

文章编号: 1001-6112(2000)03-0276-04

# 基于人工神经网络的岩石含油气性评价方法

刘勇健<sup>1</sup>, 沈 军<sup>1</sup>, 刘义建<sup>2</sup>, 王 琳<sup>3</sup>

(1. 广东工业大学, 广东 广州 510500; 2. 湖南省地勘局 407 队, 湖南 怀化 418000;  
3. 中国石化 荆州新区勘探研究所, 湖北 荆州 434100)

摘要: 神经网络计算法是模拟人体经络系统活动的机理来研究事物的新方法。本文运用 T. Kohonen 提出的 SOM 自组织人工神经网络模型, 以准噶尔盆地的彩南油田—主力油层为例, 建立起岩石含油气性评价的人工神经网络模型。实例研究表明, 人工神经网络法性能良好, 是一种岩石含油气性评价的有效方法。

关键词: 自组织; 模型; 评价; 含油气性; 人工神经网络

中图分类号: TE122.1

文献标识码: A

岩石的含油气性受一系列因素的影响, 如含油气构造、岩石类型、物质成分、成岩后生变化以及岩石的孔隙性和渗透性等, 是诸因素综合作用的结果。各因素与评价结论往往呈高度的非线性关系。而人工神经网络(ANN)是一种非线性动力系统, 解决这类非线性问题最具优势。它具有良好的自适应性、自组织性及很强的学习、联想、容错及抗干扰功能。

神经网络法是一种模拟人体经络系统活动的机理来对客观事物进行科学研究的方法。它已广泛应用于自动化控制、模式识别、优化设计以及预报预测等领域, 并取得了很好的效果。本文在运用自组织(SOM)人工神经网络原理评价岩石的含油气性方面做了一次新的尝试。

较接近。这些比较接近的样本就构成一类, 在  $N$  维空间形成一个集群。当输入样本分属多个类型时,  $N$  维特征空间就会呈现出多个集群状分布的特点。每个集群代表一类型, 集群的中心就是聚类中心。同属一类的样本与该类聚类中心的距离比与另一类聚类中心的距离要小。可用欧氏(Eyclid)距离来表示:

$$D_j(k) = \sum_{i=1}^N [x_i - w_{ij}(k)]^2 \quad (1)$$

式中,  $D_j$  为欧氏距离,  $x_i$  为分类指标,  $w_{ij}$  为第  $j$  类型的聚类中心,  $k$  为迭代次数。SOM 网络的算法步骤如下:

(1) 给出阈值  $\theta$ ,  $\theta$  用于控制分类粗细。  $\theta$  愈小,

## 1 SOM 网络模型

本文采用由 T. Kohonen 提出的自组织(Self-organizing Feature Map, 简称 SOM)网络模型<sup>[1]</sup>。该网络由两层组成, 即输入层  $L_A$  和输出层  $L_B$ , 拓扑结构如图 1。每个输入节点与输出节点通过连接权  $w$  联系, 输出层节点  $j$  与输入层各节点  $x_i$  ( $i=1, 2, \dots, N$ ) 的连接权  $w_{ij}$  为第  $j$  类的聚类中心。

模型学习样本由具有  $N$  个分类指标的实测样本组成。假设这些学习样本是  $N$  维空间的点, 显然类别相同或某些特征相似的样本在  $N$  维空间就比




图 1 SOM 网络的拓扑结构  
Fig. 1 Topological skeleton diagram of SOM neural networks

收稿日期: 2000-01-10; 修订日期: 2000-04-30.

作者简介: 刘勇健(1968-), 女(汉族), 讲师、硕士, 湖南安化人, 主要从事地质专业的教学和科研工作。

则分类愈细,类型愈多;反之 $\theta$ 愈大,则分类愈粗,类型愈少。因此, $\theta$ 值的选定要根据地层条件和试算确定。

(2) 令输出层初始节点数为1(即 $j=1$ ),并任选一学习样本赋予连接权 $w_{ij}$ 作初始值。

(3) 输入一个新的学习样本,计算它与每一类型聚类中心 $w_{ij}(k)$ 的欧氏距离 $D_j(k)$ 。

(4) 具最小距离的输出神经元竞争获胜,

$$D_j^* = \min\{D_j(k)\}. \quad (2)$$

(5) 识别当前样本所属类别,有两种可能。当 $D_j^* < \theta$ 时,则表示当前输入样本属于输出神经元所代表的类型,并按公式(3)调整连接权:

$$w_{ij}(k+1) = w_{ij}(k) + \alpha(t)\{x_i - w_{ij}(k)\}. \quad (3)$$

式中: $\alpha(t)$ 为增益函数, $0 < \alpha(t) < 1$ 。

当 $D_j^* > \theta$ 时,则输入样本不属于已有输出神经元所代表的类,而属于新一类。此时增加一输出节点(即 $j=j+1$ ),该输入样本就作为 $w_{i(j+1)}$ 的初值,即:

$$w_{i(j+1)}(k+1) = w_{ij}(k). \quad (4)$$

然后转入第(3)步。

(6) 当所有样本输入一遍后,并满足

$$\max\{|w_{ij}(k+1) - w_{ij}(k)|\} < \varepsilon, \quad (5)$$

则学习结束;否则进入下一轮学习。式中 $\varepsilon$ 为预先给定的小值(控制迭代次数)。最终网络模型的输出神经元数为样本的分类数,连接权为各类型的聚类中心。

关于算法的收敛性证明可参阅文献<sup>[1]</sup>。在运算过程中,网络连接权根据输入的训练样本进行自适应、自组织,逐渐收敛到样本空间的各集群的聚类中心。学习完毕后,网络具有了对学习样本的记忆、联想能力。当输入新样本的判别指标时,通过网络识别,就可以确定待测样本的类别。

## 2 实例应用

### 2.1 预测模型的建立<sup>[2,3]</sup>

如前所述,岩石的含油气性与众多因素有关,它是各因素综合作用的结果,我们可从众多的影响因素中提取具代表性的参数作为评判指标。本文选用

岩石的孔渗性特征参数(孔隙度 $\Phi$ ,渗透率 $K$ )、岩石的弹性参数(纵、横波波速 $V_P$ 和 $V_S$ )、岩石的主要氧化物含量指标( $SiO_2$ 、 $Al_2O_3$ 、 $MgO$ 、 $CaO$ 、 $CO_2$ )3个方面的参数共9个评判指标。将实测样本的9个评判指标作为输入,岩石含油气性作为输出,建立起岩石含油气评价的自组织人工神经网络模型。

### 2.2 实例分析

笔者以新疆准噶尔盆地彩南油田目的层之一的侏罗系三工河组( $J_{1s}$ 为一套陆源碎屑岩)80个岩样的实测资料<sup>[4]</sup>作为网络的学习样本,共输入720个数据。表1仅列出部分资料。

首先将第1个样本S1输入网络,此时网络输出层神经元数为一个(即 $j=1$ ),表示第1个样本所属类型,并给连接权矩阵赋初值。接着输入第2个样本,按步骤2.-(5)进行判别。如果它与第1个样本同类时,则按(3)式调整连接权;否则增加一个神经元,即产生新的类别。如此类推,经反复迭代直到满足要求为止,网络学习完毕。

在样本训练过程中,如何选择阈值 $\theta$ 是一个很关键的问题,因 $\theta$ 取值直接关系到分类的合理性。在计算中,我们一般根据储层情况和试算来确定 $\theta$ 值的大小。本文取 $\theta=0.4$ 和 $0.6$ 得到两种不同的分类结果,如表2。当 $\theta=0.4$ 时,分为5类,其网络模型结构为9-5,即输入节点数为9,输出节点数为5;当 $\theta=0.6$ 时,分为3类,其网络模型结构为9-3,即输出节点数为3。

把网络分类结果与岩样含油气性实测结果进行对比,可发现两者之间有良好的对应关系。当 $\theta=0.6$ 时,分成3大类,第一类对应含油气性好的岩样,第二类对应含油气性中等的岩样,第三类对应不含油的岩样。当 $\theta=0.4$ 时,分成5类,这时把上述的第一类细分为富含油气和含油两小类,第二类分为油浸和油迹两小类,第(3)类为不含油类。表1中学习样本的网络分类结果和岩样实测含油气性见表2。从表中可见,阈值 $\theta$ 对样本分类的粗细起有效的控制作用。

### 2.3 岩石含油气性预测

为了检验所建立人工神经网络评价模型的可靠性,将未参加训练的4个学习样本作为“未知”样本,由已学习训练完毕、并掌握了知识信息的神经网络进行预测,取网络阈值 $\theta=0.4$ ,通过网络学习,立即可得判别结果,从表3可见,4个检测样本的预测结果与实测结果完全一致。

表 1 学习样本原始数据

Table 1 Raw data of studying samples

样本号	孔隙度 $\Phi$ / %	渗透率 $K$ / $10^{-3}\mu\text{m}^2$	主要氧化物含量 / %					波速 / ( $\text{m}\cdot\text{s}^{-1}$ )	
			SiO <sub>2</sub>	Al <sub>2</sub> O <sub>3</sub>	MgO	CaO	CO <sub>2</sub>	V <sub>P</sub>	V <sub>S</sub>
S1	18.53	96.89	66.31	11.45	0.91	0.55	3.48	3 820	2 135
S2	18.19	97.23	71.80	8.46	1.62	0.57	2.32	4 124	2 467
S3	18.05	72.16	65.71	11.49	0.92	0.94	3.17	3 920	1 992
S4	14.56	55.71	64.26	11.99	0.57	0.88	2.02	3 819	2 888
S5	22.21	104.49	61.41	8.99	0.96	1.51	1.92	4 216	2 058
S6	16.38	78.52	71.12	11.03	0.83	0.81	2.18	4 120	2 189
S7	14.84	68.05	64.62	12.3	0.97	0.68	3.48	4 020	2 210
S8	18.35	103.66	61.11	12.2	0.98	0.81	2.95	4 064	2 196
S9	18.53	99.57	66.89	12.2	0.73	0.73	3.02	4 109	2 395
S10	10.08	67.44	63.14	10.45	3.11	0.89	6.02	3 878	1 897
S11	19.17	88.31	66.84	10.71	0.96	0.85	3.12	3 984	2 409
S12	19.3	106.78	71.44	11.98	0.88	0.60	4.08	3 805	2 131
S13	12.68	59.50	56.67	14.59	1.56	0.90	4.45	3 608	1 779
S14	17.94	77.44	69.32	9.78	0.82	1.3	4.39	3 940	2 299
S15	13.63	80.54	70.01	8.76	0.79	0.48	3.01	4 577	2 879
S16	14.73	68.31	67.61	10.61	0.69	0.86	2.14	3 997	2 316
S17	17.27	70.16	69.00	11.25	0.76	1.48	3.15	4 002	2 253
S18	19.43	93.10	69.58	11.49	0.79	0.91	3.48	3 633	2 193
S19	16.85	101.38	69.64	11.24	0.98	1.34	3.46	4 064	2 581
S20	14.93	68.72	64.99	13.22	1.01	1.69	4.05	5 370	2 755

表 2 表 1 中学习样本的分类结果

Table 2 Classified results of strdying samples in table 1

$\theta = 0.4$			$\theta = 0.6$		
网络类	样本号	实测含油类型	网络类	样本号	含油性
iv	S1, S8, S9, S12, S18, S19	富含油	一类	S1, S2, S5, S8, S9	含油性好
㊸	S2, S5, S14	含油		S12, S14, S18, S19	
㊹	S3, S7, S11, S15, S17	油浸	二类	S3, S6, S7, S11, S15	含油性中等
㊺	S6, S18	油迹		S16, S17	
㊻	S4, S10, S13, S20	不含油	三类	S4, S10, S13, S20	不含油

表 3 4 个“未知”样本的预测结果与实测结果对比表

Table 3 Comparison between predicted and measured results of four unknown samples

样本号	$x_1$	$x_2$	$x_3$	$x_4$	$x_5$	$x_6$	$x_7$	$x_8$	$x_9$	预测类型	实测类型
S81	19.38	95.66	61.17	9.20	0.89	1.52	1.94	3 954	2 073	㊸	㊸
S82	20.29	101.39	68.77	11.53	0.86	0.73	3.45	3 892	2 390	iv	iv
S83	17.51	73.85	69.68	11.28	0.72	1.50	3.16	4 011	2 356	㊹	㊹
S84	7.08	46.94	53.50	6.98	1.63	0.94	1.65	5 676	3 580	㊻	㊻

### 3 小结

岩石的含油气性受一系列因素的影响。本文选用9个判别因素,建立了岩石含油气性评价的人工神经网络模型。实例研究表明,神经网络法是一种有效的预测方法。神经网络具有如下优点:

①分类能力强: SOM 自组织神经网络通过对学习样本进行训练,可建立起分类评价模型。其中阈值 $\theta$ 对分类的粗细起有效的控制作用,可调节其大小使分类更方便合理。

②容错性强:神经网络具有非线性、容错性及抗干扰性等优点。由于网络的知识信息存储于各单元,个别输入信号失真不会引起识别错误。

③预测速度快:训练好的网络模型在对“未知”

样本进行预测时,仅需少量加法和乘法运算,很快就能得到输出结果,预测变得简单而快捷。

人工神经网络法性能良好,利用神经网络原理解答非线性问题潜力很大,它是一种值得推广的新方法。

#### 参考文献:

- [1] 靳蕃. 神经网络与计算机[M]. 成都:西南交通大学出版社, 1991.
- [2] 张翔. 自组织神经网络在地下水动态分类中的应用[J]. 工程勘察, 1998, (2): 29-31.
- [3] 黄崇福. 模糊信息优化处理技术及其应用[M]. 北京:航空航天大学出版社, 1995.
- [4] 季钟霖. 含气岩石弹性特征及其与油气的关系[J]. 地球物理学报, 1993, 36(2): 20-24.

## AN ARTIFICIAL NEURAL NETWORK-BASED METHOD FOR EVALUATING THE OIL PROSPECTS OF ROCKS

LIU Yong-jian<sup>1</sup>, SHEN Jun<sup>1</sup>, LIU Yi-jian<sup>2</sup>, WANG Lin<sup>3</sup>

(1. Guangdong Industrial University, Guangzhou, Guangdong 510500, China;

2. 407 Geological Party, Hunan Bureau of Geology and Exploration, Huaihua, Hunan 418000, China;

3. Jingzhou Institute of New Prospect Exploration, SINOPEC, Jingzhou, Hubei 434100, China)

**Abstract:** The calculating method of neural networks is a new way to discuss problems by simulating the mechanism of activities of human body network systems. Based on the SOM artificial neural network model advanced by T. Kohonen, an artificial network model for evaluating the oil prospects of rocks is built in this paper by taking the main reservoirs of Cainan oil field in the Junggar Basin as an example. The case study indicates that the method of artificial neural networks has good performance and is an effective way to evaluate the oil prospects of rocks.

**Key words:** self organizing; models; evaluation; oil prospects; artificial neural networks