

◀固井与泥浆▶

# 改进的神经网络模型在储层敏感性预测中的应用

何顺利<sup>1</sup> 田 冷<sup>1</sup> 顾岱鸿<sup>1,2</sup>

(1. 中国石油大学(北京)石油天然气工程学院, 北京昌平 102249; 2. 中国地质大学(北京), 北京 100083)

**摘要:** 在改进的神经网络训练算法的基础上, 提出了利用神经网络快速预测储层潜在敏感性(水敏性、速敏性、盐敏性、酸敏性和碱敏性, 简称“五敏”)的方法。在对储层的“五敏”伤害预测中, 采用 Kohonen 自组织网络和 BP 网络建立了敏感性伤害的预测模型, 提高了预测的精度。分析表明, 该方法受人为因素干扰小、所需参数少、适用范围广(特别适用于探井), 能定量地反映出储层潜在敏感性程度, 从而为制定保护油气层技术措施提供较可靠的依据。

**关键词:** 防止地层损害; 神经网络; 数学模型; 预测; 实例; 长庆油田

中图分类号: TE258 文献标识码: A 文章编号: 1001-0890 (2006) 01-0028-04

长庆油田储层粘土矿物含量高, 孔隙度、渗透率较低, 含有铁方解石、黄铁矿等敏感性矿物, 很容易引起储层敏感性伤害。室内试验结果也表明, 该油田储层存在不同程度的水敏、酸敏等伤害形式。敏感性伤害的影响因素比较多, 且影响因素之间的作用复杂, 而神经网络通过有指导学习, 可以逼近任何函数, 表达非常复杂的函数关系, 非常适合处理敏感性伤害的预测问题。笔者在改进的神经网络训练算法的基础上, 提出了利用神经网络快速预测储层潜在敏感性的方法。

## 1 神经网络模型

### 1.1 B-P 神经网络

B-P 网络即误差反向传播(back-propagation)神经网络, 属于监督学习神经网络。该网络是多层网络, 有输入层、输出层以及隐层, 层与层间采用全互连方式(见图 1), 但同一层的节点之间不存在相互连接。对于每一层间的连接权值都可以通过学习来调节, 基本处理单元(输入层单元除外)为非线性输入/输出关系(一般选用 S 型作用函数, 如  $f(x) = \frac{1}{1+e^{-x}}$ ), 其中处理单元的输入、输出值可连续变化。

设 B-P 网络每层有  $N$  个处理单元, 其作用函数为  $f(x) = \frac{1}{1+e^{-x}}$ , 训练集有  $M$  个样本模式对  $(X_k, Y_k)$ 。对于  $p$  个训练样本 ( $p=1, 2, \dots, M$ ), 单元  $j$  的输入总和(即激活函数)记为  $a_{pj}$ , 输出记为  $O_{pj}$ , 阈值为  $\theta_j$ , 则

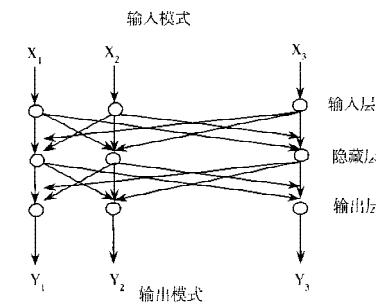


图 1 三层 B-P 网络

$$a_{pj} = \sum_{i=0}^N W_{ji} x_{pi} - \theta_j \quad (1)$$

$$O_{pj} = f(a_{pj}) = \frac{1}{1+e^{-a_{pj}}} \quad (2)$$

如果任意设置网络的初始权值, 则对每个输入模式  $p$ , 网络的实际输出与期望输出一般总有误差, 现定义网络的误差:

$$E = \sum_p E_p \quad (3)$$

$$E_p = \frac{1}{2} \sum_j (d_{pj} - O_{pj})^2 \quad (4)$$

式中,  $d_{pj}$  表示第  $p$  个输入模式输出单元  $j$  的期望输出。

$\delta$  学习规则的实质是利用梯度最陡下降法, 使权值沿误差函数的负梯度方向改变。若权值  $W_{ji}$  的变化量记为  $\Delta_p W_{ji}$ , 则

收稿日期: 2005-04-20; 改回日期: 2005-08-17

作者简介: 何顺利(1952—), 男, 江苏徐州人, 1994 年获法国傅利叶大学渗流力学专业博士学位, 教授。

联系电话: (010) 89734267

$$\Delta_p W_{ji} \propto -\frac{\partial E_p}{\partial W_{ji}} \quad (5)$$

由于

$$\frac{\partial E_p}{\partial W_{ji}} = \frac{\partial E_p}{\partial a_{pj}} \frac{\partial a_{pj}}{\partial W_{ji}} = \frac{\partial E_p}{\partial a_{ji}} O_{pi} = -\delta_{pj} O_{pi} \quad (6)$$

令  $\delta_{pj} = -\frac{\partial E_p}{\partial a_{pj}}$ , 则

$$\Delta_p W_{ji} = \eta \delta_{pj} O_{pi}, \quad \eta > 0 \quad (7)$$

权值修正公式可统一表示为:

$$W_{ji}(t+1) = W_{ji}(t) + \eta \delta_{pj} O_{pi} \quad (8)$$

同理可以推导出阈值的变化量  $\Delta \theta_j$  的计算公式:

$$\Delta \theta_j = \eta \delta_{pj} \quad (9)$$

对于输出层单元, 误差  $\delta_{pj}$  为:

$$\delta_{pj} = f'(a_{pj})(d_{pj} - O_{pj}) \quad (10)$$

对于隐层单元, 误差  $\delta_{pj}$  为:

$$\delta_{pj} = f'(a_{pj}) \sum_k \delta_{pk} W_{kj} \quad (11)$$

## 1.2 B-P 网络的学习步骤和训练过程

用 B-P 网络求解应用问题的 B-P 学习算法描述的步骤见图 2。

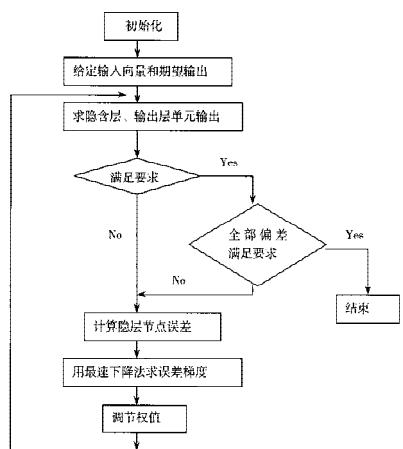


图 2 B-P 网络学习和训练流程

1) 初始化网络及学习参数, 包括设置网络的初始权矩阵、学习因子、势态因子等参数;

2) 提供训练模式, 训练网络, 直到使网络满足学习要求;

3) 前向传播过程, 对给定的输入训练模式, 计算网络的输出模式, 并与期望模式比较, 若有误差, 则执行 (4), 否则, 返回 (2) 提供下一个训练模式;

4) 后向传播过程: 计算同一层单元的误差; 修正权值和阈值; 返回第 (2) 步。

## 2 敏感性伤害预测模型

### 2.1 敏感性影响因素的确定

根据长庆油田储层特征以及试验分析数据, 认为

储层敏感性与储层物性、岩石结构、孔隙结构、岩石矿物组成、地层流体有密切的关系, 确定了各种敏感性伤害的主要影响因素。

1) 水敏。伊蒙混层含量、地层水 pH 值、气测渗透率、主要孔喉均值、地层水矿化度及颗粒分选。

2) 盐敏。地层水矿化度、地层水 pH 值、伊蒙混层含量、高岭石含量、伊利石含量、绿泥石含量、主要孔喉均值、胶结类型以及气测渗透率。

3) 速敏。高岭石含量、伊利石含量、胶结类型、主要孔喉均值、碳酸盐含量、气测渗透率、泥质含量、地层水 pH 值以及地层水矿化度。

4) 盐酸敏感。绿泥石含量、绿蒙混层含量、碳酸盐含量、铁矿石含量、胶结物含量、黄铁矿含量、气测渗透率以及颗粒分选。

5) 碱敏。高岭石含量、石膏含量、铁白云石含量、伊利石含量、地层水 pH 值、气测渗透率、地层水矿化度、钙离子含量以及胶结类型。

## 2.2 神经网络预测模型的建立

以往直接用 B-P 网络建立的预测模型存在着一些问题, 一是由于数据分布比较分散, 训练网络使之达到稳定需要的时间长, 二是模型预测误差大。为此, 需要对 B-P 网络进行改进。

1) 利用 Kohonen 自组织网络对输入数据空间进行聚类, 即对输入空间进行划分, 使得每一划分空间的函数关系更容易用网络逼近<sup>[1]</sup>。

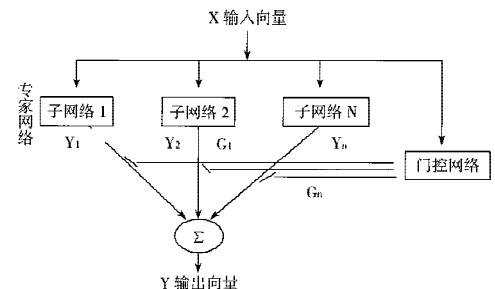


图 3 组合神经网络结构图

2) 利用组合网络(基本结构见图 3)消除单个网络的限制。该网络由局部子网(或专家网络)和门控网络(集成网络)两部分组成。其基本的思想是用门控网络将一个任务分配给一个或几个专家网络, 每个专家网络就是一个 B-P 网络。

3) 对 B-P 网络的算法进行改进。

a. 在权值修正公式中增加一个势态项, 得:

$$W_{ji}(t+1) = W_{ji}(t) + \eta \delta_{pj} O_{pi} + \alpha [W_{ji}(t) - W_{ji}(t-1)] \quad (12)$$

式中,  $\alpha$  为一常数, 称为势态因子, 它决定上一次学

习的权值变化对本次权值更新的影响程度。

b. 在非线性函数  $f(x)$  的选择中, 由于 sigmoid 函数 ( $f(x) = \frac{1}{1+e^{-x}}$ ) 的可微及平滑性, 选择了 sigmoid 函数作为映射函数。但是该函数在  $x$  较大时函数值接近 1, 较小时接近 0, 使得  $f'(x)$  接近 0, 这样权值的变化较小, 训练速度慢。为此, 规定  $f(x)$  的取值范围为 0.01~0.99, 这样就提高了网络的训练速度。

c. 学习因子和势态因子的动态变化。采用了如下形式:

$$\eta_{t+1} = \frac{E_t}{E_{t+1}} \eta_t \quad (13)$$

$$\alpha_{t+1} = 6\eta_{t+1} \quad (14)$$

式中,  $t$  是训练次数。

### 2.3 数据资料的处理

敏感性伤害的影响因素包括定性数据和定量数据。处理时, 首先将定性数据定量化, 然后对所有的数据进行归一化处理<sup>[2]</sup>, 以满足神经网络模型的处理需要。

#### 2.3.1 定性数据定量化

储层敏感性影响因素中存在许多描述性参数, 如胶结类型、岩石颗粒分选等, 需要对它们进行定量化处理。

1) 胶结类型。由于胶结类型属于有序多态定性数据, 所以这里采用了非等差式赋值方法。

2) 岩石颗粒分选。目前常用的是福克、沃德分选标准偏差来表示分选程度, 其归一化方式为<sup>[3]</sup>:

$$X_i = \begin{cases} 0.0690 & \delta_i < 0.35 \\ \delta_i / (4.0 + 0.35) & 0.35 \leq \delta_i \leq 4.0 \\ 0.9432 & \delta_i > 4.0 \end{cases} \quad (15)$$

#### 2.3.2 定量数据标准化

对定量数据标准化时, 采用了极大极小值标准化法则。

$$Y_{ij} = \frac{X_{ij} - X_{\min}}{X_{\max} - X_{\min}} \quad (16)$$

## 3 预测实例

利用靖安油田部分区块的岩石组成、岩石结构、孔渗性质、地层水以及水敏、速敏、盐敏和酸敏的试验数据, 对神经网络进行了学习和预测, 由于碱敏的试验资料缺乏而且长庆油田储层碱敏性很弱, 所以碱敏的验证就忽略了。水敏、速敏、盐敏和酸敏预测结果见表 1~4。

表 1 水敏预测对比结果

序号	井号	层位	实测	预测	实测	预测	判断结果
			水敏指数	水敏指数	水敏程度	水敏程度	
1	柳 109	延 10	0.55	0.5499	中	中	正确
2	柳 106	延 10	0.73	0.6802	中偏强	中偏强	正确
3	柳 106	延 10	0.62	0.5486	中偏强	中	基本正确
4	柳 106	延 10	0.53	0.5311	中	中	正确
5	柳 106	延 10	0.73	0.7052	中偏强	中偏强	正确
6	ZJ11	延 10	0.15	0.1503	弱	弱	正确
7	ZJ2	延 10	0.25	0.253	中偏弱	中偏弱	正确
8	ZJ13	延 10	0.72	0.7178	中偏强	中偏强	正确
9	ZJ12	延 10	0.56	0.5029	中	中	正确

表 2 速敏预测对比结果

序号	井号	层位	实测	预测	实测	预测	判断结果
			速敏指数	速敏指数	速敏程度	速敏程度	
1	柳 109	延 10	0.666	0.6670	中偏强	中偏强	正确
2	柳 109	延 10	0.747	0.7472	中偏强	中偏强	正确
3	柳 109	延 10	0.690	0.6063	中偏强	中偏强	正确
4	柳 106	延 10	0.518	0.5174	中	中	正确
5	ZJ13	延 10	0.049	0.0368	弱	弱	正确
6	ZJ2	延 10	0.604	0.6031	中偏强	中偏强	正确
7	ZJ4	延 9	0.101	0.0992	弱	弱	正确

表 3 酸敏预测对比结果

序号	井号	层位	实测	预测	实测	预测	判断结果
			酸敏指数	酸敏指数	酸敏程度	酸敏程度	
1	柳 106	延 10	0.25	0.2490	中偏弱	中偏弱	正确
2	柳 106	延 10	0.26	0.2950	中偏弱	中偏弱	正确
3	ZJ4	延 10	0.23	0.2309	中偏弱	中偏弱	正确
4	南 10-141 C32		0.38	0.3456	中偏弱	中偏弱	正确
5	木 102	延 10	0.23	0.2033	中偏弱	中偏弱	正确
6	玄 101	延 10	0.27	0.2262	中偏弱	中偏弱	正确

表 4 盐敏预测对比结果

序号	井号	层位	实测	预测	实测	预测	判断结果
			盐敏指数	盐敏指数	盐敏程度	盐敏程度	
1	南 10-141 C41		0.47	0.4689	中	中	正确
2	南 10-141 C32		0.41	0.4588	中	中	正确
3	南 10-151 C32		0.47	0.4709	中	中	正确

由表 1~4 可知, 改进后的神经网络模型预测敏感性伤害的准确率较高, 能满足工程预测的需要, 从而为保护油气层技术措施提供可靠的依据。

## 4 结 论

1) 在对长庆油田储层的“五敏”伤害预测中, 建立了敏感性伤害的预测模型, 提高了预测的精度。

2) 采用改进的神经网络法可较准确地预测储层潜在水敏性、速敏性、盐敏性和酸敏性, 预测实例表明, 预测值和实测值基本相符合。

3) 利用神经网络法预测储层潜在敏感性所需要的参数较少, 特别适合于对探井的潜在敏感性进行快速、有效的预测。

### 参 考 文 献

[1] 冈秦麟. 气藏开发利用基础技术方法 [M]. 北京: 石油工业出版社, 1999, 27-59.

- [2] 彭春耀, 鄢捷年. 人工神经网络在储层敏感性预测中的应用 [J]. 石油钻探技术, 1997, 25 (4): 16-18.
- [3] Dutton S P, Hamlin H S. Geologic controls on reservoir properties of frontier formation low-permeability gas reservoirs: Moxa Arch, Wyoming [R]. SPE 21851, 1991: 1-8.

[审稿 王杰祥]

## Improved Neural Network Model Predicts Formation Sensitivity

He Shunli<sup>1</sup> Tian Leng<sup>1</sup> Gu Daihong<sup>1,2</sup>

(1. College of Petroleum and Gas Engineering, China University of Petroleum (Beijing), Changping, Beijing, 102249, China; 2. China University of Geosciences (Beijing), Beijing, 100083, China)

**Abstract:** On the basis of an improved neural network training method, a way using neural network to quickly predict reservoir potential sensitivity (water sensitivity, flow rate sensitivity, salt sensitivity, acid sensitivity, and alkali sensitivity) is developed. Kohonen self-organized network and Back-Propagation network are employed in the model to forecast the damages caused by the potential sensitivity more correctly. The analyses show that the method needs fewer parameters and has wider applicability (especially for exploratory wells), and quantitatively reflect reservoir potential sensitivity, which can provides reliable foundation for designing reservoir protection techniques and measures.

**Key words:** formation damage prevention; nerve network; mathematical model; prediction; example; Changqing Oilfield

## 多 功 能 油 井 防 污 染 管 柱

由国内一公司研制的多功能油井防污染管柱 1 年来的现场应用证明, 不仅有保持油井稳产、降低生产成本、延长检泵周期、防止洗井液对油层污染等功能, 而且能确保油井作业时不会对地面环境造成污染。

该管柱的工作原理: 防污染管柱在油井检泵时, 随油管下入井内, 置于油层顶界以上、动液面以下。泄油器有两种: 一种是安装在泵上的拉断式泄油器, 另一种是安装在泵下的撞击式泄油器。在检泵、清蜡作业进行热洗井时, 洗井液在防污染器以上形成液柱, 液柱压力将防污染器皮碗胀开并封闭油套环形空间, 洗井液在防污染管柱、泵及泵上管柱间循环, 使泵及泵上油管内、油管外被冲洗干净, 避免了热洗对油层造成的污染。每次作业, 冲洗管柱起出时, 也不会对油层和地面造成污染。

该管柱使用寿命长, 并可在检泵时更换。该管柱适用于井斜角 $\leqslant 25^\circ$ 、原油粘度 $\leqslant 3500 \text{ mPa} \cdot \text{s}$ 的油井。

## 智 能 井 技 术

智能井就是在井中安装了可获得井下油气生产信息的传感器、数据传输系统和控制设备, 并可在地面进行数据收集和决策分析的井。通过智能井可以进行远程控制, 达到优化产能的目的。智能井系统的主要部件包括: 1) 流动控制装置, 通常是控制流体流出/入油藏的水力内部控制阀; 2) 直通层间隔离封隔器, 使水力控制管线和地下控制阀连通; 3) 井下传感器, 向地面提供压力、温度和流量数据; 4) 控制系统, 包括水力/电力地面系统, 用以监测和控制地面条件。

应用智能井技术可以通过一口井对多个油藏流体的流入和流出进行远程控制, 避免不同油藏压力带来的交叉流动。对于多油层合采, 智能完井的应用允许交替开采上部和下部产层, 加快了整个井的生产速度, 油井的净现值也得到了提高。

应用智能完井的注入井可以更好地控制注水, 提高油井的最终采收率。同时, 应用智能井系统也可以减少地面基建设施成本。