

文章编号: 1001-6112(1999)02-0156-05

神经网络专家系统在预测单井日产量上的应用研究

彭敦陆 徐士进 王汝成 郭延军

(南京大学地球科学系, 江苏南京 210093)

摘要: 本文全面论述了神经网络专家系统及其开发步骤, 并利用所开发出的神经网络专家系统, 以胜利樊家油田 10 口已知油井的储层参数和原油参数及单井日产量为学习样本, 成功地预测了 2 口预测井的单井日产量。说明利用神经网络专家系统可以克服常规的统计方法和模糊方法无法正确确定各参数隶属度及权重分配的缺点, 并指出通过神经网络专家系统进行油田预测的准确、快速及有效性。

关键词: 神经网络专家系统; 单井日产量; B-P 网络; 特征参数

中图分类号: TE19 **文献标识码:** A

在开采条件一定的情况下, 影响单井产量的参数主要是储层参数和原油参数。由于储层参数和原油参数的多样性, 难以用一简单的表达式将其中的关系表示出来。目前, 解决这一问题主要采用统计或模糊方法, 但这些方法不易准确确定参数的隶属度和权重分配。

神经网络专家系统为解决这一预测性问题提供了新途径^[1]。本文运用神经网络专家系统, 以已知油井的 5 个储层物理参数及 3 个原油物理参数及单井日产量为学习样本, 经过神经网络学习, 自动生成知识库。输入预测井的储层参数及原油参数之后, 推理机根据知识库, 可以得出与实际相符的决策井的单井日产量。

1 神经网络专家系统

1.1 神经网络专家系统与神经网络的基本结构

神经网络专家系统有别于常规的专家系统, 它是一种将神经网络技术与专家系统相结合的网络系统, 其系统的一般功能与结构见图 1^[1]。

在该系统中, 知识的存贮与问题求解过程中的推理过程均在系统的神经网络模块中进行。

在神经网络专家系统中, 神经网络模块是系统的核心。它是由大量的基本单元——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

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普遍的神经元模型仍是 1943 年 W·McCulloch 和 W·Pitts 共同提出的 MP 模型。本文也将使用这种模型, 结构示意图见图 2。

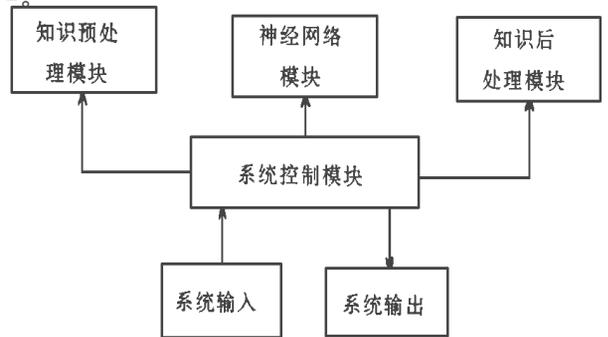


图 1 神经网络专家系统的一般功能与结构

Fig. 1 General function and structure of the Neural Network Expert System

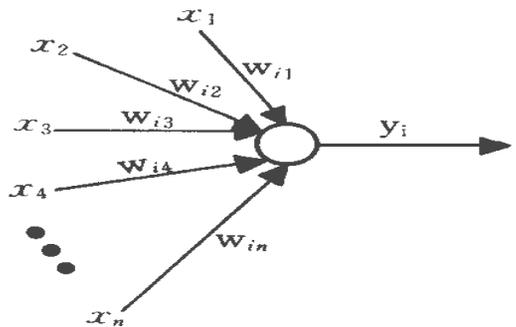


图 2 神经元模型结构示意图

Fig. 2 Structure sketch of the neural unit model

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

$$y_i = f \left[\sum_{j=1}^n x_j w_{ij} - \theta \right] \quad (1)$$

其中 w_{ij} 为权系数; θ 为阈值; f 为神经元功能函数。

本文采用 B-P 网络,神经元功能函数为 S 型函数

$$y = f(x) = \frac{1}{1 + e^{-x}} \quad (2)$$

如图 3 给出了 B-P 网络的拓朴结构框架,该图表示含有两个隐含层的三层网络例子。从图 3 中可见,每个神经元代表不同的变量和不同的值,其个数需要根据实际问题确定;神经网络的层次除输入层和输出层之外,一般还包括一个或多个隐含层;网络单元的连接一般采用分层结构,即相邻两层之间的神经元都要连接;同层神经元之间彼此没有信息交换,层间的信息只沿一个方向传递,而且只在相邻两层间进行,不能越层传递。

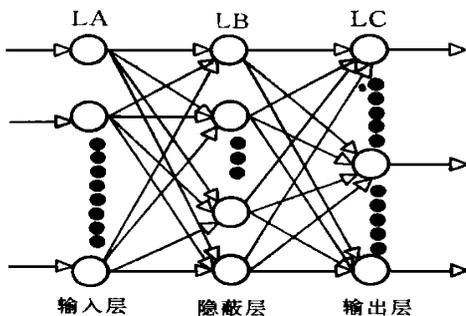


图 3 神经网络的拓朴结构框架图

Fig. 3 Topological structural frame map of the neural network

1.2 神经网络专家系统的实现方法

神经网络专家系统的运行通常分为两个阶段。前一个阶段系统依据专家经验与实例(即学习样本),调整网络中的连接权,使之适应系统期望的输入输出要求,这一阶段又称学习阶段。后一阶段称为运用阶段,它是系统在外界激发下,实现已记忆信息转换操作或联想(即输入输出模式的转换)。这一阶段实际上是一般专家系统所完成的功能。神经网络专家系统的大多数功能(如神经元学习、知识库、推

理机等)是在神经网络模块中进行的,故选择何种网络会直接影响整个系统的精度与速度。本文综合各种因素,采用 B-P 网络。

1.2.1 B-P 网络及 B-P 算法

B-P 网络是一种具有多层结构的神经网络(见图 3)。它含有输入层(LA)、隐蔽层(LB)及输出层(LC),其中隐蔽层可以有多个,本文取一层为例。

B-P 网络主要是利用已知的学习样本集,用误差反向传播算法进行训练并建成网络,其学习过程分为正向学习和反向传播两个过程。在正向学习过程中,输入信息从输入层经隐蔽单元层逐层处理,并传向输出层,每一层神经元的状态只影响下一层神经元的状态。如果在输出层不能得到期望的输出,则转入反向传播,将误差信号沿原来的连接通路返回,通过修改各层神经元的权值,使用权得误差信号最小^[3]。

在如图 2 中,隐蔽层 LB 中节点的输出函数为

$$b_r = f \left(\sum_{i=1}^m W_{ij} \cdot a_i - T_r \right) \quad (r = 1, \dots, u) \quad (3)$$

输出层 LC 中节点输出函数为

$$c_j = f \left(\sum_{r=1}^u V_{rj} \cdot b_r - \theta \right) \quad (j = 1, \dots, n) \quad (4)$$

上两式中, a_i 、 b_r 、 c_j 分别表示 LA 层、LB 层及 LC 上的节点值, a_i 、 b_r 之间的连接权值为 W_{ij} , b_r 、 c_j 之间的连接权值为 V_{rj} , T_r 为 LB 层节点的阈值, θ 为 LC 层节点的阈值。作用 $f(x)$ 函数取 S 型函数。

B-P 网络学习过程的详细步骤(其框图见图 4)为:

- (1) 给 W_{ir} 、 T_r 、 V_{rj} 、 θ 随机赋一个较小的值;
- (2) 对每一模式对 $(A^{(k)}, C^{(k)})$ ($k = 1, \dots, p$), 进行下列操作:

a. 将 $A^{(k)}$ 的值($a_i^{(k)}$)输入 LA 层节点,据 LA 层节点激活值 a_i ,根据式(3)、(4)依次正向计算。

b. 计算 LC 层节点输出 c_j 与期望输出值 $c_j^{(k)}$ 的误差。

$$d_j = c_j(1 - c_j)(c_j^{(k)} - c_j) \quad (5)$$

c. 向 LB 层节点反向分配误差。

$$e_r = b_r(1 - b_r) \sum_{j=1}^n V_{rj} \cdot d_j \quad (6)$$

d. 调整 LB 层与 LC 层节点间连接权 V_{rj} 及 LC 层节点阈值 θ 。

$$V_{rj} = V_{rj} + \alpha \cdot b_r \cdot d_j \quad (7)$$

$$\theta = \theta + a \cdot d_j \quad (8)$$

神经元 i 的输入

$$I_i = \sum W_{ik} D_k \quad (11)$$

e. 调整 LA 及 LB 层节点间连接权 W_{ir} 及 LB 层节点阈值 T_r 。

上式中, W_{ik} 为神经元 i 和下层神经元 k 之间的连接权值; D_k 为下层 k 单元的输出。

$$W_{ir} = W_{ir} + \beta \cdot \alpha \cdot e_r \quad (9)$$

神经元 i 的输入

$$T_r = T_r + \beta \cdot e_r \quad (0 < \beta < 1) \quad (10)$$

$$D_i = f(I_i - \theta)$$

式中, θ 为阈值; f 神经元作用函数。

(3) 重复步骤(2), 直至对于 $j = 1, \dots, n; k = 1, \dots, p$; 误差 d_j 变得足够小 ($< \xi$ 或变为零)。

知识库是专家系统的核心之一, 其主要功能是存贮和管理系统中的知识。在神经网络专家系统中, 知识库是由 B-P 网络通过对样本集的学习(见图 3、图 4) 而得的各神经元之间的连接权值。BP 网络推理的第一层(即输入-隐节点) 为矩阵 (W_{ij}) $n \times m$, 其中 m 为输入节点个数, n 为输出节点个数; 第二层(隐节点-输出) 为矩阵 (V_{ij}) $n \times m$ 。

1.2.2 推理机与知识库

推理机的主要功能是协调控制整个系统, 决定如何选用知识库中的有关知识, 对用户提供的证据进行推理, 以最终对用户提出的特定问题做出回答。在神经网络专家系统中, 推理机是基于神经元的的信息处理过程, 它是通过 B-P 算法实现的。

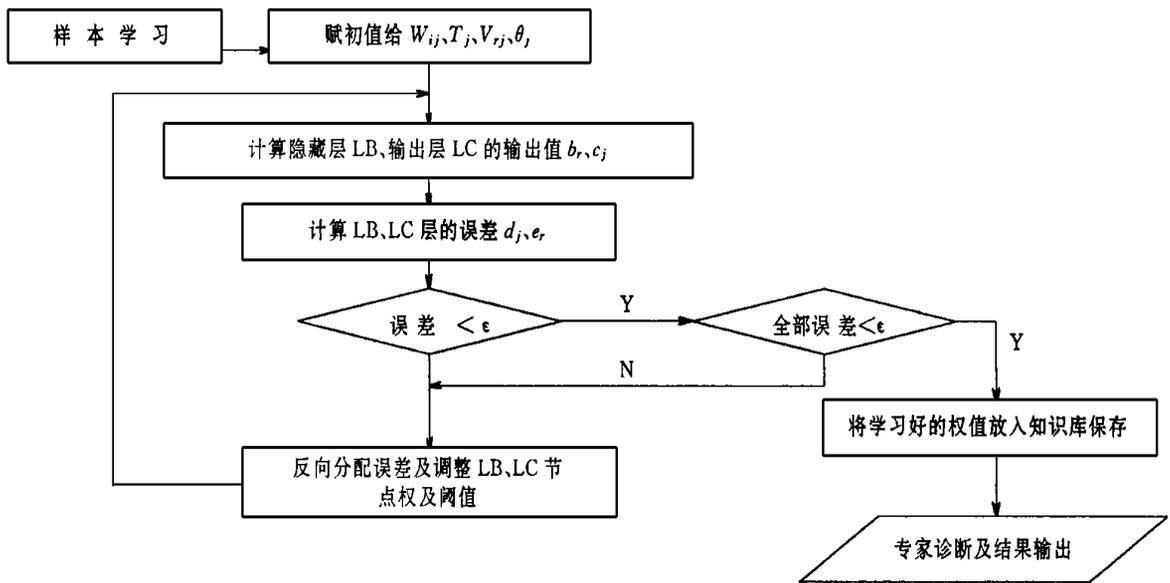


图 4 B-P 网络算法框图

Fig. 4 Block diagram of the B-P network algorithm

1.2.3 解释接口(数据输入及输出模式转换)

在处理实际问题时, 输入的数据既有数值型的, 又有概念型的。而在神经网络中, 处理的数据是在 $(-\infty, +\infty)$ 之间数值。因此在神经元对概念型进行处理之前, 必须对数据类型进行转换。神经元输出的数值在 $(-1, 1)$ 之间, 为便于阅读, 我们往往有必要将一个数值型数据向概念型进行逆转换。这些功能主要在解释接口模块中完成。

2 应用实例及效果

樊家油田区域构造位于东营凹陷博兴洼陷西北部, 属于理庄-樊家鼻状构造北端, 其范围西起高 7 井, 东至樊 7 井; 南起樊 32 井, 北至樊 16 井, 勘探面积约为 120 km^2 。由于自然产能低, 因此用注采法进行开采。我们运用上述神经网络专家系统, 根据先前

开采井的储集层物理及原油参数对注采日产量量的影响,较成功地预测了两口新井的注采日产量量。其具体步骤如下。

2.1 网络训练样本集的选取

应用神经网络专家系统预测单井日产量,虽然不需要给定具体的物理学和数学模型,但网络训练样本集的选取对网络的解释效果起决定性作用。在这个作用中,选取样本的原则是样本的代表性和有效性。代表性要求选取的样品分析值的范围与该区块的物性参数范围相一致。如本文研究区域的地层温度大约为 $105^{\circ}\text{C} \sim 128^{\circ}\text{C}$,所以选取的地层温度也应该在这一数值区间内。本文选取的 5 个储集层参数:储层累积厚度、温度、有效孔隙度、有效渗透率、地层压力,3 个原油参数:含油饱和度、地下原油粘度及地下原油密度,已知油井的单井日产量,它们都基本满足这一条件(见表 1)。有效性要求样本的个数是网络连接权的 3~5 倍,使之符合一般统计建模的要求。

2.2 参数的标准化、归一化

每个油井的资料,难以保证是用同一类仪器、相同刻度标准化及统一操作方式而测得的。故各个单

井数据必然存在以刻度因数为为主的误差。对数据进行标准化,可将这些非地质因素校正到一个水平。本文采用均值-方差法进行标准化。归一化处理则是把数据都统一到 $0 \sim 1$ 之间,以便网络的训练和计算。本文数据标准化和归一化处理后的数据见表 2。

2.3 神经网络的作用过程

将作为学习样本的 10 口单井日产量作为学习样本的输出节点值。将 5 个储层物理参数及 3 个原油参数作用学习样本的输入节点值。代入 B-P 网络学习模型,由图形 4 的算法,可自动生成适合该样本群的知识库及单井日产量与其它 8 个特征参数的非线性计算关系。将预测井的储集层参数及原油参数的标准值,代入推理机,根据知识库就可得出 2 口预测井的单井日产量,22 号井为 $0.44\text{m}^3/\text{d}$,29 号井为 $14.4\text{m}^3/\text{d}$ 。生产后该 2 口井的实际日产量为 $0.51\text{m}^3/\text{d}$ 及 $15.7\text{m}^3/\text{d}$ 。与预测结果相比较误差分别为 13.7% 及 8.2%,它们都在误差允许范围($\leq 20\%$)内。

为了进一步验证系统的准确性,我们还将系统用于其它油区(如垦东、临南等),结果也较理想。

表 1 胜利油田樊 29 区储层参数及原油参数数据表^猿

Table 1 Data schedule of reservoir and crude oil parameters for the Fan-29 region of Shengli oil field

	井号	储层参数					原油参数			日产量 (m^3/d)
		储集层累计 有效厚度 (m)	温度 ($^{\circ}\text{C}$)	有效 孔隙度 (%)	有效 渗透率 ($\times 10^{-3} \mu\text{m}^2$)	地层压力 (Ma)	含油饱 和度 (%)	地下原油 粘度 ($\text{MPa}\cdot\text{s}$)	地下原油 密度 (g/cm^3)	
学 习 样 本	2	47.00	111	17.00	24.39	28.36	62	2.87	0.7467	4.60
	3	6.00	108	16.62	66.81	28.06	62	2.67	0.7409	16.5
	6	12.00	117	16.7	91.62	28.69	57	2.65	0.7664	0.06
	7	9.00	113	17.32	65.33	34.85	58	1.85	0.7163	8.58
	9	17.50	124	15.33	56.52	31.04	58	2.36	0.7455	0.02
	10	6.00	127	16.98	91.55	31.1	56	2.48	0.7542	28.8
	11	6.80	128	14.25	63.36	34.44	58	1.97	0.7325	19.4
	13	11.41	117	16.65	52.32	27.94	62	2.33	0.7156	21.7
	14	5.80	125	17.89	47.21	28.82	62	2.47	0.7563	14.5
	12	150	119	19.98	68.98	34.89	62	2.23	0.7148	0.26
决 策 井	22	9.10	116	10.66	87.77	29.99	58	1.77	0.7236	0.44
	29	9.7	124	11.95	67.32	28.86	64	2.58	0.7366	14.8

表 2 经过标准化、归一化处理后的储层参数及原油参数数据

Table 2 Data schedule of standardized and normalized reservoir and crude oil parameters

	井号	储层参数					原油参数			日产油量
		储集层累计有效厚度	温度	有效孔隙度	有效渗透率	地层压力	含油饱和度	地下原油粘度	地下原油密度	
学 习 样 本	2	0.479	0.150	0.680	0.000	0.614	0.750	1.000	0.652	0.140
	3	0.017	0.000	0.639	0.631	0.017	0.750	0.818	0.534	0.573
	6	0.547	0.450	0.652	1.000	0.109	0.125	0.800	1.000	0.001
	7	0.273	0.250	0.714	0.609	0.998	0.250	0.072	0.031	0.297
	9	1.000	0.800	0.501	0.478	0.454	0.250	0.536	0.628	0.000
	10	0.017	0.950	0.678	0.998	0.462	0.000	0.645	0.806	1.000
	11	0.085	1.000	0.358	0.579	0.951	0.250	0.181	0.362	0.673
	13	0.478	0.450	0.642	0.415	0.000	0.750	0.509	0.017	0.753
	14	0.000	0.850	0.775	0.339	0.129	0.750	0.636	0.849	0.503
	12	0.786	0.554	1.000	0.663	1.000	0.750	0.418	0.000	0.008
	决策井	22	0.282	0.400	0.000	0.942	0.300	0.250	0.000	0.179
29		0.333	0.800	0.138	0.638	0.135	1.00	0.736	0.446	

3 结束语

本文在全面论述神经网络专家系统及 B-P 网络的基础上,利用开发出的神经网络专家系统,较成功地预测了新油井的单井日产量。并通过实例说明建立神经网络专家系统的方法及其有效性。并得出以下几点认识:

(1) 运用神经网络专家系统能够很好地避免一般统计方法和模糊评判的隶属度和权重分配不易正确确定的问题,从而大幅度地提高预测精度。

(2) 因为神经网络专家系统是根据学习样本,经过训练进入知识库。因此,只要测得预测目标的特征参数后,输入系统,很快就能得出预测结果,提高预测速度和工作效率。

(3) 由于系统输入参数是多样的,运用这种多变量技术,进行类似单井日产量的预测工作,为新井及

新油田的后期开发研究,搞好油田开发规划,提供决策依据。

(4) 如果将神经网络专家系统与数值模拟技术有机结合,可以建立与实际情况更加相符的预测模型,从而更有效地为油田服务。

致谢 感谢胜利石油管理局的同志在完成本论文时,提供了宝贵的原始资料。

参 考 文 献

- 1 刘有才等.模糊专家系统原理与设计.北京:北京航空航天大学出版社,1995,246~258
- 2 刘端林等.神经网络在油气评价和预测方面的应用研究.地球物理学进展,10(2),1995
- 3 张广杰等.神经网络在油田动态预测方面的应用.石油学,1997,18(4):70~75

(下转 169 页)

APPLICATION OF ARTIFICIAL NEURAL NETWORKS TO RESERVOIR DESCRIPTION

QIU Liwei KANG Zhijiang

(*Institute of petroleum, CNSPC, Beijing 100083, China*)

Abstract

The normal logging explanation methods based on experience formulas and the linear hypothesis show lower accuracy and successful rate. The artificial neural networks technique can adapt itself, learn itself. It has well prospect in logging explanation. This paper provides a case to illustrate the advantage of the artificial neural network technique in logging porosity explanation.

Key words: artificial neural networks; BP nets; logging explanation; porosity

(上接 160 页)

STUDY ON THE APPLICATION OF THE NEURAL NETWORK EXPERT SYSTEM TO THE PREDICTION OF DAILY OUTPUT PER WELL

PENG Dunlu XU Shijin WANG Rucheng GUO Yangjun

(*Department of Earth Sciences, Nanjing University, Nanjing, Jiangsu 210093, China*)

Abstract

This paper gives an overall discussion on the Neural Network Expert System and its development steps. Taking the reservoir and crude oil parameters and daily output per well for 10 available oil wells in Shengli-Fanjia oil field for example, the Neural Network Expert System developed has been used successfully to predict the daily output per well of two forecasting wells. Therefore, the Neural Network Expert System can overcome the defects of conventional statistical method and fuzzy method who are unable to correctly determine the subordination degree and jurisdiction distribution of each parameter. It is also pointed out that the oil field prediction by the Neural Network Expert System is accurate, rapid and effective.

Key words: the Neural Network Expert System; daily output per well; B-P network, characteristic parameters