

前馈神经网络的岩性识别方法

卢新卫 金章东

(南京大学地球科学系, 南京 210093)

测井资料的地质解释是测井过程中十分重要的环节。岩芯资料少, 测井资料较多及测井参数分布的模糊性, 是岩性识别中的困难所在。在引入前馈神经网络方法的基础上, 以取芯井岩芯与测井参数的对应关系作为识别模式, 经过向识别模式学习获得模式识别智能知识, 从而利用这些智能知识去识别未取芯井的测井岩性。通过对胜利油田永一地区沙河街组四段测井岩性的计算机判识, 正确判别率达100%。应用结果表明, 神经网络方法性能良好, 具有极好的应用前景。

关键词 神经网络 BP训练算法 模式识别 测井岩性

第一作者简介 卢新卫 男 28岁 博士生 地球化学

测井参数观测值的差异主要取决于岩性, 即决定于组成岩石的矿物成分、结构和岩石孔隙中所含流体的性质。反之, 对于一组特定的测井参数值, 它就对应着地层中的某一种岩性。因此, 在利用测井参数值识别地层岩性时, 首先要在分析研究区内岩芯和测井参数对应特征的基础上, 划分研究区岩芯的岩石类型, 并从各类岩石中读取部分代表性岩样对应的测井参数值, 作为确定岩性与测井参数对应关系的基础数据, 然后通过数学手段建立岩性识别模式。

传统的模式识别采用 Bayes 方法, 它是以概率统计为基础, 通过先验概率和条件概率估计后验概率来达到确切识别。然而, 先验概率很少知道, 而且就某一模式而言, 可能还会以不同程度属于多个标准类别, 建立在判别分析基础上的模式识别, 从理论上和实践中已证明了用于岩性识别的可行性和可信性。不过, 其标准模式的建立与所选方法有关, 具有一定的人为因素^[1]。神经网络模式识别方法是基于学习样本的识别方法^[2], 不需要将模式变换的内在规律转化为显示规则, 仅只需要对样本作简单重复的学习训练, 从而获得智能化的识别知识, 对测井岩性进行识别。

本文以胜利油田永一地区沙河街组四段(简称沙四段)测井岩性的识别为例, 来说明神经网络智能化识别岩性的具体实现过程及其使用效果。

1 人工神经网络与 BP 学习算法

目前使用最为广泛的是误差反向传播(Back-Propagation)的 B-P 网络模型。其实质就是调节各层的加权使网络学会并记忆住学习样本集。学习过程由正向传播和反向传播两部分组成: 正向传播是输入模式从输入层经隐层处理传向输出层; 反向传播是误差信号从输出层向输入层传播并沿途调整各层连接权值及各层神经元的阈值, 以使误差信号不断减少, 直到所有的误差都达到可以接受的最低值。

1989 年, Hechir-Nielson^[3] 证明了一个 3 层的 B-P 网络就可以完成任意的 n 维到 m 维的映射(图 1)。具体步骤可归纳为^[4,5]




图 1 3层网络结构

Fig. 1 Network structure of threelayers

- (1) 权值和节点偏移的初始化。
- (2) 给定输入向量 X 和所希望的输出向量 T 。
- (3) 输入信息正向传播过程中, 经过 Sigmoid 激活函数 $f(X) = 1/(1 + e^{-X})$ 作用后, 在输出节点 k 得

到输出

$$y_k=f(\sum_{j=1}^LW_{jk}y_j'+\varphi_k)\tag{1}$$

式中

$$y_j' = f(\sum_{i=1}^LW_{ij}X_i + \theta_j)\tag{2}$$

为隐含层节点*j* 的输出量; φ_k , θ_j 分别为输出节点*k* 和隐含节点*j* 的阈值; W_{jk} 为隐含层节点*j* 和输出层节点*k* 的连接权值; W_{ij} 为输入层节点*i* 和隐层节点*j* 的连接权值。

(4) 计算网络输出节点 *k* 的值 y_k 与训练样本的目标值 T_k 的误差信号

$$\delta_k = (y_k - T_k)y_k(1 - y_k)\tag{3}$$

(5) 将 δ_k 从输出层向隐含层和输入层反向传播, 计算隐含层的误差信号

$$y_j = (\sum \delta W_{jk}y_j'(1 - y_j'))\tag{4}$$

(6) 用 δ_k 向减少误差方向调整权值 W_{jk} 和阈值 φ_k

$$W_{jk} = W_{jk} + c \delta_k y_j'$$
$$\varphi_k = \varphi_k + d \delta_k\tag{5}$$

(7) 用 y_j 向减少误差方向调整权值 W_{ij} 和阈值 θ_j

$$W_{ij} = W_{ij} + c y_j X_i$$
$$\theta_j = \theta_j + d y_j\tag{6}$$

(8) 对训练样本集中的每个样本往复学习上述过程, 直到整个样本集的均方差

$$E = \frac{1}{N} \sum_{l=1}^N (y_{lk} - T_{lk})^2\tag{7}$$

达到精度要求, 即 $E < \varepsilon$ 为止 (ε 为大于 0 的一个给定小数), 则学习结束, 并输出此时调整后的权值和阈值。(5), (6) 式中的 c, d 为属于 (0, 1) 的学习参数。我们运用 FORTRAN 77 编制了上述模型的通用程序。

2 神经网络训练和测井岩性识别

2.1 岩性识别的原始数据

胜利油田永一地区沙四段有 30 余口井, 其中两口井有部分岩芯, 各井均提供了测井曲线。根据多数井资料拟定了微电极 2 m 梯度 (x_1)、2.5 m 梯度 (x_2)、4 m 梯度 (x_3)、感应电导 (x_4)、声波 (x_5)、浅侧向 (x_6)、补偿中子 (x_7)、井径 (x_8) 和微电极差 (x_9) 共 9 项指示岩性的测井参数^[1] (表 1)。该段的岩芯可分为砾岩、砂岩和泥岩 3 种岩石类型。样

品总数为 84 个。本文以此作为研究对象, 尝试了神经网络方法的效果。

表 1 学习样本集

Table 1 Learning sample set												
样品号	测井参数									期望输出		
	x_1	x_2	x_3	x_4	x_5	x_6	x_7	x_8	x_9	输	出	
G1	4.0	22.0	19.6	70	400	3.70	7.50	21.00	0.00	0.9	0.1	0.1
G2	6.2	28.0	24.0	70	340	1.90	12.00	25.00	2.50	0.9	0.1	0.1
G3	3.0	16.0	15.0	71	350	1.20	16.00	21.00	0.50	0.9	0.1	0.1
G4	2.8	13.0	12.0	70	380	1.60	15.00	22.00	1.30	0.9	0.1	0.1
G5	3.5	23.6	30.0	80	340	1.50	14.50	20.00	0.30	0.9	0.1	0.1
G6	4.8	25.4	36.0	80	350	1.60	12.50	21.00	0.20	0.9	0.1	0.1
G7	3.2	27.0	37.0	75	350	2.30	12.50	20.00	0.20	0.9	0.1	0.1
G8	2.6	31.0	39.0	70	370	1.60	15.00	21.00	0.40	0.9	0.1	0.1
G9	5.5	23.0	33.0	70	330	2.30	16.50	19.50	0.80	0.9	0.1	0.1
G10	2.4	23.4	35.0	78	350	2.20	13.50	19.50	0.60	0.9	0.1	0.1
S1	2.1	47.0	4.0	45	280	1.20	22.00	21.00	0.40	0.1	0.9	0.1
S2	6.0	7.2	7.6	70	370	1.20	15.00	21.50	2.40	0.1	0.9	0.1
S3	2.4	7.9	8.1	80	4 000	0.60	17.50	21.50	0.70	0.1	0.9	0.1
S4	1.4	6.0	9.1	85	350	0.72	14.00	21.00	0.55	0.1	0.9	0.1
S5	2.5	14.6	18.8	70	370	0.80	20.00	20.50	0.00	0.1	0.9	0.1
S6	3.8	17.0	19.0	90	400	0.50	17.50	25.00	0.50	0.1	0.9	0.1
S7	3.0	12.2	17.6	95	430	0.46	18.50	23.50	0.10	0.1	0.9	0.1
S8	2.0	22.5	27.0	65	400	0.80	18.00	22.00	0.00	0.1	0.9	0.1
S9	3.0	12.0	16.0	73	450	0.80	20.00	21.00	0.60	0.1	0.9	0.1
SI2	5.5	10.7	10.2	65	400	0.65	21.00	23.00	0.50	0.1	0.9	0.1
M1	1.1	9.0	12.0	130	350	0.40	26.50	25.00	0.00	0.1	0.1	0.9
M2	0.7	5.3	6.5	155	360	0.30	32.50	25.00	0.10	0.1	0.1	0.9
M4	1.8	5.4	6.0	155	350	0.31	29.00	26.00	0.00	0.1	0.1	0.9
M5	1.1	4.8	5.0	150	400	0.30	32.00	24.00	0.00	0.1	0.1	0.9
M6	0.7	8.0	6.2	135	370	0.35	28.00	23.50	0.00	0.1	0.1	0.9
M7	0.6	6.0	6.1	150	380	0.24	31.00	25.00	0.00	0.1	0.1	0.9
M9	0.4	6.8	8.4	60	530	0.23	35.00	28.00	0.10	0.1	0.1	0.9
M10	0.5	11.4	11.8	71	500	0.32	32.00	27.00	0.00	0.1	0.1	0.9
M11	0.4	10.0	14.0	70	460	0.49	26.00	26.00	0.20	0.1	0.1	0.9
M12	0.6	8.4	8.0	70	450	0.38	28.00	25.00	0.10	0.1	0.1	0.9

2.2 B-P 网络结构的设计

网络的输入、输出层维数是完全根据使用者的要求设计。网络作为模式分类识别器, 输入层的维数为模式的特征向量的个数; 输出层神经元的数目为模式的类别数。为了识别胜利油田永一地区砂四段测井岩性, 共考虑 9 个特征变量即 9 项指示岩性的测井参数, 因此神经网络的输入层有 9 个神经元; 输出层为 3 个神经元, 对应于 3 类岩性 (砾岩、砂岩和泥岩); 隐含层神经元的数目为 4 个。因此, 用于测井岩性识别的神经网络为 9-4-3 型 3 层

网络结构。

表 2 待判别样本及识别结果

Table 2 Sample to be identified and recognizing
result of neural network

样品号	测井参数									BP 法识别结果		实际岩性
	x_1	x_2	x_3	x_4	x_5	x_6	x_7	x_8	x_9			
G25	7.0	21.0	27.0	30	275	2.00	12.50	21.00	1.00	砾岩	砾岩	
G26	3.1	27.6	30.0	55	370	1.10	17.0	21.00	0.40	砾岩	砾岩	
G27	2.8	25.6	31.5	47	350	1.30	12.50	20.50	0.40	砾岩	砾岩	
G28	5.5	26.0	36.5	40	340	2.50	12.50	21.00	0.30	砾岩	砾岩	
G29	4.3	36.0	37.0	45	350	1.70	12.50	22.00	0.30	砾岩	砾岩	
G30	3.5	43.0	51.0	20	200	3.00	14.50	21.00	0.00	砾岩	砾岩	
S25	0.9	18.6	24.5	80	380	0.53	18.50	24.50	0.00	砂岩	砂岩	
S26	3.0	14.6	22.0	55	360	1.00	12.50	20.00	0.00	砂岩	砂岩	
S27	2.5	15.0	19.5	70	340	0.65	17.50	22.50	0.50	砂岩	砂岩	
S28	3.7	14.0	16.5	67	335	0.59	17.00	22.00	0.60	砂岩	砂岩	
S29	3.7	25.0	30.0	50	375	0.59	19.00	22.00	0.10	砂岩	砂岩	
S30	2.8	12.4	17.5	58	380	0.55	19.00	22.00	0.60	砂岩	砂岩	
M19	0.5	10.0	12.0	250	350	0.26	32.50	26.50	0.00	泥岩	泥岩	
M21	1.0	8.0	11.0	215	285	0.31	30.50	23.50	0.30	泥岩	泥岩	
M22	0.6	8.0	6.8	225	395	0.22	30.00	26.50	0.20	泥岩	泥岩	
M23	0.5	7.04	12.0	180	330	0.25	29.00	27.50	0.20	泥岩	泥岩	
M24	0.6	8.0	7.4	235	320	0.33	24.00	26.00	0.30	泥岩	泥岩	

2.3 网络的训练

前面已经提到, 知识规则是通过网络的学习过程得到的, 因此, 网络的训练是决定成功与否的决定因素。取 30 个样品作为训练学习样本(表 1), 训练过程中, 训练样本的目标矢量即期望输出值为 (0.9, 0.1, 0.1), (0.1, 0.9, 0.1) 和 (0.1, 0.1, 0.9), 分别代表砾岩、砂岩和泥岩。学习参数 $c=0.7, d=0.5$, 网络按步骤 (1) ~ (8) 反复训练, 当均方差 $E<0.0005$ 时训练结束, 并输出此时调整后的权值和阈值。通过神经网络的学习, 实现了测井岩性识别神经网络的知识获取和表示, 利用这些知识就能对研究区未取芯井的测井岩性进行识别。

3 验证

为了验证所建立模型的正确性, 取 17 个样品, 作为“未知”样本, 利用训练好的神经网络, 用调整后的权值和阈值按 (1) ~ (2) 式对其进行识别, 识别结果见表 2。可见, 神经网络识别结果与实际情况完全一致。

4 结论

人工神经网络方法是以自身特有的样本学习能力获得识别模式, 从而克服了模糊数学法、灰色聚类法和多元统计法^[1, 6, 7]的缺陷。这种学习算法是一种有指导的训练算法, 它模拟人脑的功能, 分析处理信息, 具有自组织、自学习、自适应、容错及抗干扰能力, 因而识别结果客观可靠。运用这种方法识别岩性是测井岩性识别工作的改进。实际应用表明, 该方法识别速度快, 精度高, 完全可以用于岩性、岩相、沉积微相的识别, 矿床预测及矿物岩石分类等地质方面的研究。

参 考 文 献

1 李汉林, 赵永军. 岩性识别的多元统计方法. 地质论评, 1989, 44(1): 106~ 112

2 殷勤业, 杨宗凯, 谈正. 模式识别与神经网络. 北京: 机械工业出版社, 1992

3 Hechi Nielson R. Theory of the back propagation network. Proc of IJCNN, 1989, 4(1): 593~ 603

4 焦李成. 神经网络系统理论. 西安: 西安电子科技大学出版社, 1990. 242~ 251

5 Hush D R, Home B G. Progress in supervised neural networks. IEEE Signal Processing Magazine, 1993, 10(1): 18~ 38

6 王硕儒, 刘伸衡, 范得江. 海相碳酸盐岩岩相的模糊模式识别. 沉积学报, 1992, 10(4): 462~ 468

7 郭少斌, 董清水, 刘忠群. 灰色聚类自动识别岩性及微相. 沉积学报, 1996, 14(2): 124~ 130

METHOD OF LITHOLOGIC RECOGNIZING BASED ON
FEEDFORWARD NEURAL NETWORK

Lu Xinwei Jin Zhangdong

(Department of Earth Sciences, Nanjing University, Nanjing)

Bull, 1930, 14: 1~ 24

2 刘国臣, 李京昌, 金之钧. 波动地质学研究中资料收集与整理. 石油大学学报, 1994, 18(6): 1~ 7

3 Hedberg H D. Gravitational compaction of clays and shales. Amer J Sci, 1936, 31: 241~ 287

4 Ruby W W, Hubbet M K. Role of fluid pressure in mechanics of overthrust

faulting, II, over thrust belt in geosynclinal area of western wyoming in light of fluid pressure hypothesis. Bull Geol Soc Am, 1960, 60: 167~ 205

5 Lerche I 著. 盆地分析的定量方法(第一卷). 魏增璞, 冷鹏华, 张博文, 等译. 北京: 石油工业出版社, 1996 7~ 10

6 艾伦 P A, 艾伦 J R 著. 盆地分析: 原理与方法. 陈全茂, 张学预, 李大成, 等译. 北京: 石油工业出版社, 1995 246~ 248

RECOVERING PLATE ON INITIAL THICKNESS
OF CLASTIC ROCKS IN SEDIMENTARY BASINS:
A quick and practical method

Wei Yongpei
(Northwest University, Xi'an)
Chen Huixin
(Xi'an Engineering College, Xi'an)

Abstract

There are several methods of recovering initial strata thickness such as compaction, coefficient of compaction, dehydration compaction, vitrinite reflectance and geological statistics. Most of these methods have evident shortcomings and are irrational. So the plate of recovering initial strata thickness has established by means of the computation of the initial strata in certain artificial well. The initial strata thickness can be obtained by this method through knowing present strata thickness and lithology in wells. This method is proved to be convenient and practical.

Key Words: sedimentary basin initial strata thickness recovery empirical plate

(上接第 84 页)

Abstract

Geological explanation of logging data is an important link of logging work. When there are scanty core data and more log data, feedforward neural network is a very effective method to recognize the logging lithology. This paper introduces an identifying method of logging lithology by the pattern recognition approach using feedback neural network. The approach firstly regards the relationship between drilling cores and logging parameters as an identifying pattern so as to obtain intelligent knowledge from the identifying pattern, and finally applies the knowledge to identify the logging lithology of well. The method was used in lithologic recognition of the 4th member of Shahejie Formation in Shengli Oilfields, the result is satisfactory and shows good application prospects.

Key Words: neural network B P algorithm pattern recognition logging lithology