

引用格式:赵军,张涛,何胜林,等.基于参数优选的储层渗透率深度置信网络模型预测初探[J].油气藏评价与开发,2021,11(4):577-585.  
ZHAO Jun, ZHANG Tao, HE Shenglin, et al. Prediction of reservoir permeability by deep belief network based on optimized parameters [J]. Petroleum Reservoir Evaluation and Development, 2021, 11(4): 577-585.  
DOI: 10.13809/j.cnki.cn32-1825/te.2021.04.014

## 基于参数优选的储层渗透率深度置信网络模型预测初探

赵军<sup>1</sup>,张涛<sup>1</sup>,何胜林<sup>2</sup>,张桓荣<sup>2</sup>,韩东<sup>1</sup>,汤翟<sup>2</sup>

(1.西南石油大学地球科学与技术学院,四川成都610500;  
2.中海石油(中国)有限公司湛江分公司地质研究院,广东湛江524057)

**摘要:**储层渗透率是储层产能的一个重要影响因素。针对常规测井渗透率模型在孔隙连通性差的低渗砂岩储层预测精度不高的问题,提出利用深度置信网络算法结合常规测井曲线预测储层渗透率的方法。该方法利用灰色关联法对测井曲线进行了关联度分析,依据相关度排序选取了特征敏感测井曲线,结合深度置信网络的有监督学习调优与对比散度算法进行数据挖掘,建立了渗透率的预测模型。该模型在以往BP神经网络的基础上改善了局部优化的问题,提高了网络模型的训练效率与预测精度。预测模型的平均相对误差为9.1%,相比常规渗透率模型,降低了20%左右。通过对实际资料的处理应用,结合误差分析,表明该方法能够有效地提高低渗透储层渗透率的预测精度。

**关键词:**渗透率;测井曲线;灰色关联分析法;深度置信网络;预测

中图分类号:TE31

文献标识码:A

### Prediction of reservoir permeability by deep belief network based on optimized parameters

ZHAO Jun<sup>1</sup>, ZHANG Tao<sup>1</sup>, HE Shenglin<sup>2</sup>, ZHANG Huanrong<sup>2</sup>, HAN Dong<sup>1</sup>, TANG Di<sup>2</sup>

(1. School of Resources and Environment, Southwest Petroleum University, Chengdu, Sichuan 610500, China;

2. Research Institute of Zhanjiang Company, CNOOC, Zhanjiang, Guangdong 524057, China)

**Abstract:** Reservoir permeability is an important factor affecting reservoir productivity. In order to solve the problem of poor prediction accuracy of conventional permeability logging models in low-permeability sandstone reservoirs with poor pore connectivity, a scheme combined with deep belief network (DBN) algorithm is proposed. First, the gray correlation method is used for the correlation analysis of logging curve, and according to the correlation ranking, the characteristic sensitive curves is sorted. Then, the optimization by supervised learning is combined with the contrastive divergence for the data mining to establish the prediction model of permeability. Compared to the previous BP neural network, DBN model improves the local optimization, and enhances the training efficiency and prediction accuracy. The average relative error of the prediction model is 9.1%, which is about 20% lower than that of the conventional permeability model. Based on the actual data processing applications and the error analysis, it is found that this method can effectively improve the prediction accuracy of permeability for the low permeability reservoirs.

**Keywords:** permeability, logging curve, grey relational analysis, deep belief network, prediction

储层渗透率是储层产能评价的一项重要指标,也是反映储层物性好坏的重要参数。通过对渗透率建模的优化处理,得到准确的渗透率参数,对储层品质评价具有十分重要的意义。已有研究表明,针对

渗透率的预测方法主体上分为两类:一类为基于岩心分析数据的统计建模,另一类是利用数据挖掘的学习建模方法。许多学者根据岩心分析数据提出了许多渗透率预测模型,包括分形模型<sup>[1]</sup>和根据压汞与

收稿日期:2020-10-29。

第一作者简介:赵军(1970—),男,博士,教授,主要从事岩石物理及其解释与评价工作。地址:四川省成都市新都区新都大道8号,邮政编码:610500。E-mail:zhaojun\_70@126.com

基金项目:中海石油(中国)有限公司湛江分公司科技项目“文昌9、10区低孔低渗储层测井精细评价及潜力分析”(CCL2019ZJFN0823)。

核磁共振等<sup>[2]</sup>一系列预测模型。其中利用测井资料估算渗透率,建立以实验数据为标准的经验统计模型是目前较为常用的方法<sup>[3-7]</sup>,但是基于岩心数据建模的方法不能完全适用于所有储层条件下的渗透率。因此,许多学者在此基础上采用各种智能算法来预测储层渗透率,以提高渗透率的预测精度。毛志勇等<sup>[8]</sup>、邵良彬等<sup>[9]</sup>、古勇等<sup>[10]</sup>、AKANDE等<sup>[11]</sup>根据粒子群算法的随机性选择,结合支持向量机简化回归问题,从而建立渗透率预测模型,提高了模型的泛化能力和预测精度,汪雷等<sup>[12]</sup>、张言辉等<sup>[13]</sup>、朱林奇等<sup>[14]</sup>、马晟翔等<sup>[15]</sup>利用BP神经网络的学习和泛化能力,结合不同的测井数据信息,挖掘测井数据与渗透率之间的关联,建立渗透率预测模型。BARAKA等<sup>[16]</sup>利用数据分组的处理方法能快速推导最优模型的特点,结合神经网络建立渗透率模型。这些浅层机器学习相较于参数建模效果更好,但是浅层机器学习结构单一,组合之后更是将各自的缺点叠加,如泛化能力受到制约,在渗透率预测中具有局限性。随着机器学习领域的研究深入,HINTON等<sup>[17]</sup>提出深度学习的方法,其网络结构具有多个隐含层,利用其隐含层的数据挖掘能力,解决非线性计算问题。其中王俊等<sup>[18]</sup>利用门控循环神经网络循环的重新判断、保留有效信息和提高收敛速度的特点,通过对测井曲线与孔隙度、渗透率及饱和度参数之间的相关性分析,建立测井数据与储层参数的关系模型。SUDAKOV等<sup>[19]</sup>根据数字岩心技术结合梯度回归算法与深度神经网络在3D图像中预测渗透率,降低了误差率并减少了预测时间。TIAN等<sup>[20]</sup>根据卷积神经网络的特征提取与模式分类同时在训练中产生的特点,结合数字岩心的三维建模数据,对多孔介质的渗

透率进行预测。由于神经网络算法在计算过程中梯度弥散问题没有解决,容易造成局部极值。数字岩心需要进行岩心三维图像建模,在构建图像模型时,需要对实际岩心进行扫描成像,结合卷积神经网络算法进一步对图形进行学习建模,增加了拟合建模的步骤,降低了效率,而卷积神经网络在池化时,容易造成数据的丢失,忽略整体与部分的联系。因此,基于常规测井,优选对渗透率敏感的测井参数,建立深度学习模型中的深度置信网络预测储层渗透率,通过与实验测试数据的对比分析,提高了低渗储层渗透率参数的预测精度。

## 1 区域概况

研究区为珠江口盆地珠三坳陷下二级构造单元中的文昌A凹陷,北部接阳江低凸起,南部、东南部以珠三南断裂为界,与神狐隆起相邻,西部以珠三2号断裂为界,与琼海低凸起、文昌B凹陷相连。

根据珠海组三段数据的孔渗分析,得到各段数据孔渗关系分布范围较广,同样,根据珠海组岩性分布得到的结果也是一致的(图1、图2)。由于研究区岩性变化频繁,砂体颗粒变化较大,不同岩相的孔渗关系也不尽相同,而不同沉积相的孔渗关系也存在区别,常规的孔渗模型不能较好拟合。根据BP算法回归处理的误差相较于常规模型能得到降低,其算法的拟合程度不高,但是其解释误差不能较好地符合解释要求。基于常规模型与基本算法的拟合效果较差,采用深度学习的算法对测井数据进行深度挖掘。依据深度置信(Deep Belief Network,简称DBN)能处理回归问题但需要大量数据进行模拟,因此,使




图1 分段孔隙度—渗透率交会图

Fig. 1 Cross plot of segmented porosity and permeability




图2 岩性孔隙度—渗透率交会图

Fig. 2 Cross plot of lithology porosity and permeability

用全部数据进行建模。

## 2 模型原理及影响因素分析

### 2.1 输入参数优选

由于DBN需要进行深度挖掘,故输入数据的选取尤为重要,不合适的数据变量将导致局部收敛。故采取灰色关联分析法,它是一种动态分析衡量各因素相关程度的方法。根据各因素的样本数据用灰色关联分析得到与之对应的关联度,依据关联度来描述各因素间关系的强弱、大小和次序。通过对比样本数据,若两者之间的变化趋势相似,则说明两因素之间的关联度大,若趋势相反,则说明关联度低。此方法的优点在于步骤简单,减少了信息不对称的损失,对应的计算模型也不需要具有分布规律,只需通过比较关联度的大小,判断其影响程度。

灰色关联分析步骤:

1) 根据预测需要,基于测井数据建立参考数列与比较数列。其中比较数列一般形式为:

$$X'_i = [x'_i(1), x'_i(2), \dots, x'_i(m)]^T, i = 0, 1, \dots, n \quad (1)$$

式中:  $X'_i$  表示比较数列,  $m$  表示每列比较数列的维度,  $i$  表示第  $i$  列数据,  $T$  表示为数据列的转置。

参考数列为:

$$X'_0 = [x'_0(1), x'_0(2), \dots, x'_0(m)] \quad (2)$$

式中:  $X'_0$  表示参考数列,默认下标为0的比较数列为参考数列。

2) 对已选取好的比较数列与参考数列做无量纲化处理,根据数据之间的联系进行初值无量纲化处理,即:

$$x_i(k) = \frac{x'_i(k)}{x'_i(1)} \quad (3)$$

式中:  $x_i(k)$  表示无量纲化后的比较数列。

3) 计算两个数列之间的关联系数

$$\zeta_i(k) = \frac{\min_k \min_i |x_0(k) - x_i(k)| + \rho \max_k \max_i |x_0(k) - x_i(k)|}{|x_0(k) - x_i(k)| + \rho \max_k \max_i |x_0(k) - x_i(k)|} \quad (4)$$

$k = 1, 2, \dots, m$

式中:  $\zeta_i(k)$  表示两个数列之间的关联系数,  $\rho$  为分辨系数,  $0 < \rho < 1$ , 一般  $\rho$  取 0.5。

4) 计算关联序,根据计算的关联系数,计算比较数列相较于参考数列对应项关联系数的均值,得

到关联序:

$$r_{0i} = \frac{1}{m} \sum_{k=1}^m \zeta_i(k) \quad (5)$$

式中:  $r_{0i}$  表示两个数列之间的关联序。

若每个比较数据在综合评价中所起的作用不同,则对关联系数求加权平均值,即:

$$r'_{0i} = \frac{1}{m} \sum_{k=1}^m W_k \zeta_i(k) \quad (6)$$

式中:  $r'_{0i}$  表示每个比较数列在综合评价中所起作用不同时求取的关联序,  $W_k$  为第  $k$  个指标权重。

5) 依据观察结果的关联序,得出分析结果

通过对研究区的测井样本数据与岩心分析渗透率数据进行灰色关联分析,将对应段声波时差、密度、自然伽马等测井曲线和岩心分析渗透率数据作矩阵化处理,选取一行基数列,进行无量纲化处理,同时将测井数据与渗透率数据根据关联系数计算公式得到关联系数,在关联系数下进一步计算关联度,最后将关联度排序,优选测井曲线,得到见表1所示的各测井曲线对渗透率的关联度,从中优选出对渗透率关联度高的测井曲线。据表分析,选择关联度排序前6的测井曲线,分别为声波时差、补偿中子、密度、深侧向、浅侧向、自然伽马。

### 2.2 深度置信方法原理

深度学习是一种具有多个隐层神经网络的总称,广泛运用在自动驾驶汽车、艺术创作、语言翻译、医学研究等。深度学习是机器学习的一种,是最终为实现人工智能的一种过程,随着研究的深入,深度学习的模型不断在改善,深度学习在处理回归问题上有着较高准确性<sup>[21-24]</sup>。DBN是由若干个受限玻尔兹曼机堆叠,再利用一个反向传播的神经网络进行

表1 输入参数的灰色关联度优选分析  
Table 1 Grey correlation analysis with selected parameters

测井类别	关联度	排序
声波时差(AC)	0.874 7	2
密度(DEN)	0.892 5	1
自然伽马(GR)	0.723 0	3
补偿中子(CNL)	0.667 9	4
井径(CAL)	0.507 7	8
自然电位(SP)	0.557 7	7
浅侧向(RILM)	0.656 4	5
深侧向(RILD)	0.648 6	6

调节的神经网络。玻尔兹曼机(Boltzmann Machine, 简称BM)是一种层内、层间全连接的神经网络,也是基于统计概率能量函数的一种建模方法,具有很强的学习监督能力。BM是一种反馈型神经网络,由可见层与隐层构成(图3),BM由二值神经元构成,网络中的神经元只有两种状态即激活态与未激活态。受限玻尔兹曼机(Restricted Boltzmann Machine, 简称RBM)是基于BM的一种革新,跟BM一样也是一个两层神经网络,同样也是由可见层与隐层构成(图4),其中RBM与BM的不同是RBM层间全连接,层内无连接。

RBM模型是基于能量的模型,对于RBM全局最优的网络初始权值计算,可用能量函数求解,表示为:

$$E(v, h | \theta) = - \sum_{i=1}^n \sum_{j=1}^m v_j w_{ij} h_i - \sum_{j=1}^m a_j v_j - \sum_{i=1}^n b_i h_i \quad (7)$$

式中:  $w_{ij} = \{w_{ij}, a_j, b_i\}$ ;  $m$  表示可见层神经元个数;  $h_i$  表示可见神经元, 下标  $j$  代表第  $j$  个神经元;  $n$  表示隐层神经元个数;  $v_j$  表示隐层神经元, 下标  $i$  表示第  $i$  个隐层神经元;  $w_{ij}$  为可见层神经元  $j$  到隐层神经元  $i$  的连接权重;  $a_j$  为可见层第  $j$  个神经元的偏置;  $b_i$  为隐层第  $i$  个神经元的偏置。

由式(1)中能量函数的定义得到可见层  $v$  和隐层  $h$  的联合概率分布为:

$$P(\vec{v}, \vec{h} | \theta) = \frac{e^{-E(\vec{v}, \vec{h} | \theta)}}{Z(\theta)} \quad (8)$$

式中:  $P(\vec{v}, \vec{h} | \theta)$  表示可见层和隐层的联合概率分布,  $Z(\theta)$  是归一化因子, 表示为:




图3 BM模型  
Fig. 3 BM model




图4 RBM模型  
Fig. 4 RBM model

$$Z(\theta) = \sum_{(i, h)} e^{-E(i, h | \theta)} \quad (9)$$

由式(8)求解输入样本的概率分布, 即  $P$  的边缘分布, 也是  $P$  的似然函数, 表示为:

$$P(\vec{v} | \theta) = \frac{1}{Z(\theta)} \sum_h e^{-E(\vec{v}, h | \theta)} \quad (10)$$

训练RBM, 就得调整  $\theta$ , 根据对数函数的性质, 通过对数似然函数, 而后最大化对数似然函数来求取参数  $\theta^*$ :

$$\theta^* = \arg \max_{\theta} L(\theta) = \arg \max_{\theta} \sum_{k=1}^K \log P(\vec{v}^{(k)} | \theta) \quad (11)$$

式中:  $\theta^*$  表示需要求解的参数,  $L(\theta)$  表示似然函数,  $K$  表示训练样本总数。

为了求解  $\theta^*$ , 利用随机梯度下降来最大化  $L(\theta)$ , 则需对  $L(\theta)$  求取各项参数的偏导数, 从而  $L(\theta)$  对权重矩阵  $W_{ij}$  求导可得:

$$\frac{\partial \log L(\theta)}{\partial w_{ij}} = - \sum_h P(\vec{h} | \vec{v}) \frac{\partial E(\vec{v}, \vec{h})}{\partial w_{ij}} + \sum_{(v, h)} P(\vec{v}, \vec{h}) \frac{\partial E(\vec{v}, \vec{h})}{\partial w_{ij}} \quad (12)$$

化简可得:

$$\frac{\partial \log L(\theta)}{\partial w_{ij}} = -P(H_i = 1 | \vec{v}) v_j + \sum_v P(\vec{v}) P(H_i = 1 | \vec{v}) v_j \quad (13)$$

同理对可见层偏置  $a_j$ 、隐层偏置  $b_i$  的导数为:

$$\frac{\partial \log L(\theta)}{\partial a_j} = v_j - \sum_v P(\vec{v}) v_j \quad (14)$$

$$\frac{\partial \log L(\theta)}{\partial b_i} = P(H_i = 1 | \vec{v}) - \sum_v P(\vec{v}) P(H_i = 1 | \vec{v}) \quad (15)$$

当训练样本的可见层节点较多时, HINTON 提出了通过对比散度算法(Contrastive Divergence, CD-k)来提高重构RBM的可见节点概率分布训练速度, 一般取  $k=1$ , 即只进行一步 Gibbs 采样, 就能取得很好的学习效果。

有监督调优学习时, 一般先通过前向传播算法, 从最后一个RBM输出信息输入BP神经网络得到输出值, 然后再利用反向传播算法来调整网络的权重值和偏置值, 得到网络的全局最优参数, 定义前向传播算法输出值为:

$$\hat{X} = f(w^{(m)} h^{(m-1)} + b^{(m)}) \quad (16)$$

式中:  $\hat{X}$  表示前向传播算法的输出值,  $w^{(m)}$  表示第  $m$  层的网络连接权重值;  $h^{(m-1)}$  表示第  $m-1$  层可视层的偏置;  $b^{(m)}$  表示第  $m$  层隐层的偏置。

基于最小均方误差准则的反向误差传播算法来

调整网络的权重值和偏置值,成本函数表示为:

$$L = \frac{1}{N} \sum_{i=1}^N (\hat{X}_i(w^{(m)}, h^{(m-1)}) - X_i)^2 \quad (17)$$

式中: $L$ 表示DBN模型的平均平方误差; $N$ 表示样本数量; $\hat{X}_i$ 表示输出层输出; $X_i$ 表示样本标签。

再根据梯度下降速度最快的原理,对代价函数进行梯度求导,得到更新后网络的权重和偏置参数:

$$(w^{(m)}, b^{(m)}) \leftarrow (w^{(m)}, b^{(m)}) - \lambda \frac{\partial L}{\partial (w^{(m)}, b^{(m)})} \quad (18)$$

式中: $\lambda$ 表示学习效率。

根据DBN模型分析得到DBN的训练结构,DBN是由多个RBM堆叠与一个BP神经网络构成。输入样本数据后通过逐层无监督训练RBM,完成RBM的自发向上的训练,将最后的特征值作为BP神经网络的输入,通过BP神经网络的反向传播,逐层微调RBM,如此反复,达到拟合数据最佳范围值,实现整个网络的微调(图5)。

### 2.3 影响因素分析

DBN预测框架的模型中,预测框架的模型参数对预测结果有着直接影响。基于上述原理,以低渗透率实验分析值为基础,进一步依据DBN智能算法建立渗透率预测模型。通过对框架中主要的影响因素进行实验分析,分析影响因素与DBN预测性能之间的关系,用于后续模型参数的选取。

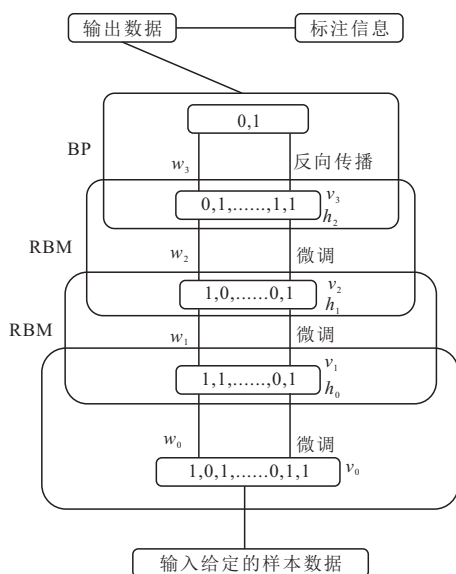


图5 DBN训练结构

Fig. 5 DBN training structure

DBN的设定与BP神经网络基本相似,其结构相差无几,其中网络层数、输入节点数、隐含层层数、隐含层节点数、输出层节点数及传输函数与训练方法及训练参数的设置,需要对DBN模型根据初始状态设置相关参数。针对其中主要的因素进行实验分析,根据反映预测值与实际值误差的三类指标均方误差(mean square error,简称MSE)、平均绝对误差(mean absolute error,简称MAE)以及平均相对误差(mean relative error,简称MRE),判断DBN预测渗透率效果。

#### 2.3.1 输入节点数

输入节点数在训练与预测中,代表着使用有效历史数据的个数,数据越多,模型获得的有用信息就越多,并在预测中能提高预测精度。根据测井曲线作为输入数据,则曲线数据的个数为输入节点的个数。根据初始模型,设定参数,根据经验设定初始网络节点数为6,设定初始网络层数为3,隐层节点数为10,初始动量为0.9,学习率为0.01,最大预训练次数100,反向微调次数与预训练次数一致,也设为100次,改变输入节点数的大小:分别设置为1,2,3,4,5,6,7,8,9,10,11,12。通过预设输入节点数,进行预训练,选择误差范围较小的模型,在有多个误差范围相似时,通过该输入节点数对比真实数据与预测数据之间的差值精度(图6),得到输入节点为6时,拟合指标值最佳。

#### 2.3.2 网络层数

网络深度代表深度学习的学习能力,随着网络深度的加深,挖掘数据的信息越多,据已有的理论证明在网络层次足够深的情况下,能拟合任何函数,表




图6 输入节点数评价指标

Fig. 6 Evaluation index of input node number

明网络层数对特征提取和数据拟合都有直接影响。网络层数与RBM的层数直接相关,通过对比不同RBM层数情况下各项误差,得到误差范围较小的RBM层数,反映的就是网络层数的误差(图7)。通过图7评价结果对比得到该项预测评价选择4层RBM网络结构。

### 2.3.3 隐层节点数与隐层层数

隐层节点与隐层层数一样,对于预测性能有较为明显的影响,根据对网络层数的实验分析得到层数为4,则隐层层数与网络层数相一致,根据已确定的隐层层数和输入节点数对隐层节点数进行实验分析,通过对比不同隐层节点数的预测评价指标,得到图8、图9所示的评价指标,选取最优节点数。

根据(图8、图9)分析得到在隐层节点数为20时,隐层层数为4时,各项误差都处于相对较低的范围。

## 3 应用效果分析

实验岩心数据取自文昌A凹陷的珠海组,根据岩心孔渗分析资料研究区珠海组储层物性随埋深增

大而变差,整体以低孔、低渗为主。岩心样品数据分别来自WC1井的珠海组全段235个样本数据,其中珠海一段44个样本数据、珠海二段72个样本数据、珠海三段119个样本数据,WC2井的珠海二段73个岩心样本数据,WC3井的珠海二段106个岩心样本数据,WC4井的珠海二段17个岩心样本数据以及WC5井的珠海一段83个岩心样本数据和珠海三段75个岩心样本数据,共计592个岩心样本数据。根据选取的岩心渗透率样本数据和对应深度段筛选的声波时差、补偿中子、密度、深侧向、浅侧向、自然伽马测井曲线进行归一化处理,将渗透率值作为输出数据,测井曲线数据作为输入数据按照4:1的比例随机分为训练集与测试集。利用Matlab进行编程,按照图10的流程进行学习建模。根据DBN模型主控因素分析,设置以输入节点数为10,网络层数为4,隐




图9 隐层层数评价指标

Fig. 9 Evaluation index of hidden layers number




图7 RBM层数评价指标

Fig. 7 Evaluation index of RBM layer number




图8 隐层节点数评价指标

Fig. 8 Evaluation index of node number for hidden layer

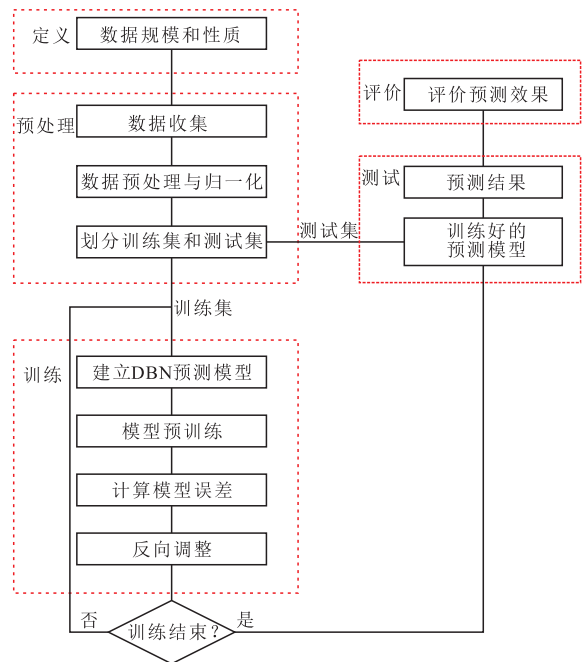


图10 DBN流程

Fig. 10 DBN flow chart

层输入节点数为20,RBM隐层层数与BP神经网络隐层层数一致,设为4层,其中RBM的动量为0.9,学习率为0.01,初始迭代次数为100次,同样BP神经网络迭代为100次的DBN模型。

通过不断调节迭代次数和调整学习率与其他相关参数,对比评价指标,反复迭代循环,得到预测模型。预测结果与实际数据吻合度很高,与岩心分析渗透率的平均相对误差为9.1%(图11、图12)。

根据所建的预测模型,对研究区的渗透率进行了预测与对比分析,分别采用DBN模型、常规岩心孔渗模型与BP神经网络模型对研究区5口井的渗透率进行了预测。图13、图14分别为WC1井3660~3680m井段和WC3井3990~4010m井段的预测结果。图中最右道为3种预测模型计算的渗透率曲线值,两口井的对比结果表明,常规岩心孔渗模型预算数据与岩心实验分析数据偏离较大,吻合度最差;DBN模型计算的曲线与岩心实验数据的吻合度最好,误差最

小;尽管BP神经网络模型预测的结果与DBN模型的结果趋势较一致,但与岩心实验数据的对比误差仍然高于DBN模型。

分别统计了研究区5口井的预测结果,并与岩心分析渗透率进行了对比分析(表2),误差分析表明,DBN模型的平均预测误差为9.12%,远远优于其他两个模型的预测精度,且相较于常规孔渗方法误差降低了20%左右,相较于BP神经网络降低了10%,说明DBN模型对研究区渗透率参数具有较强的预测能力,能够明显改善本地区渗透率参数的预测精度。

## 4 结论

1) 通过对比常规孔隙度渗透率模型与BP神经网络模型,低渗储层在神经网络算法的建模下能提高预测精度,而后通过对比研究发现,基于深度学习的神经网络能够明显地提高地渗储层渗透率的预测精度。




图11 DBN渗透率预测结果  
Fig. 11 DBN permeability prediction results

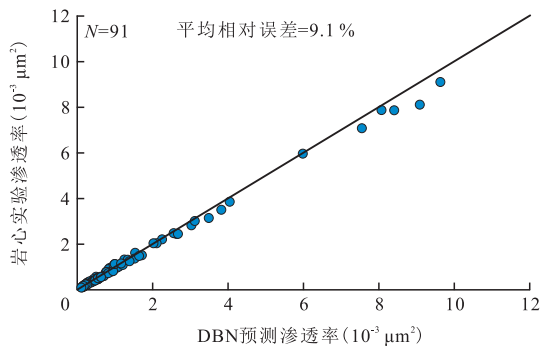


图12 DBN渗透率预测精度  
Fig. 12 DBN permeability prediction accuracy




图13 WC1井的渗透率预测曲线对比  
Fig. 13 Comparison of prediction curves of Well-WC1




图14 WC3井的渗透率预测曲线对比

Fig. 14 Comparison of prediction curves of Well-WC3

表2 研究区5口三种模型渗透率预测的  
平均相对误差统计Table 2 Statistic of average relative error of  
permeability prediction of three models for five wells in  
study area

井号	深度段 (m)	常规孔隙度 预测模型 (%)	BP神经 网络模型 (%)	深度置信 网络模型 (%)
WC1井	3 663.3 ~ 3 678.9	32.70	22.30	10.60
WC2井	3 849.7 ~ 3 867.7	28.40	18.40	7.20
WC3井	3 987.8 ~ 4 006.1	30.30	19.20	8.14
WC4井	3 851 ~ 3 855.4	28.10	19.90	9.25
WC5井	3 753.6 ~ 3 771.6	31.20	20.10	10.40
平均值		30.14	19.98	9.12

2) 针对DBN预测模型,用灰色关联分析的方法得到与渗透率相关性大的测井曲线参数,将这相关性高的测井曲线数据作为输入数据用来提高研究区渗透率的相关性。

3) RBM进行无监督训练时,应当注意隐层层数与隐层节点数的选取,两者之间各有一个最佳拟合

数据点,需要对RBM进行不断微调,达到RBM训练的最佳模型参数目的。

4) DBN模型可准确预测本地区低孔渗储层渗透率,改进了BP神经网络训练效率问题,提高了预测精度,能为储层综合评价提供可靠渗透率参数。

5) 基于DBN模型来进行渗透率的预测,能够较好地提高参数的预测精度,为该地区储层的精细评价提供了解释基础。

#### 参考文献

- 赵久玉,王付勇,杨坤.致密砂岩分形渗透率模型构建及关键分形参数计算方法[J].特种油气藏,2020,27(4):73-78.  
ZHAO Jiuyu, WANG Fuyong, YANG Kun. Tight sandstone fractal permeability model and key fractal parameter calculation [J]. Special Oil & Gas Reservoirs, 2020, 27(4): 73-78.
- 程辉,王付勇,宰芸,等.基于高压压汞和核磁共振的致密砂岩渗透率预测[J].岩性油气藏,2020,32(3):122-132.  
CHENG Hui, WANG Fuyong, ZAI Yun, et al. Prediction of tight sandstone permeability based on high-pressure mercury intrusion (HPMI) and nuclear magnetic resonance (NMR) [J]. Lithologic Reservoirs, 2020, 32(3): 122-132.
- 赵天逸,宁正福,陈刚,等.致密砂岩储集层渗透率预测修正方法[J].新疆石油地质,2020,41(3):337-343.  
ZHAO Tianyi, NING Zhengfu, CHEN Gang, et al. Modified methods of permeability prediction for tight sandstone reservoirs [J]. Xinjiang Petroleum Geology, 2020, 41(3): 337-343.
- 张恒荣,何胜林,吴进波,等.一种基于Kozeny-Carmen方程改进的渗透率预测新方法[J].吉林大学学报(地球科学版),2017,47(3):899-906.  
ZHANG Hengrong, HE Shenglin, WU Jinbo, et al. A new method for predicting permeability based on modified Kozeny-Carmen [J]. Journal of Jilin University (Earth Science Edition), 2017, 47(3): 899-906.
- 于华,令狐松,王谦,等.一种砂岩储层渗透率计算新方法[J].西南石油大学学报(自然科学版),2020,42(2):125-132.  
YU Hua, LINGHU Song, WANG Qian, et al. A new method for calculating permeability of sandstone reservoir [J]. Journal of Southwest Petroleum University (Science & Technology Edition), 2020, 42(2): 125-132.
- 张冲.基于海上砂砾岩低渗透率成因分析及测井评价[J].测井技术,2019,43(5):524-530.  
ZHANG Chong. Log evaluation of offshore low permeability conglomerate based on permeability genesis analysis [J]. Well Logging Technology, 2019, 43(5): 524-530.
- 李奇,高树生,刘华勋,等.岩心渗透率的计算方法与适用范围[J].天然气工业,2015,35(3):68-73.  
LI Qi, GAO Shusheng, LIU Huaxun, et al. Core permeability calculation methods and application scopes [J]. Natural Gas Industry, 2015, 35(3): 68-73.
- 毛志勇,黄春娟,路世昌,等.基于APSO-WLS-SVM的含瓦斯煤渗透率预测模型[J].煤田地质与勘探,2019,47(2):66-71.

- MAO Zhiyong, HUANG Chunjuan, LU Shichang, et al. Model of gas-bearing coal permeability prediction based on APSO-WLS-SVM[J]. *Coal Geology & Exploration*, 2019, 47(2): 66-71.
- [9] 邵良杉,马寒.媒体瓦斯渗透率的PSO-LSSVM预测模型[J].*煤田地质与勘探*,2015,43(4):23-26.
- SHAO Liangshan, MA Han. Model of coal gas permeability prediction based on PSO-LSSVM[J]. *Coal Geology & Exploration*, 2015, 43(4): 23-26.
- [10] 古勇.基于改进支持向量机的煤体瓦斯渗透率预测[J].*数学的实践与认识*,2016,46(20):149-155.
- GU Yong. Prediction of coal gas permeability based on PSOSVM[J]. *Mathematics in Practice and Theory*, 2016, 46(20): 149-155.
- [11] KABIRU O A, TAOREED O O, SUNDAY O O, et al. A hybrid particle swarm optimization and support vector regression model for modelling permeability prediction of hydrocarbon reservoir[J]. *Journal of Petroleum Science and Engineering*, 2017, 150(2): 43-53.
- [12] 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.
- [13] 张言辉.基于物性预测相对渗透率的改进神经网络方法[J].*天然气与石油*,2020,38(3):44-49.
- ZHANG Yanhui. Improved neural network method for predicting relative permeability based on physical properties[J]. *Natural Gas and Oil*, 2020, 38(3): 44-49.
- [14] 朱林奇,张冲,何小菊,等.基于改进BPNN与T<sub>2</sub>全谱的致密砂岩储层渗透率预测[J].*石油物探*,2017,56(5):727-734.
- ZHU Linqi, ZHANG Chong, HE Xiaoju, et al. Permeability prediction of tight sandstone reservoir based on improved BPNN and T<sub>2</sub> full-spectrum[J]. *Geophysical Prospecting for Petroleum*, 2017, 56(5): 727-734.
- [15] 马晟翔,李希建.基于因子分析与BP神经网络的煤体瓦斯渗透率预测[J].*煤矿开采*,2018,23(6):108-111.
- MA Shengxiang, LI Xijian. Forecast of coal body gas permeability based on factor analysis and BP neural net[J]. *Coal Mining Technology*, 2018, 23(6): 108-111.
- [16] BARAKA M N, CHUANNO S, SOLOMON A O, et al. Prediction of permeability using group method of data handling (GMDH) neural network from well log data[J]. *Energies*, 2020, 13(6): 1-18.
- [17] HINTON G E, SALAKHUTDINOV R R. Reducing the dimensionality of data with neural networks[J]. *Science*, 2006, 313(5786): 504-507.
- [18] 王俊,曹俊兴,尤加春,等.基于门控循环单元神经网络的储层孔渗饱参数预测[J].*石油物探*,2020,59(4):616-627.
- WANG Jun, CAO Junxing, YOU Jiachun, et al. Prediction of reservoir porosity permeability and saturation based on a gated recurrent unit neural network[J]. *Geophysical Prospecting for Petroleum*, 2020, 59(4): 616-627.
- [19] OLEG S, EVGENY B, DMITRY K. Driving digital rock towards machine learning: predicting permeability with gradient boosting and deep neural networks[J]. *Computers and Geosciences*, 2019, 127(6): 91-98.
- [20] JIAN W T, CHONG C Q, YING F S, et al. Surrogate permeability modelling of low permeable rocks using convolutional neural networks[J]. *Computer Methods in Applied Mechanics and Engineering*, 2020, 366(13): 103-113.
- [21] 王小艺,李柳生,孔建磊,等.基于深度置信网络-多类模糊支持向量机的粮食供应链危害物风险预警[J].*食品科学*,2020,41(19):17-24.
- WANG Xiaoyi, LI Liusheng, KONG Jianlei, et al. Risk pre-warming of hazardous materials in cereal supply chain based on deep belief network-multiclass fuzzy support vector machine (DBN-MFSVM)[J]. *Food Science*, 2020, 41(19): 17-24.
- [22] 孟智慧.基于深度置信网络的互联网流量预测方法[J].*电信工程技术与标准化*,2020,33(10):42-47.
- MENG Zhihui. Internet traffic prediction method based on deep belief network[J]. *Telecom Engineering Technics and Standardization*, 2020, 33(10): 42-47.
- [23] 许若冰,王璇,赵倩宇,等.基于卷积神经网络和深度置信网络的多类型能源需求预测方法[J].*供用电*,2020,37(10):65-70.
- XU Ruobing, WANG Xuan, ZHAO Qianyu, et al. A multi-energy demand prediction method based on convolutional neural network and deep belief network[J]. *Distribution & Utilization*, 2020, 37(10): 65-70.
- [24] 叶绍泽,曹俊兴,吴施楷,等.基于深度置信网络的总有机碳含量预测方法[J].*地球物理学进展*,2018,33(6):2490-2497.
- YE Shaoze, CAO Junxing, WU Shikai, et al. Prediction method of total organic carbon content based on deep belief nets[J]. *Progress in Geophysics*, 2018, 33(6): 2490-2497.

(编辑 尹淑容)