

# 地震资料的统计模式识别和神经网络模式识别<sup>①</sup>

代俊堂<sup>\*</sup> 钱绍新

(石油勘探开发科学研究院 北京)

## 提 要

在油气储集层预测技术中存在着两种不同的地震模式识别方法——统计模式识别和神经网络模式识别。文中详细地描述了上述两种方法,着重于分析两者决策面的差异,并得出结论:神经网络模式识别的决策面可以是任意复杂的形式,而统计模式识别的决策面只能是有限的几种简单形式;因此神经网络模式识别较统计模式识别具有更大的适应性。通过两个实例证实了上述结论

主题词 模式识别 神经网络 决策面 地震解释

## 1 前 言

利用地震资料来寻找油气藏的方法大致可以分为两种。一种是利用地震资料寻找圈闭,进而根据圈闭间接地推测出油气聚集区;另一种是结合已知井的结果利用地震资料进行油气检测。地震模式识别就是一种重要的油气检测的地球物理方法。

在长期的油气勘探实践及理论工作中,人们一直在探索利用地震资料进行油气检测的方法。早在70年代初,在墨西哥湾应用寻找亮点的方法获得了气藏勘探的成功,从而兴起了一股亮点技术热,随后人们又探索出了平点、暗点技术并将它们应用于油气藏勘探。这些方法在本质上就是利用了地震资料的振幅信息。在80年代初期,又兴起了一种叠前检测技术——振幅炮检距分析技术,即AVO技术,这一技术的理论基础是Zopritz方程,在叠加前用共反射点道集记录分析振幅随炮检距的变化,从而检测油气存在的可能性,这一技术在本质上也只是单一地用到了地震资料中的振幅信息。在油气勘探的实践中,人们逐渐认识到储层是否含有油气与许多因素有着复杂的联系,采用单一的某种信息(例如振幅信息)进行油气检测,往往有很大的局限性。因此人们逐渐意识到了在进行油气检测时综合分析多种参数的必要性,并探索出了一套行之有效的多参数油气检测技术,即人们常说的地震模式识别技术。

模式识别在地震上的应用,最早见于文献<sup>[1]</sup>,以后又有一些论文发表,但一直未得到广泛的应用。国内于80年代末,对模式识别在地震特征提取等方面和方法上作了改进,并结合不同地质条件进行试验,都取得了良好的效果<sup>[2]</sup>,接着又增加了人机交互的功能<sup>②</sup>,这些改进和试验使模式识别在国内得以广泛地应用,目前已成为地震检测油气的一种有效的方法。在分类方法方面,早期采用统计识别的方法,近几年来又增加了神经网络识别方法。在80年代后期,人工神经网络的研究进入了新的高潮期,其原因主要是由于Rumelhart和McClelland提出了反向传播学习算法<sup>[3]</sup>,该学习算法成功地解决了前馈反向神经网络的学习训练问题——该问题在此以前一直困扰着人工神经网络的研究与应用。随着前馈反向神经网络学习训练问题的解决,神经网络的强大分类功能终于在实际应用中得以充分地体现。于是在模式识别技术领域中出现了一种新的分类手段——即前馈反向神经网络模式识别。与此相应地,石油地球物理学中的地震模式识别技术领域中也出现了两种方法——统计模式识别和前馈反向神经网络模式识别共存的局面。

地震模式识别技术中的统计模式识别和前馈反向神经网络模式识别在各自的应用中都有着成功的例子,

<sup>①</sup> 国家自然科学基金会、中国科学院、中国石油天然气总公司、大庆石油管理局联合资助的课题。

<sup>\*</sup> 代俊堂,1993年毕业于北京大学技术物理系,获理学硕士学位。现在中国石油天然气总公司石油勘探开发科学研究院攻读石油地球物理勘探专业的博士学位。通讯处:北京910信箱地球物理所,邮编:100083。

<sup>②</sup> 汤磊.交互油气藏识别系统IRIS软件研制及应用(博士后研究报告).中科院地球物理所,1991.3。

但这两者究竟有何区别呢? 本文将比较详细地讨论地震模式识别中的两种方法, 着重比较两者之间的差异。

## 2 统计模式识别的基本原理和方法

模式识别的任务在于根据已知类别的样本(称为学习样本)去判断未知类别的样本是属于哪一类的。目前地震模式识别技术所采用的统计模式识别方法有 Bayes(贝叶斯)判别和 Fisher(费歇尔)判别。可以证明在正态等协方差假设下, Fisher 判别与 Bayes 判别是等价的<sup>[4]</sup>。下面介绍 Bayes 判别的基本原理和方法。

### 2.1 Bayes 判别的基本原理

假设样本可以分成  $G$  类, 分别记为  $\omega_1, \omega_2, \dots, \omega_G$ 。每个类别的先验概率记为  $P(\omega_g)$ , 样本的类条件概率密度记为  $p(x|\omega_g)$ , 这里  $x$  表示样本的特征矢量。于是利用 Bayes 公式

$$P(\omega_g|x) = \frac{p(x|\omega_g)P(\omega_g)}{\sum_{i=1}^G p(x|\omega_i)P(\omega_i)} \quad (1)$$

得到的条件概率  $P(\omega_g|x)$  称为类别的后验概率。

需要强调的是, Bayes 判别中有三个重要的概率概念: ①类别的先验概率  $P(\omega_i)$ , 它指任意取一个样本, 这个样本属于类别  $\omega_i$  的概率为  $P(\omega_i)$ ; ②类条件概率密度  $p(x|\omega_i)$ , 属于同一类别的样本可以具有不同的特征矢量值,  $p(x|\omega_i)$  就是指属于  $\omega_i$  的样本的特征矢量取值概率分布; ③类别后验概率  $P(\omega_i|x)$ , 它是指取值为  $x$  的样本属于类别  $\omega_i$  的概率。理解上述三个概率概念是理解 Bayes 判别的基础, 尤其是要区分类别的先验概率  $P(\omega_i)$  和类别的后验概率  $P(\omega_i|x)$ 。Bayes 决策规则表述为

$$P(\omega_g|x) = \max_{j=1}^G P(\omega_j|x), \text{ 则 } x \in \omega_g \quad (2)$$

利用 Bayes 公式(1)还可以得到 Bayes 决策规则的另外一种等价形式

$$p(x|\omega_g) \cdot P(\omega_g) = \max_{j=1}^G p(x|\omega_j) \cdot P(\omega_j), \text{ 则 } x \in \omega_g \quad (3)$$

### 2.2 Bayes 判别的实现方法

在统计地震模式识别中常假定样本  $x$  来自于正态母体  $N(\mu_g, \Sigma)$ , 这里的  $\mu_g$  为第  $g$  类样本的特征均值矢量,  $\Sigma$  为样本的协方差矩阵, 它们的估计值可以通过已知类别的学习样本集而得到。为明确, 把已知类别的学习样本集记为

$$\{x_{gk}, g = 1, 2, \dots, G; k = 1, 2, \dots, n_g\}$$

$x_{gk}$  表示第  $g$  类中的第  $k$  个样本矢量;  $G$  为总的类别数;  $n_g$  为第  $g$  类样本中的样本个数, 并记总的学习样本数为  $N$ 。于是:

$$\mu_g = \frac{1}{n_g} \sum_{k=1}^{n_g} x_{gk}, g = 1, 2, \dots, G \quad (4)$$

$$\Sigma = \frac{1}{N-G} \sum_{g=1}^G \sum_{k=1}^{n_g} (x_{gk} - \mu_g)(x_{gk} - \mu_g)^T \quad (T \text{ 表示转置}) \quad (5)$$

利用式(4)和式(5)就可以写出式(1)中的类条件概率密度函数

$$p(x|\omega_g) = \frac{|\Sigma^{-1}|^{1/2}}{(2\pi)^{d/2}} \exp\left[-\frac{1}{2}(x - \mu_g)^T \Sigma^{-1}(x - \mu_g)\right] \quad (6)$$

式中  $d$  表示样本矢量的维数。为了减少计算量, 常用决策式(3)中的  $p(x|\omega_g)P(\omega_g)$  作为判别函数

$$p(x|\omega_g)P(\omega_g) = P(\omega_g) \cdot \frac{|\Sigma^{-1}|^{1/2}}{(2\pi)^{d/2}} \exp\left[-\frac{1}{2}(x - \mu_g)^T \Sigma^{-1}(x - \mu_g)\right] \quad (7)$$

利用 Bayes 判别进行地震模式识别的主要步骤:

第一步:目的层位解释,提取地震特征参数。目前通常提取的特征参数包含四类,即自回归系数,功率谱、自相关函数和振幅类。

第二步:根据试井结果把地震道分类,如含油类、含气类、干层等,并根据已知井的位置抽取一定数量的地震道,形成相应的学习样本集 $\{x_{rk}\}$ 。

第三步:学习。根据学习样本集 $\{x_{rk}\}$ ,利用式(4)和式(5)求出各类的均值向量 $\mu_k$ 和协方差矩阵 $\Sigma$ 。

第四步:预测分类。把未知地震道的特征矢量 $x$ 代入式(7)求出判别函数值,并利用 Bayes 决策规则式(3)进行决策。

### 3 前馈反向神经网络模式识别的基本原理和方法

#### 3.1 前馈反向神经网络的基本结构

神经网络是由大量简单的基本单元——神经元按照某种特定的方式相互连接而成的具有自适应性的动态系统,每个神经元的结构和功能比较简单,而大量神经元按照某一方式组合而成的系统却是非常复杂的。

目前各种神经网络使用最为普遍的神经元模型仍然是 1943 年由 W. McCulloch 和 W. Pitts 共同提出的 MP 模型。前馈反向神经网络也使用 MP 模型,图 1 给出了这种模型的结构示意图。




图 1 神经元模型结构示意图

Fig. 1 The structure of neural unit model




图 2 S 型函数曲线

Fig. 2 The curve of sigmod function

对于序号为  $i$  的神经元,它可以接受多个输入,这些输入既可以是其它神经元的输出,也可以是客观外界直接作用于第  $i$  个神经元的输入。第  $i$  个神经元的输出  $y_i$  与它的输入  $(x_1, x_2, \dots, x_N)$  具有如下的关系。

$$y_i = f\left(\sum_{j=1}^N x_j w_{ij} - \theta_j\right) \quad (8)$$

式中  $w_{ij}$ ——权系数; $\theta_j$ ——阈值; $f$ ——神经元功能函数。

对于前馈反向网络,神经元功能函数一般为 S 型函数

$$y = f(x) = \frac{1}{1 + e^{-x}} \quad (9)$$

S 型函数的一般形状如图 2 所示。前馈反向神经网络的结构如图 3 所示,给出的是一个具有两个隐含层的三层网络例子<sup>①</sup>。从图 3 中可以看出,网络的每一层都包含若干个神经元,同层中的神经元彼此之间没有信息交换,层间的信息只沿一个方向传递,而且只在相邻的两层之间进行,不能越层传递。




图 3 前馈反向网络结构示意图(3层网络)

Fig. 3 The structure of forward feed network (3 layers)

① 如无特殊申明,本文提到的三层前馈反向网络指含有两个隐含层的网络,它的结构如本文图 3 所示。

### 3.2 前馈反向网络模式识别实现方法

神经网络在使用之前必须要经过学习(或称训练)。学习的目的就是要找到一套合适的权系数  $w_{ij}$ , 使得当学习样本的样本矢量作用于神经网络的输入端时, 网络输出端所产生的输出值在给定的误差范围内近似于期望值。目前前馈反向网络所采用的学习算法主要是反向传播算法(即 BP 算法)。在介绍这一学习算法之前先作如下的符号约定:  $I_j^{(q)}$  表示第  $q$  层中第  $j$  神经元的净输入;  $O_j^{(q)}$  表示第  $q$  层中第  $j$  个神经元的输出;  $w_{ij}^{(q)}$  表示连接第  $(q-1)$  层中第  $i$  个神经元与第  $q$  层中第  $j$  个神经元之间的权系数。

具有两个隐含层的三层前馈反向网络可以实现任何复杂的映射<sup>[5]</sup>, 因此模式识别中一般采用三层前馈反向神经网络。下面介绍三层前馈反向神经网络的学习算法。

首先随机地给定  $w_{ij}^{(1)}$ 、 $w_{ij}^{(2)}$  和  $w_{ij}^{(3)}$  的初值, 然后按照下面的步骤调整这些权重值, 直到它们符合要求。

第一步:按下式

$$I_j^{(q)} = \sum_{i=1}^L O_i^{(q-1)} w_{ij}^{(q)} \quad (\text{其中 } L \text{ 为第 } (q-1) \text{ 层的神经元数目}) \quad (10)$$

$$O_j^{(q)} = f[I_j^{(q)}] \quad (11)$$

作一次前馈运算, 得到网络的各级净输入  $I_j^{(q)}$  和输出  $O_j^{(q)}$ 。

第二步: 求出第三层(即输出层)的等效误差分量  $\delta_j^{(3)}$ 。

$$\delta_j^{(3)} = (d_j - O_j^{(3)}) \cdot f'[I_j^{(3)}] \quad (12)$$

式中  $d_j$  为输出层第  $j$  个神经元的期望输出;  $f'$  表示函数  $f$  的导数。

第三步: 分别求出第二层与第一层的等效误差分量  $\delta_j^{(2)}$  和  $\delta_j^{(1)}$ 。

$$\delta_j^{(2)} = \left\{ \sum_{k=1}^M \delta_k^{(3)} w_{jk}^{(3)} \right\} \cdot f'[I_j^{(2)}] \quad (M \text{ 为第三层即输出层的神经元数目}) \quad (13)$$

$$\delta_j^{(1)} = \left\{ \sum_{k=1}^K \delta_k^{(2)} w_{jk}^{(2)} \right\} \cdot f'[I_j^{(1)}] \quad (K \text{ 为第二层的神经元数目}) \quad (14)$$

第四步: 分别求出各层权系数的调整量  $\Delta w_{ij}^{(q)}$ , 并对它们进行调整。

$$\Delta w_{ij}^{(q)} = \alpha \delta_j^{(q)} O_i^{(q-1)} \quad (15)$$

式(15)中的  $\alpha$  为调整步长, 一般取值在 0 与 1 之间。

从以上各步骤可以看出, 反向传播算法的核心思想是首先计算第三层的等效误差分量  $\delta_j^{(3)}$ , 然后利用  $\delta_j^{(3)}$  求出第二层的等效误差分量  $\delta_j^{(2)}$ , 最后利用  $\delta_j^{(2)}$  求出第一层的等效误差分量  $\delta_j^{(1)}$ 。一旦这些误差分量被求出后, 权系数调整量即可立即求得。所以说这是一种由输出层向输入层逐步反向递推的学习算法。

一旦前馈反向神经网络按照上面介绍的学习方法学习完毕后, 就可以用它来进行模式识别了。以三个类别的模式识别为例, 规定第一类学习样本的期望输出为:  $d_1=0.9, d_2=0.1, d_3=0.1$ ; 第二类学习样本的期望输出为:  $d_1=0.1, d_2=0.9, d_3=0.1$ ; 第三类学习样本的期望输出为:  $d_1=0.1, d_2=0.1, d_3=0.9$ , 利用已知类别的学习样本集让网络进行学习。学习完毕后, 就可以利用它来判别某个样本的所属类别了。具体做法是, 让该样本的样本矢量作用于输入端, 如果输出层第  $j$  个神经元的输出值  $O_j = \max_{i=1}^3 O_i$ , 则做出决策: 该样本属于第  $j$  类。

利用前馈反向神经网络进行地震模式识别的主要步骤:

第一步和第二步与前面介绍的统计地震模式识别的第一、二两步完全一样。

第三步: 学习。根据第二步得到的学习样本集, 让前馈反向神经网络进行学习, 直到网络的权系数满足要求为止。

第四步: 预测分类。把未知类别地震道的特征矢量输入到网络的输入端, 如果第  $j$  个输出神经元的输出值

$O_j = \max_{i=1}^G O_i$  ( $G$  为在第二步中所划分的地震道类别数), 则做出决策: 该地震道属于第  $j$  类。

#### 4 Bayes 统计模式识别与前馈反向神经网络模式识别的决策面

不论是利用统计的方法还是利用神经网络的方法, 模式识别都是根据样本的特征参数向量来判断样本的所属类别, 也就是说经过学习后的模式识别系统建立起了这样一种概念: 在某个取值范围的样本是属于某个类别的。这种取值范围的边界就是模式识别系统的决策面。就样本总体而言, 不同类别的样本具有不同的取值范围, 这些范围的边界就是样本类别的分界面。显然如果模式识别系统的决策面与样本总体的类别分界面完全一致, 那么该系统所做出的判断将全部正确。因此从分析形成决策面的能力入手, 可以从本质上分析不同的模式识别系统的分类判别能力。下面将分析目前在地震模式识别技术中所采用的两种方法——Bayes 统计模式识别和神经网络模式识别的决策面。

##### 4.1 Bayes 统计模式识别的决策面

在正态分布的假设下, 考虑一般的情况即不同类别的样本来自不同的正态分布  $N(\mu_g, \Sigma_g)$  ( $\mu_g$  与  $\Sigma_g$  分别为第  $g$  类的样本的均值向量和协方差矩阵)。这时, 判别函数(7)式有如下的具体形式

$$f_g(x) = p(x|\omega_g) \cdot P(\omega_g) = P(\omega_g) \frac{|\Sigma_g^{-1}|^{1/2}}{(2\pi)^{d/2}} \exp\left[-\frac{1}{2}(x - \mu_g)^T \Sigma_g^{-1}(x - \mu_g)\right] \quad (16)$$

前面已经介绍 Bayes 模式识别是根据判别函数的大小来差别样本的类别的, 比如说有两个类别, 如果  $f_1(x) > f_2(x)$ , 则决策  $x$  属于类别 1, 否则决策  $x$  属于类别 2, 这样决策面应满足

$$f_1(x) = f_2(x) \quad (17)$$

根据式(17)易知上述方程所决定的决策面为某种超二次曲面。图 4 表示了二维情况下决策面的 5 种表现形式。

##### 4.2 前馈反向神经网络模式识别的决策面

前馈反向神经网络的决策面不是由一个固定的方程所决定的, 它是在学习过程中通过各层神经元的相互协调作用而形成的。可以证明三层前馈反向神经网络可以有任意形态的决策面。Lippmann 曾给出一个前馈反向神经网络层数与决策面形式的对应表格, 见表 1。从表中可以看出, 当网络的结构由无隐层结构变化为两个隐含层结构时, 决策面的形态也由最简单的超平面变化为任意的形状。

从以上的分析可以看出, Bayes 决策面只能表现为有限的 5 种简单形式, 而三层前馈反向神经网络的决策面则可以是任意形状的。实际中的样本集往往具有复杂的不规则的分界面, 因此神经网络模式识别较统计模式识别具有更强的适应性。

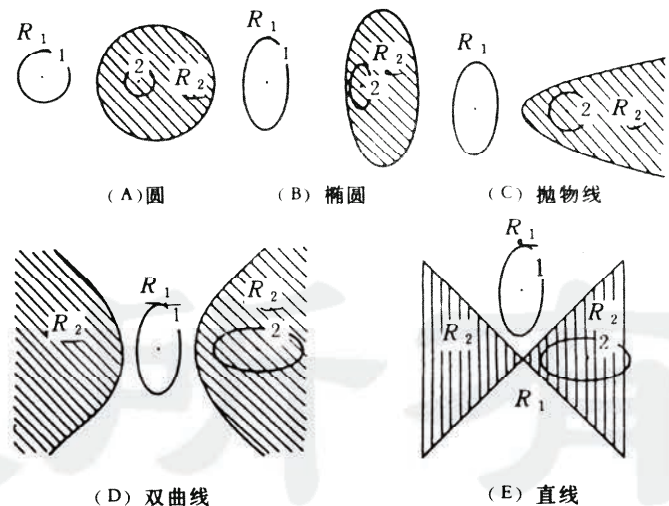


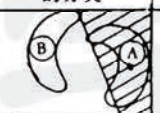
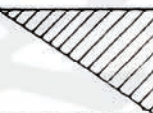

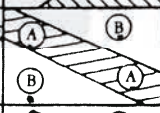
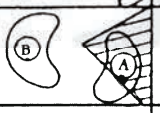
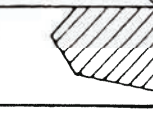

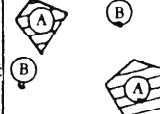

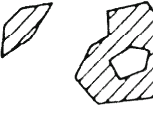


图 4 正态下 Bayes 模式识别的决策面

Fig. 4 The decision interface from Bayes pattern recognition at normal distribution

表 1 前馈反向神经网络层数与决策面的对应关系

Table 1 The relationship between the number of layers of forward feed network and the shape of the decision interface

网络结构	分类区域类型	对异域 (XOR) 分类	对咬合状区域的分类	分类区域一般形状
无隐层 	由超平面分成二个区域			
单隐层 	开凸区域或闭凸区域			
2个隐层 	任意形状 (但与结点数之间的关系复杂)			

Ⓐ、Ⓑ表示两个类别

### 5 两种模式识别方法学习分类的计算实例

实例 1 该实例所使用的学习样本集见表 2, 由 17 个学习样本组成, 分属于三个不同类别, 每个样本的特征由一个四维矢量描述。表 2 还给出了使用 Bayes 判别和三层前馈反向神经网络判别的学习分类结果, 从表 2 中可以看出采用 Bayes 判别有二个样本被错误分类, 而采用三层前馈反向神经网络时, 全部样本都被正确分类。

表 2 实例 1 学习样本集及学习分类结果

Table 2 The known samples and the classification result in case 1

编 号	原 始 数 据				原 分 类	Bayes 统计判别		学习后 分类	前馈反向神经网络判别		
	$x_1$	$x_2$	$x_3$	$x_4$		学习后 分类	后验 概率		实际输出值		
									$O_1$	$O_2$	$O_3$
1	6	-11.5	19	90	1	1	0.989	1	0.901	0.100	0.101
2	-11	-18.5	25	-36	3	3	0.902	3	0.102	0.100	0.900
3	90.2	-17.0	17	3	2	3	0.551	2	0.100	0.900	0.100
4	-4	-15.0	13	54	1	1	0.982	1	0.901	0.101	0.099
5	0	-14.0	20	35	2	2	0.560	2	0.100	0.100	0.900
6	0.5	-11.5	19	37	3	3	0.676	3	0.100	0.100	0.900
7	-10	-19.0	21	-42	3	3	0.894	3	0.098	0.101	0.900
8	0	-23.0	5	-35	1	1	0.555	1	0.900	0.098	0.100
9	20	-22.0	8	-20	3	1	0.632	3	0.100	0.100	0.900
10	-100	-21.4	7	-15	1	1	0.986	1	0.900	0.100	0.100
11	-100	-21.5	15	-40	2	2	0.463	2	0.100	0.900	0.100
12	13	-17.2	18	2	2	2	0.529	2	0.100	0.900	0.100
13	-5	-18.5	15	18	1	1	0.910	1	0.900	0.101	0.100
14	10	-18.0	14	50	1	1	0.999	1	0.899	0.100	0.099
15	-8	-14.0	16	56	1	1	0.941	1	0.900	0.100	0.101
16	0.6	-13.0	26	21	3	3	0.809	3	0.099	0.099	0.899
17	-40	-20.0	22	-50	3	3	0.882	3	0.100	0.100	0.900

实例2 在该实例中对一张实际的地震剖面进行了地震模式识别处理。该剖面来自大庆油田,目的层为葡萄花砂层见图5-c。对于图5-c所示剖面,沿测线共钻6口井,其中ZU301和ZU1井为出油井,ZU211井钻遇含水油层,ZU52、ZA404与ZU17井为出水井。在ZU301、ZU211、ZU52和ZA404井附近各取20个地震道做为学习样本集,截取时窗为26ms。图5-a使用Bayes统计模式识别的分类结果,其中3条曲线,由下往上,分别表示油层概率、含水油层概率和水层概率。图5-b为使用三层前馈反向神经网络的分类结果,其中3条曲线,由下往上分别对应于网络输出层的三个神经元 $O_1$ 、 $O_2$ 和 $O_3$ 的输出值。在网络学习时约定:油层类样本的输出为( $O_1=0.9, O_2=0.1, O_3=0.1$ ),含水油层类样本的输出为( $O_1=0.1, O_2=0.9, O_3=0.1$ ),水层类样本的输出为( $O_1=0.1, O_2=0.1, O_3=0.9$ )。

在该实例中,两种方法给出的结果稍有差别,从图5可以看出,统计模式识别对ZA404井和ZU17井的预测分类效果不如神经网络对这两口井的分类效果好。实际研究工作中我们发现神经网络地震模式识别给出的




图5 地震剖面及分类结果

Fig. 5 Seismic section and classification result

a—Bayes统计地震模式识别结果;b—神经网络地震模式识别结果;c—地震剖面

$P_1$ —油层概率; $P_2$ —含水油层概率; $P_3$ —水层概率。

$O_1$ —油层神经元输出值; $O_2$ —含水油层神经元输出值; $O_3$ —水层神经元输出值

分类结果有时与统计模式识别给出的分类结果基本相似,由于文章篇幅的限制,我们不给出这种情况的计算实例。

## 6 结 论

一种分类系统性能的好坏,常有不同的方法去衡量,而最实际也是最苛刻的衡量方法就是看它的学习样本错分数。我们说某些样本属于某个类别,另外一些样本属于另外的类别。这在本质上就是认为这两类不同的样本在它们的类别空间中存在分界面。在实际问题中我们无法知道这个分界面的精确形式,我们只能利用有限数量的学习样本,通过分类系统的学习训练而得到近似的分界面——决策面。显然有理由相信,决策面与实际分界面的近似程度可以由错分学习样本数来反映。

由于地震数据的复杂性,地震模式识别中样本的分界面有时具有很复杂的形状。本文的计算实例表明,在有些情况下,统计模式识别的预测效果和神经网络的模式识别的预测效果近似,而在分界面变得比较复杂的情况下,神经网络模式识别的结果较统计模式识别的效果更为理想。本文通过决策面分析,指出了出现上述差别的本质原因在于统计模式识别的决策面表现为一些简单的形式,而三层前馈反向神经网络则可以形成任意复杂的形式的决策面,因此三层前馈反向神经网络模式识别的具有更大的适应性。

### 参 考 文 献

- [1] Mathieu P G. and Rice G W. Multivariate Analysis used in the detection of stratigraphic anomalies from seismic data. *Geophysics*, 1969. Vol. 34 (4).
- [2] 钱绍新. 应用模式识别方法预测油气储集层. *地球物理学报*, 1992(5).
- [3] Rumelhart D E., McClelland J L. *Parallel Distributed Processing*. MIT Press, Cambridge, MA, 1986, 18(2).
- [4] 边肇祺. 模式识别. 北京:清华大学出版社, 1988.
- [5] 阎平儿, 黄端旭. 人工神经网络—模型分析与应用. 安徽:安徽教育出版社, 1993.

(本文收到日期 1996-03-29)

(修改稿收到日期 1996-08-22)

(编辑 张 怡)

## STATISTICAL PATTERN RECOGNITION AND NEURAL NETWORK PATTERN RECOGNITION OF SEISMIC DATA

Dai Juntang Qian Shaoxin

(Research Institute of Petroleum Exploration and Development, Beijing)

### Abstract

There are two different seismic pattern recognition methods for prediction of hydrocarbon reservoir. One is statistical pattern recognition (SPR), the other is neural network pattern recognition (NNPR). In this paper, both methods are described with special attention to the analysis of decision interfaces. The decision interface of NNPR can be of any complex forms, while SPR can only have some simple decision interfaces, so NNPR is more adaptable than SPR. This conclusion has been proved by two examples

**Key words** pattern recognition neural network decision interface seismic interpretation