

文章编号: 0253-9985(2002)01-0076-05

谢凤桥构造油气层的人工神经网络识别*

杨久西^{1,2}

(1. 中国地质大学研究生院, 湖北武汉 430074; 2. 中国石化新星公司中南石油局, 湖南长沙 410117)

摘要: 江汉盆地西南缘谢凤桥构造是一背斜构造, 为岩性+构造复合型油藏。油藏的聚集明显受储层纵向分布和横向展布及非均质性的控制。根据这一储层特点, 用前向(BP)网络建立储层参数的仿真计算, 然后用自组织映射特征(SOM)网络来预测油层类别。首先从一口或多口关键井所属已知数据中选取训练样本, 选用冲洗带电阻率、真电阻率、自然伽马、自然电位、补偿声波、补偿中子及井径等 7 类钻、测井数据作输入变量, 由此建立测井数据参数与储层孔隙度、含油饱和度和渗透率等参数的输入输出映射关系。以产油井鄂深 4、8 等井的已测试油层作为训练样本, 用 BP 神经网络进行函数逼近, 来预测储层参数。然后, 利用 SOM 网络进行模式分类。将对储层较敏感的真电阻率、补偿声波进行二度输入, 与 BP 网络所输出的孔隙度、含油饱和度、渗透率等储层参数一起作为油层识别的诊断特征参数。样本的特征参数经过标准化处理后, 送入 SOM 网络进行学习训练和建模, 得出建模样本油层识别的 SOM 网络, 输入所要预测层位的数据, 由网络仿真输出各井的油层识别结果。结果经生产检验, 符合率超过 90%。

关键词: BP 网络; SOM 网络; 储层识别; 测井数据; 储层参数; 预测

作者简介: 杨久西, 女, 38 岁, 工程师(硕士研究生), 管理信息系统和资源经济

中图分类号: TE122.2

文献标识码: A

1 原理^[1~5]

1.1 BP 神经网络

BP 神经网络是目前应用最广泛、研究最深入的一种多层前馈神经网络。该种网络采用有导师监督的学习方式和广义的 Delta 学习规则, 即误差反传播算法, 对非线性可微分函数进行网络权值训练。它经常使用的激活函数是 S 型对数或正切函数以及线性函数。

BP 算法是一种监督式的学习算法, 它是通过连续不断地在相对于误差函数斜率下降的方向上计算网络权值和偏差的变化而逐渐逼近目标的。它由信息的正向传递和误差的反向传播两部分组成。在第一阶段, 即信息的正向传递阶段, 给出输入信息, 通过神经网络处理并计算每个神经元的实际输出值; 在第二阶段, 即误差反向传播阶段, 网络在输出层比较网络输出与目标值, 若未能得到期望的输出值, 则逐层递归计算目标值与期望输出之差(即误差), 以此为根据调节权值。上述两个过程反

复进行, 直到网络输出与目标匹配或误差达到人们所希望的要求时为止^[6]。

1.2 SOM 神经网络

自组织特征映射(self-organizing feature map)网络是一种竞争式学习网络。这种网络采用无导师监督的学习方式, 以基本竞争网络算法为基础, 通过网络中邻近神经元间的侧向交互作用和相互竞争, 在一维或二维输出空间中形成输入信号的特征分布拓扑图, 自适应的形成对输入模式的不同响应, 以完成对输入信号的特征提取功能。SOM 模拟了大脑信息处理的自组织、自学习和聚类功能, 在许多领域得到了广泛应用^[5]。

SOM 网络模型由 4 个功能部分组成。(1) 一个处理单元阵列。这个处理单元阵列从事件空间中接受相关的输入, 并且形成这些输入信号的简单辨别函数。(2) 一种比较选择机制。这种机制就是比较辨别函数并选择一个具有最大函数输出值的处理单元。(3) 某种局部互连作用。这种局部互连作用同时激励被选择的处理单元及其最相近的邻接处理单元。(4) 一个自适应过程。这个自适应过程修正被激励处理单元的参数, 以增加其相应于特定

* 湖北省自然科学基金资助, 编号 NO: 99j007

收稿日期: 2001-12-09

输入的辨别函数输出值。

SOM 模型是由输入层和输出层(竞争层)组成的两层网络。网络中的权分为两类:一类是层与层之间的权,它们是可以学习的;另一类是层内互相抑制的权,一般来讲,它们是固定的,如果满足一定的分布关系,距离近的抑制强,距离远的抑制弱,它是一种对称权。SOM 网络将学习过程分成两部分来进行:一是选择最佳匹配神经元,二是权向量的自适应更新过程。

选择最佳匹配神经元采用竞争机制。对于输入信号 X , 网络自动寻找出竞争层中联接权重与其最靠近的单元 c 。此时 X 与 c 之间的欧氏距离最小,即:

$$\|X - W_c\| = \min_i \|X - W_i\|$$

式中 W_c 表示与 X 最靠近的单元 c 具有的权向量, W_i 表示输入层与竞争层各神经元之间的权向量。这个最小的距离确定了神经元 c 在竞争中获胜。

2 应用

位于江汉盆地西南缘的谢凤桥构造是一背斜构造,其南侧被断层封闭,为岩性+构造复合型油藏,储层具低孔、低渗透特点。

经计算,油藏探明储量约 119×10^4 t,具有建成年产 $2 \times 10^4 \sim 3 \times 10^4$ t 小型油田的资源条件。鄂深4井和鄂深8井相继获得 $6 \sim 7 \text{ m}^3/\text{d}$ 和 $32.4 \text{ m}^3/\text{d}$ 的产能,预示着该油田具有较好的勘探开发前景。由于谢凤桥油藏的聚集明显受储层纵向分布和横向展布及非均质性的控制,运用人工神经网络进行储层的识别和追踪就成为我们的课题。

对谢凤桥含油构造基于人工神经网络的油层识别,是通过 BP 网络和 SOM 网络按二次“滤波”来实现的。首先用 BP 网络建立储层参数的仿真计算,然后用 SOM 网络来预测油层类别。

2.1 预测储层参数^[7~11]

2.1.1 选择训练样本

对沉积型储层而言反映沉积环境的微相对储渗规律性分布有着控制作用,即不同的微相有着不同的分布规律,因此结合已试油层位的情况,我们采用对勘探目的层段进行多个单层储油性三级分类的方法,以这些单层作为学习样本,达到分微相建立学习样本集,通过 BP 网络以反映测井曲线与物性参数间的非线性关系及通过 SOM 网络进行单

层储油性分类的目的。

谢凤桥含油气构造的油气勘探目的层段为荆沙组、新沟嘴组和沙市组,岩性为致密砂岩和泥岩。岩性致密,储层孔渗性差。该含油构造现有鄂深4、6、7、8井等钻井。其中鄂深4井和鄂深8井为产油井。我们的网络训练样本井选择的是鄂深4、6、8井,这3口井测井解释结果中已标定层共有38层,其中鄂深4井的第7、10、13层,鄂深6井的第4、5、6、8层,鄂深8井的12、12¹、12²、13层共11层已经试油,这些层含油气情况已较清楚,因此我们选择这11层作为学习样本。因这11个层位的厚度都很薄,为达到更理想的预测效果,综合各种因素另选鄂深4井第5、6、8、9、11、12层和以上11层共计17层607个样本点作为本研究的训练样本集。另用马王庙油田36井作为检验井,来验证所建立的网络性能及网络的外推预测能力。

网络输入层的节点数目取决于样本的维数。由于不同类型的地层测井等信息响应特征一般不同,致使储层参数有多种。为了确保网络的简单有效性,需要从这些参数中筛选出对储层参数敏感的指标加以利用。对所能提供的地质、地震、钻井、测井、井中化探、录井、测试资料进行充分的调研,为确保网络的有效性,选用冲洗带电阻率^[7](R_{XO})、真电阻率(RT)、自然伽马(GR)、自然电位(SP)、补偿声波(AC)、补偿中子(CNL)及井径(CAL)这7类钻测井数据作为输入变量,由此建立起测井数据参数与储层参数孔隙度(POR)、含油饱和度(S_o)和渗透率(K)的输入输出映射关系,网络输入维数为7,输出变量个数为3,形成映射关系。

2.1.2 设置初始权重

我们采用 Nguyen-Widrow 法则来初始化隐层权值。这种法则适合于 S 型的激活函数,它使神经元节点的活动区域均匀地分布于输入空间,一方面提高了每个神经元的利用效率,另一方面也加快了网络学习的速度。使用该方法可以在较少的训练次数下得到满意的训练结果。对于输出层权值,我们则从 $(-1, 1)$ 之间产生随机数来完成网络权值的初始化。

2.1.3 选取学习速率

学习速率决定着每一次循环训练中所产生的权值变化量,其大小对于网络的收敛速度有较大影响。在训练开始初始功效较好的学习速率,不见得对后来的训练合适。因此,我们希望在网络的学习

过程中能不断调整学习速率,以满足网络的不同需求。为此,我们将自适应学习速率引入网络训练。采用自适应学习速率后,网络将在训练的每一步自动检查误差平方和的大小。当新的误差平方和大于原误差平方和的一定倍数时,说明权值产生了过调,应减小学习速率;当新的误差平方和小于原误差平方和时,说明权值调整不足,应增大学习速率;否则保持原学习速率不变。此方法能保证网络总是以最大的可接受的学习速率进行训练。

2.1.4 数据预处理

在对人工神经网络训练前,需要对数据资料进行预处理。这样做的目的主要有两个:其一,由于地质信息内容广泛、类型众多、性质不一,不同探测技术的变量数和数据精度差异大,数据水平的高低和量纲变化相差悬殊;并且数据具有定量观测性、定性描述性、方向性、条件性、相关性和等级结构性等特征,往往会影响人工神经网络建模和预测的效果。预处理的目的是要使各种信息归一化、无量纲化、平衡化或等权化,以消除其中的不合理现象。其二,BP网络的隐层输出响应函数为S型函数,若输入模式变量的取值范围差异太大会影响网络的正常收敛和识别效果。适合于人工神经网络数据预处理的方法很多,常见的有均匀化、阈值化、标准化、极差化及对数化等。本文采用的是标准化。

2.1.5 训练和检验

将经过变换后的数据送入网络学习,训练的步数定为2 000步,期望误差定为0.000 3。网络训练步数或期望误差两者之一达到,网络训练即停止。该网络训练到723步时,网络误差达到精度要求,网络学习过程结束,训练样本的期望输出与网络的仿真输出几乎完全重合。这说明我们选择的误差范围已完全可以满足现场油田解释工作的实际需要,网络已训练成功,可用来进行参数的外推预测。

2.1.6 网络泛化

在得到标准样本的满意训练结果以后,就可用网络去预测谢凤桥构造各井未知样本的孔、渗、饱等参数。将鄂深6井、7井、8井未知样本的 PXO , RT , GR , SP , AC , CNL , CAL 等7个指标数据输入已训练好的网络,由网络仿真输出6井、7井、8井的孔、渗、饱网络预测值。

2.2 油层识别^[12~14]

油层识别实际上是一个分类问题。自组织特征映射SOM网络采用的是无监督式的学习算法,

只要为网络建立输入模式,提供输入样本,可很快得到输出结果,即目标层位的分类。SOM网络起到的是模式分类器的作用,它将输出响应分成子集类,每一子集对应于输入模式的一个类。

2.2.1 特征参数提取

为进一步提高SOM网络的分类功能,我们在BP网络所输出的储层参数孔隙度、渗透率、含油饱和度的基础上,对地质参数权重较大的真电阻率(RT)、补偿声波(AC)进行二度输入,与孔、渗、饱一起作为油层识别的诊断特征参数。为了检验这些特征参数选取的合理性,我们采用聚类分析的方法来对其进行评价。具体做法是:选择若干类型已知的地层层段样本进行聚类分析,若有已知的油层和非油层出现在某一相同的类别内,则说明用这些参数进行油层识别不合适,此时需要删除或增加一些其他的参数,再进行聚类分析,直到没有油层和非油层样本出现在相同的类别内,即可认为用这套参数进行网络训练和油层识别是可行的。这里我们选取鄂深4井、6井、8井的8个已知层段进行聚类分析。

2.2.2 网络训练

SOM网络训练样本的选择与BP网络对应,即仍采用鄂深4井、6井和8井的17个层位。与BP网络不同的是,BP网络以单个样本点为单位进行训练,而SOM网络以层为单位进行训练,即这里是以每一层各属性的平均值作为一个样本点,这样SOM网络的训练样本数为17。在这17个样本中,油层样本4个,差油层样本6个,干层样本7个。其中,已测试层位11个,未测试层位6个。上述样本的特征参数经过标准化处理后,送入SOM网络进行学习训练和建模。网络训练步数设为5 000,步数达到后网络训练停止,得出SOM网络对建模样本的油层识别结果(表1)。

2.2.3 网络检验

为了进一步验证网络性能,我们用马王庙36井作为检验井来验证网络的推广预测能力。马王庙36井位于潜江凹陷,是一高产油井,其出油层各项储层参数指标总体高于谢凤桥含油构造,使用我们所训练的SOM网络对其试油结果为油层类的层位进行人工神经网络分类识别,正确率达100%。

2.2.4 网络预测

在网络性能得到验证后,网络内部结构稳定下来。输入所要预测的鄂深6井、7井及8井21个未

知层位的数据, 由网络仿真输出各井的油层识别结果(表 2)。

表 1 训练样本神经网络油层识别与测井解释比较表

Table 1 Comparison between oil horizon identification processed by training sample neural networks and well log interpretation									
井 号	层 号	$RT/\Omega\cdot m$	$AC/\mu s\cdot m^{-1}$	$POR/\%$	$So/\%$	$K/10^{-3}\mu m^2$	测井解释	SOM 解释	试油成果 $/m^3\cdot d^{-1}$
ES4	5	64	206	6.0	48.6	1.1	差油层	差油层	0.28
	6	140	208	6.5	41.5	1.3	干 层	干 层	
	7	63	206	6.0	36.4	1.1	差油层	差油层	
	8	116	196	3.8	0.7	0.5	干 层	干 层	1.12
	9	17	267	19.6	44.0	32.4	油 层	油 层	
	10	49	226	10.6	57.2	5.2	差油层	差油层	
	11	44	208	6.6	36.1	1.4	差油层	差油层	6.28
	12	90	208	6.5	29.7	1.3	干 层	干 层	
	13	69	260	18.1	81.7	16.8	油 层	油 层	
ES6	4	49	207	6.2	67.5	0.9	差油层	差油层	累 0.4
	5	80	207	6.3	50.9	1.0	干 层	干 层	干 层
	6	95	218	8.7	77.5	2.2	油 层	干 层	干 层
	8	164	212	7.5	67.5	1.5	干 层	干 层	干 层
ES8	12	6	226	10.4	45.6	5.8	油 层	油 层	32.4
	12 ¹	6	225	10.3	50.4	6.1	差油层	油 层	
	12 ²	10	206	6.0	44.0	1.7	干 层	油 层	
	13	7	224	9.9	44.4	5.2	油 层	油 层	

表 2 鄂深 8 井神经网络油层识别结果

Table 2 Identified results of oil horizons processed by neural networks in Esheng 8 Well									
井 号	层 位	井 段	$RT/\Omega\cdot m$	$AC/\mu s\cdot m^{-1}$	$POR/\%$	$So/\%$	$K/10^{-3}\mu m^2$	测井解释	SOM 解释
鄂 深 8 井	5	3 137.2~ 3 140.0	21	202	5.1	22.2	1.0	干 层	差油层
		3 214.0~ 3 215.5	56	192	2.9	24.2	0.6	干 层	干 层
		3 227.5~ 3 234.5	36	198	4.1	28.8	0.8	干 层	差油层
	6	3 357.4~ 3 359.4	128	196	3.4	19.2	0.6	干 层	干 层
	7	3 361.0~ 3 365.0	100	190	2.4	11.0	0.5	干 层	干 层
	7 ¹	3 373.8~ 3 377.4	109	199	4.4	17.8	0.8	差油层	干 层
	8	3 384.0~ 3 387.0	106	197	3.9	16.0	0.8	干 层	干 层
	9	3 389.0~ 3 390.5	133	182	1.3	20.3	0.2	干 层	干 层
	10	3 400.0~ 3 402.5	126	192	3.2	24.6	0.7	干 层	干 层
	11	3 438.5~ 3 442.2	34	197	3.9	28.4	0.7	干 层	差油层
	12 ⁰	3 487.0~ 3 491.5	10	208	6.4	42.4	1.7	油 层	油 层
	12	3 491.5~ 3 497.0	6	226	10.4	45.6	5.8	油 层	油 层
	12 ¹	3 497.0~ 3 506.0	6	225	10.3	50.4	6.1	差油层	油 层
	12 ²	3 506.0~ 3 512.5	10	206	6.0	44.0	1.7	干 层	油 层
	13	3 512.5~ 3 520.0	7	224	9.9	44.4	5.2	油 层	油 层
		3 580.0~ 3 587.5	15	197	3.8	34.2	0.6	干 层	油 层
		3 608.5~ 3 614.4	6	208	6.4	35.2	1.5	干 层	油 层
		3 635.8~ 3 637.2	11	201	4.8	39.3	0.8	干 层	油 层
		3 640.6~ 3 644.0	25	197	3.8	16.9	0.6	干 层	差油层

3 综合评价

鄂深 8 井从井深 2 843 m 开始出现油气显示, 有 21 个显示层, 显示级别从荧光、油斑、油迹到油浸, 其中 3 382 m 以下显示较活跃, 显示级别高。从表 2 可见, 测井解释出 12⁰, 12, 13 层为油层,

12¹ 为干层, 12² 为干层, 神经网络对这几个单层的解释皆是油层。对第 12 层采用三联作测试, 使该井平均日产油 32.4 m³, 原油性质为轻质油。对于井深为 3 580.0~ 3 587.5 m, 3 608.5~ 3 614.4 m, 3 635.8~ 3 637.2 m 这 3 层神经网络解释为油层, 将来这些层均可作为测试层位。在识别表上还列出

了其他的 3 个层位为差油层、7 个层位为干层的结果。

本次研究的训练样本层位神经网络解释与测井解释的吻合度为 90% 以上, 对照试油结果, 神经网络对于训练样本层位油层识别的准确率达到了 98% 以上, 这说明我们通过 17 个标准层位建立起来的网络具有一定的代表性和较好的模拟、预测能力, 其判别准确度可满足工程预测的需求。

参 考 文 献

- 1 徐丽娜. 神经网络控制[M]. 哈尔滨: 哈尔滨工业出版社, 1998. 1~ 87
- 2 焦李成. 神经网络的应用与实现[M]. 哈尔滨: 哈尔滨工业大学出版社, 1998. 74~ 110
- 3 刘永红. 神经网络理论的发展与前沿问题[J]. 信息与控制, 1999, 28(1): 31~ 44
- 4 Scalerto R S, Tependelenioglu N. A fast new algorithm for training feed-forward neural network[J]. IEEE Trans On Signal Processing, 1992, 40(1): 202~ 210
- 5 陈守余, 周梅春. 人工神经网络模拟实现与应用[M]. 武汉: 中国地质大学出版社, 2000
- 6 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]. 石油勘探技术, 1997, 25(4): 16~ 18
- 7 魏永佩, 陈会鑫. 人工神经网络及其在油气勘探开发中的应用[J]. 大自然探索, 1998, 17(63): 43~ 46
- 8 郭科, 陈伟明, 郭崇华. 基于一种多层神经网络快速学习算法在储层识别中的应用[J]. 四川联合大学学报, 1997, 1(5): 90~ 94
- 9 傅强, 王家林, 周祖巽. 自组织特征映射网络在储层识别中的应用[J]. 同济大学学报, 1999, 27(3): 371~ 374
- 10 薛林福, 潘保芝. 用自组织神经网络自动识别岩相[J]. 长春科技大学学报, 1999, 29(2): 144~ 147
- 11 赵旭东. 石油资源定量评价[M]. 北京: 地质出版社, 1989
- 12 胡守仁, 余少波, 戴葵. 神经网络及其应用[M]. 长沙: 国防大学出版社, 1993
- 13 刘豹, 胡代平. 神经网络在预测中的一些应用研究[J]. 系统工程学报, 1999, 14(4): 338~ 343
- 14 戚德虎, 康继昌. BP 神经网络的设计[J]. 计算机工程与设计, 1998, 19(2): 48~ 50

IDENTIFICATION OF OIL HORIZONS BY ARTIFICIAL NEURAL NETWORKS IN XIEFENGQIAO STRUCTURE

Yang Jiuxi^{1,2}

(1. The Graduation Institute of China University of Geosciences, Wuhan, Hubei;

2. Zhongnan Petroleum Bureau, SINOPEC, Changsha, Hunan)

Abstract: Xiefengqiao anticlinal structure in southwestern margin of Jiangnan Basin is a litho-structural complex oil reservoir. Its oil accumulation was controlled by vertical and lateral distribution and heterogeneity of the reservoir. Two kinds of neural networks—forward network (BP) and self-organizing feature mapping network (SOM)—were used in reservoir parameter simulated calculation and horizon type prediction respectively. Then chose the data of Esheng 4 and Esheng 8 Wells as training samples, used drilling and log data such as RXO, RT, GR, SP, AC, CNL and CAL as input variables to set up input/output mapping relation between log data and POR, So and K parameters of the reservoir, used BP network to make function approximation, used SOM network to make pattern sorting. Then two parameters RT and AC of the reservoirs were reinpuited, the parameters, together with POR, So and oil saturation K outputted from BP networks were taken as characteristic parameters of the reservoir identification. The characteristic parameters were standardized and trained by SOM networks so as to get model sample, then inputted the data of oil horizon that needed to be predicted, the result of oil horizon identification could be outputted from SOM networks. The validity is proved to be more than 90%.

Key words: BP network; SOM network; reservoir identification, logging data, reservoir parameter; prediction