in$ 为改进后的目标函数值,其中 a 和 b 为系数, σ_{ih} 为相对渗透率预测模型各层节点间权重。

基于以上步骤,不断训练相对渗透率预测模型。本模型的学习过程及训练结果见图 2,由图 2 可见,模型收敛速度相对较快,经过近 200 次训练后,网络趋于稳定。

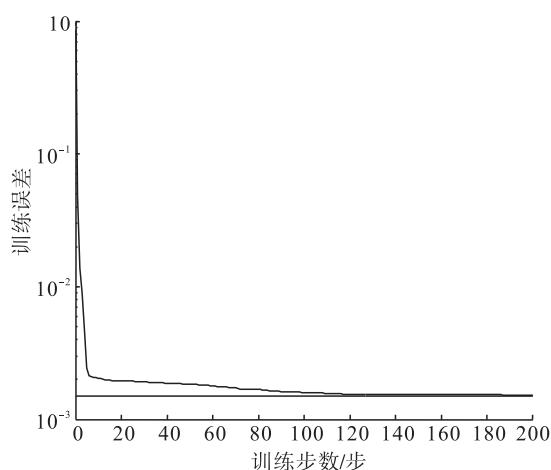


图 2 预测模型学习过程及训练结果曲线图

Fig. 2 Learning process and training results of prediction model

为了检验模型的学习效果,将相对渗透率预测模型的输出值与实际值绘制成交汇图。本文以相对渗透率预测模型预测的束缚水饱和度为例进行介绍。图 3-a)

为未经过贝叶斯正则化算法优化的传统BP神经网络模型的学习效果。从图3-a)可以看出,束缚水饱和度的实际值和输出值分布在45°线附近,说明模型具有一定的精度。图3-b)为经过贝叶斯正则化算法优化后的相对渗透率预测模型。从图3-b)可以看出,束缚水饱和度的实际值和输出值紧密分布在45°线附近,模型的学习精度明显提高,实现了对输入、输出数据的无限逼近,能够用于处理复杂非线性问题。

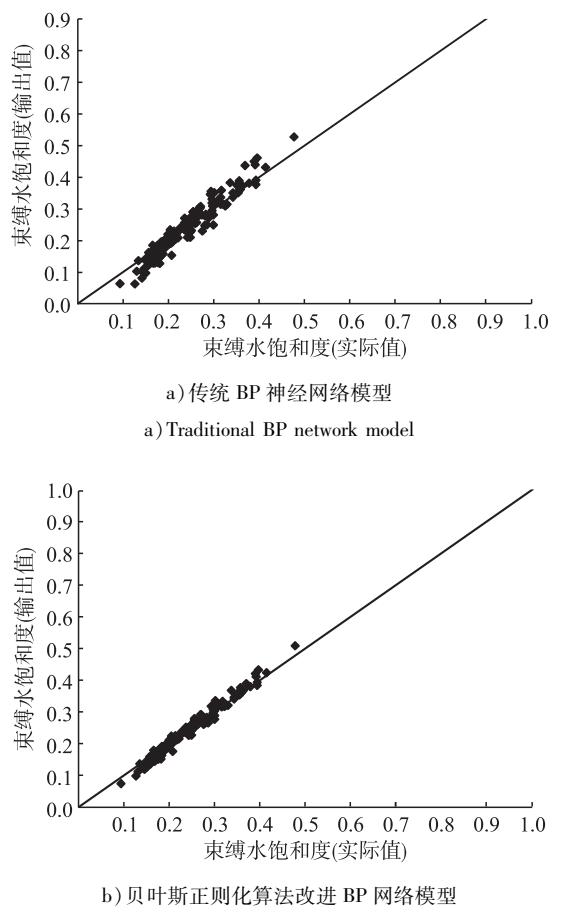


图3 束缚水饱和度输出值与实际值交汇图

Fig. 3 Intersecting plot between output value and actual value of irreducible water saturation

2.5 预测模型的检验

将未参与学习的14条相对渗透率曲线的实验数据带入训练好的相对渗透率预测模型进行测试,检验模型的预测效果,测试结果见图4。从束缚水饱和度的预测值和实际值的交汇图来看,预测值与实际值比较接近,样本点均落在绝对误差0.03两条直线区域内,说明两者的绝对误差小于0.03。进一步计算了各个预测样本的相对误差,见图5。由图5可以看出,14条相对渗透率曲线的束缚水饱和度预测相对误差均小于9%,能够满足相对渗透率曲线预测精度要求。

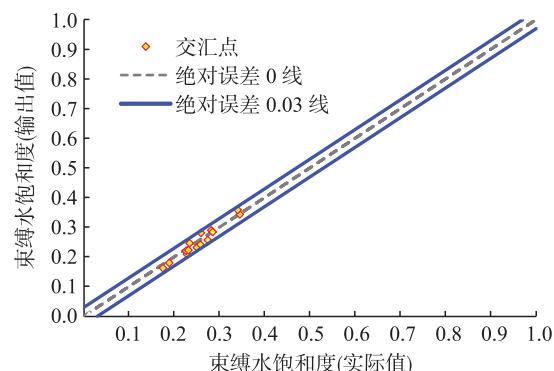


图4 束缚水饱和度预测值与实际值交汇图

Fig. 4 Intersecting plot between output value and actual value of irreducible water saturation

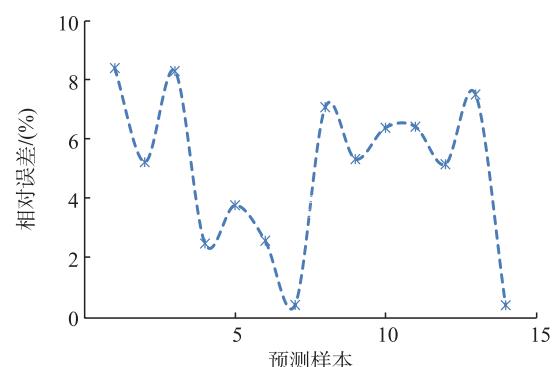


图5 模型相对误差图

Fig. 5 Model relative error

3 现场应用

BZ油藏属于河流相中轻质油藏,该油藏的主要含油层位为明下段Ⅱ油组,地层原油黏度为 $10\sim20\text{ mPa}\cdot\text{s}$,油藏平均孔隙度为30.5%。该油藏位于河道中间区域,与河道两侧的区域间物性差别较大,渗透率分布范围为 $200\times10^{-3}\sim3500\times10^{-3}\mu\text{m}^2$ 。

基于该油藏的渗透率和孔隙度分布关系,将该油藏的渗透率分为 500×10^{-3} 、 1000×10^{-3} 、 2000×10^{-3} 和 $3000\times10^{-3}\mu\text{m}^2$ 4个物性级别。利用相对渗透率曲线端点值预测模型,对4个物性级别下的相对渗透率曲线端点值进行预测,并基于预测的相对渗透率曲线端点值绘制了4个物性级别对应的相对渗透率曲线,预测结果见图6。从图6可以看出:若储层的物性较好,则预测的束缚水饱和度较低,两相渗流区较大;反之,预测的束缚水饱和度较高,两相渗流区较小。

基于4个物性级别预测的相对渗透率曲线,分别绘制了原油黏度为 $5\text{ mPa}\cdot\text{s}$ 和 $20\text{ mPa}\cdot\text{s}$ 两种情况下的含水率与驱油效率曲线,见图7。从图7可以看出,储层的物性影响油藏的含水上升规律,随着原油黏度的减小,物性对含水上升规律的影响程度逐步增强。由不同

物性下的相对渗透率曲线及含水上升规律可以看出,本模型预测的相对渗透率曲线及端点值能够反应实际油田的渗流特征,可用于不同物性储层的精细历史拟合和油田开发指标计算。

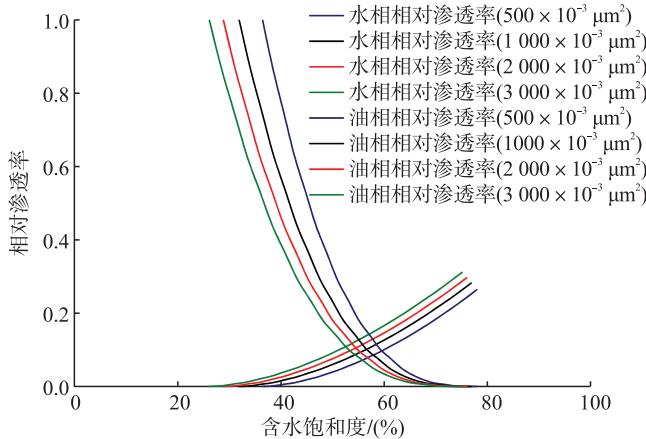


图 6 BZ 油藏不同物性级别对应的相对渗透率曲线

Fig. 6 Relative permeability curves corresponding to different physical property levels of BZ reservoir

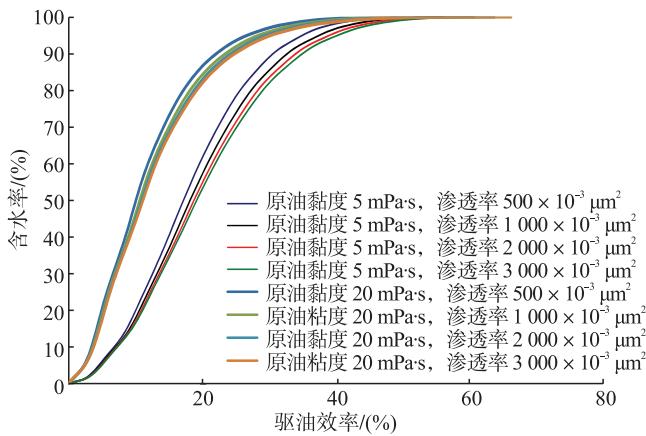


图 7 不同物性级别及不同原油黏度级别的含水率与驱油效率曲线

Fig. 7 Curves of watercut and displacement efficiency corresponding to different physical property levels and of different crude oil viscosity levels

4 结论

1) 针对储层物性和相对渗透率间高度复杂的非线性关系,建立了一种基于储层物性预测相对渗透率曲线端点值的BP神经网络模型,模型经贝叶斯正则化算法改进,更适合高维数等非线性问题,解决了相对渗透率曲线端点值难于准确预测的难题。

2) 149条相对渗透率实验数据的训练结果表明,建立的相对渗透率曲线端点值预测模型收敛性较好。14条未参与建模的相对渗透率曲线的实验数据的验证表明,建立的相对渗透率曲线端点值预测模型预测绝对误

差小于0.03,相对误差小于9%,能够满足油藏工程计算要求。

3) 基于建立的相对渗透率曲线端点值预测模型预测了BZ油藏不同物性级别的相对渗透率曲线端点值及相对渗透率曲线,该曲线能够反应实际油田的渗流特征。建立的BP神经网络模型,很好地表达了储层物性与相对渗透率曲线端点值间的内在联系与规律。

参考文献:

- [1] Damsleth E, Tjølsen C B, Omre H, et al. A Two-Stage Stochastic Model Applied to a North Sea Reservoir [J]. Journal of Petroleum Technology, 1992, 44 (4): 402–408.
- [2] Hewett T A, Behrens R A. Conditional Simulations of Reservoir Heterogeneity with Fractals [J]. SPE Formation Evaluation, 1990, 5 (3): 217–225.
- [3] 缪飞飞,刘小鸿,张宏友,等.相对渗透率曲线标准化方法评价[J].断块油气田,2013,20(6):759–762.
- Miao Feifei, Liu Xiaohong, Zhang Hongyou, et al. Evaluation on Standardized Methods of Original Relative Permeability Curves [J]. Fault-Block Oil & Gas Field, 2013, 20 (6): 759 – 762.
- [4] 张宏友.一种水驱油藏产油量递减率评价新方法[J].天然气与石油,2019,37(1):37–42.
- Zhang Hongyou. A New Method for Evaluating Oil Production Decline Rate in Water Drive Reservoirs [J]. Natural Gas and Oil, 2019, 37 (1): 37 – 42.
- [5] Hou Jian, Luo Fuquan, Wang Chuanfei, et al. Quantitative Prediction Model for the Water-Oil Relative Permeability Curve and Its Application in Reservoir Numerical Simulation. Part 1: Modeling [J]. Energy & Fuels, 2011, 25 (10): 4405–4413.
- [6] 张枫,王振升,程岩,等.油藏数值模拟中油水相对渗透率曲线处理方法[J].天然气地球科学,2010,21(5):859–862.
- Zhang Feng, Wang Zhensheng, Cheng Yan, et al. Processing Methods for Relative-permeability Curves in Reservoir Numerical Simulation [J]. Natural Gas Geoscience, 2010, 21 (5): 859 – 862.
- [7] 王曙光,赵国忠,余碧君.大庆油田油水相对渗透率统计规律及其应用[J].石油学报,2005,26(3):78–81.
- Wang Shuguang, Zhao Guozhong, Yu Bijun. Statistical Regularity of Oil-Water Relative Permeability in Daqing Oilfield [J]. Acta Petrolei Sinica, 2005, 26 (3): 78 – 81.
- [8] 汪雷,林亮,李晶晶,等.基于测井信息的煤储层渗透率BP神经网络预测方法[J].煤炭科学技术,2015,43 (7):122–126.
- Wang Lei, Lin Liang, Li Jingjing, et al. Method to Predict

- Permeability of Coal Reservoir with BP Neural Network Based on Logging Information [J]. Coal Science and Technology, 2015, 43 (7): 122–126.
- [9] 杨志浩,李治平.基于BP神经网络的底水油藏控水压裂缝段新方法[J].地质与勘探,2017,53(4):818–824.
Yang Zhihao, Li Zhiping. A New Method for Choice of Water-Control Fracturing Segments in Horizontal Wells Based on the BP Neural Network System [J]. Geology and Exploration, 2017, 53 (4): 818 –824.
- [10] 赵兴齐,陈践发,郭望,等. BP神经网络在西湖凹陷烃源岩评价中的应用[J].测井技术,2013,37(5):567–571.
Zhao Xingqi, Chen Jianfa, Guo Wang, et al. The Application of BP Neural Network to the Source Rocks Evaluation in Xihu Sag [J]. Well Logging Technology, 2013, 37 (5): 567 –571.
- [11] 李晶,栾爽,尤明慧.人工神经网络原理简介[J].现代教育科学,2010(增刊1):98–99.
Li Jing, Luan Shuang, You Minghui. Introduction to Artificial Neural Networks [J]. Modern Education Science, 2010 (Suppl 1): 98 –99.
- [12] 尹光志,李铭辉,李文璞,等.基于改进BP神经网络的煤体瓦斯渗透率预测模型[J].煤炭学报,2013,38(7):1179–1184.
Yin Guangzhi, Li Minghui, Li Wenpu, et al. Model of Coal Gas Permeability Prediction Based on Improved BP Neural Network [J]. Journal of China Coal Society, 2013, 38 (7): 1179 –1184.
- [13] 吴建生,金龙,农吉夫.遗传算法BP神经网络的预报研究和应用[J].数学的实践与认识,2005,35(1):83–88.
Wu Jiansheng, Jin Long, Nong Jifu. Forecast Research and Applying of BP Neural Network Based on Genetic Algorithms [J]. Mathematics in Practice and Theory, 2005 , 35 (1): 83 –88.
- [14] 俞启泰,罗洪,冯明生.我国油田河流相与三角洲相储层参数统计研究[J].大庆石油地质与开发,1999,18(1):28–31.
Yu Qitai, Luo Hong, Feng Mingsheng. Statistical Study on Reservoir of Fluvial and Delta Facies of Oil Filed in China [J]. Petroleum Geology & Oilfield Development in Daqing, 1999, 18 (1): 28 –31.
- [15] 肖冬峰,杨春节,宋执环.基于改进BP网络的高炉煤气发生量预测模型[J].浙江大学学报(工学版),2005,46 (11):2103–2108.
Xiao Dongfeng, Yang Chunjie, Song Zhihuan. The Forecasting Model of Blast Furnace Gas Output Based on Improved BP Network [J]. Journal of Zhejiang University (Engineering Science), 2005 , 46 (11): 2103 –2108.
- [16] 沈剑波,雷相东,李玉堂,等.基于BP神经网络的长白落叶松人工林林分平均高预测[J].南京林业大学学报(自然科学版),2018,42(2):147–154.
Shen Jianbo, Lei Xiangdong, Li Yutang, et al. Prediction Mean Height for Larix Olgensis Plantation Based on Bayesian-regularization BP Neural Network [J]. Journal of Nanjing Forestry University (Natural Science Edition), 2018, 42 (2): 147 –154.
- [17] 魏东,张明廉,蒋志坚,等.基于贝叶斯方法的神经网络非线性模型辨识[J].计算机工程与应用,2005,41(11):5–8.
Wei Dong, Zhang Minglian, Jiang Zhijian, et al. Neural Network Non-linear Modeling Based on Bayesian Methods [J]. Computer Engineering and Applications, 2005 , 41 (11): 5 –8.
- [18] 李红霞,许士国,范垂仁.基于贝叶斯正则化神经网络的径流长期预报[J].大连理工大学学报,2006,46(增刊):174–177.
Li Hongxia, Xu Shiguo, Fan Chuiren. Long-term Prediction of Runoff Based on Bayesian Regulation Neural Network [J]. Journal of Dalian University of Technology, 2006 , 46 (Suppl): 174 –177.
- [19] 喻胜华,邓娟.基于主成分分析和贝叶斯正则化BP神经网络的GDP预测[J].湖南大学学报(社会科学版),2011,25(6):42–45.
Yu Shenghua, Deng Juan. GDP Prediction Based on Principal Component Analysis and Bayesian Regularization BP Neural Network [J]. Journal of Hunan University (Social Sciences) , 2011, 25 (6): 42 –45.
- [20] Hagan M T, Menhaj M B. Training Feedforward Networks with the Marquardt Algorithm [J]. IEEE Transactions on Neural Networks, 1994, 5 (6): 989 –993.