

文章编号: 1001-0920(2002)03-0332-04

一类正则模糊神经网络及在沉积微相识别中的应用

许少华¹, 何新贵², 梁久祯¹

(1. 大庆石油学院 计算机系, 黑龙江 安达 151400; 2 北京系统工程研究所, 北京 100101)

摘 要: 考虑一种 5 层结构的正则化模糊神经网络模型, 针对网络结构的优化问题给出了该网络模型规则层节点的选取方法和相应的反传学习规则; 针对样本筛选问题, 提出一种按模糊隶属函数值相近样本向量类别矫正策略。将正则模糊神经网络用于油藏沉积微相的识别, 可自动提取测井曲线与微相类型之间复杂的映射关系, 实现沉积微相的连续识别。实际资料处理结果表明, 该方法对解决沉积微相识别问题具有良好的适应性和实用性。

关键词: 模糊神经网络; 学习算法; 模式识别; 正则化; 沉积微相识别

中图分类号: TP 183

文献标识码: A

A normal fuzzy neural network and its application to sedimentary facies identification

XU Shao-hua¹, HE Xin-gui², LIANG Jiu-zhen¹

(1. Department of Computer Science, Daqing Petroleum Institute, Anda 151400, China;

2 Beijing Institute of System Engineering, Beijing 100101, China)

Abstract: A normal fuzzy neural network (NFNN) with five layers is proposed. Focusing on the structure optimization of network, a new node selection method and corresponding back propagation learning algorithm are presented. Considering contradiction and superfluous in a pattern set that may be brought by rough selection, a strategy in which some patterns' registration is remedied according to their fuzzy value is proposed. NFNN is applied to sedimentary facies identification to find the relation between logging curve and sedimentary facies classifications. Test results illustrate its practicability.

Key words: fuzzy neural network; learning algorithm; pattern identification; normalization; sedimentary facies identification

1 引 言

沉积微相模式识别是石油地质中研究地层结构、构造和分析描述储层的基础性工作, 在油田勘探开发中起着重要作用。目前还没有很好的方法实现沉积微相自动识别。复杂的地质沉积环境反映在表

征油藏性质的测井曲线上具有许多模糊性, 在各种模糊条件的组合下沉积微相表现为分流河道、废弃河道、席状砂和道间泥等类型。目前的沉积微相识别工作主要由手工完成, 不仅工作量大且客观性较差, 已不能满足油田生产和研究的需要。

收稿日期: 2001-01-05; 修回日期: 2001-05-17

基金项目: 黑龙江省教育厅科学技术基金项目(10511119)

作者简介: 许少华(1962—), 男, 河北邢台人, 副教授, 从事神经网络、模糊计算和图像处理等研究; 何新贵(1938—), 男, 浙江浦江人, 研究员, 博士生导师, 从事模式识别、神经网络、进化计算等研究。

本文提出一种利用正则化模糊神经网络进行沉积微相自动识别的方法。正则化模糊神经网络(NFNN)是模糊神经网络的一种代表形式^[1],其基本组成可分为输入层、模糊化层、正则化层、规则层和反模糊化输出层等5层结构。该网络的特点是在确定的输入输出模式和模糊化层隶属函数的个数情形下,模糊化层、正则化层和规则层的节点数是可以计算确定的。网络训练修改的是模糊化中心、方差和规则层至反模糊化输出层的连接权值。将正则模糊神经网络用于油藏沉积微相的识别,可以自动提取测井曲线与微相类型之间复杂的映射关系,解决以往沉积微相模式特征提取困难、客观性差的问题,从而可实现沉积微相识别的自动化处理。

在实际资料处理中,如果样本没有经过精心筛选,在样本模式集中会存在一定的冗余样本;同时,在同一个训练集中也可能存在若干个样本出现矛盾的现象,即具有相近输入而输出相异。这种现象会严重影响网络的学习和推广能力。本文提出一种按模糊隶属函数值相近样本向量类别矫正策略,较好地解决了上述问题。

2 模糊规则描述

模糊逻辑的一般规则描述为:

规则 k : If x_1 is A_{k1} , x_2 is A_{k2} , ..., x_n is A_{kn}

Then y_1 is B_{k1} , y_2 is B_{k2} , ..., y_m is B_{km}

其中, A_{ki} 和 B_{kj} 分别为 U_i 和 V_j 上的模糊集, $X = (x_1, x_2, \dots, x_n)^T$ $U_1 \times U_2 \times \dots \times U_n$ 和 $Y = (y_1, y_2, \dots, y_m)^T$ $V_1 \times V_2 \times \dots \times V_m$ 分别为模糊逻辑系统的输入和输出。设有 K 条模糊 If-Then 规则。由典型的中心平均反模糊化器、乘积推理规则和模糊产生器构成的模糊逻辑系统的数值型输出具有如下形式

$$y_j = \frac{\sum_{k=1}^K b_{kj} \left(\prod_{i=1}^n \mu_{A_{ki}}(x_i) \right)}{\sum_{k=1}^K \prod_{i=1}^n \mu_{A_{ki}}(x_i)} \quad (1)$$

其中 $\mu_{A_{ki}}$ 表示模糊集 A_{ki} 的隶属函数,可用高斯型或 Sigmoid 型隶属函数表示。

3 正则化神经网络的拓扑结构

用 $\mu_{A_{ki}}$ 表示输入变量 x_i 的第 k 个节点的隶属函数,并假定 x_i 具有 n_i 个用于模糊划分的项节点,即对应于输入变量 x_i 的模糊隶属函数个数为 n_i 。则一

般的NFNN 结构如图 1 所示。




图 1 正则化神经网络拓扑结构

第 1 层: 输入层。该层的输入向量可以是精确的数值向量,也可以是模糊量。

第 2 层: 模糊化层。该层使用高斯函数作为隶属函数,第 1 层的 x_i 与该层相应的第 j 个节点的输出为

$$\mu_{A_{ij}}(x_i) = \exp \left[- \left(\frac{x_i - m_{ij}}{\sigma_{ij}} \right)^2 \right] \quad (2)$$

其中, m_{ij} 和 σ_{ij} 分别表示 A_{ij} 的均值和方差,令 $N = \sum_{i=1}^n n_i$, 而 $j = 1, 2, \dots, n_i$ 。该层有 N 个节点。

第 3 层: 正则化层。该层对第 2 层的输出进行正则化操作,即


$$\mu_{A_{ij}}(x_i) = \mu_{A_{ij}}(x_i) / \sum_{j=1}^{n_i} \mu_{A_{ij}}(x_i) \quad (3)$$

其中 $\mu_{A_{ij}}(x_i)$ 表示 $\mu_{A_{ij}}(x_i)$ 的正则化输出。该层节点数与第 2 层节点数相同,即 N 个节点。

第 4 层: 规则层。该层将前件(正规化节点)和结论节点(输出节点)连接起来。连接的规则是:每个规则节点仅与来自每个输入分量经模糊化后的一个正则节点发生连接,如图 1 中第 3 层与第 4 层之间的连接方式。因此,NFNN 网络的初始化结构中共有 $K = \sum_{i=1}^n n_i$ 个规则节点。第 k 个规则节点的输出为

$$z_k = \prod_{i=1}^n \mu_{A_{is}}(x_i) \quad (4)$$

其中, $s = s(k, i)$, 且 $1 \leq s \leq n_i$ 。设 $n_1 = 3, n_2 = 5$, 则 $N = 3n = 15, K = 3^n = 3^5$ 。若将第 2 层的节点排列如下:



其中,0 表示与第 4 层无连接,1 表示有连接。则对应

于 $k = 1$ 到 $k = 3^5$ 的连接状态为

$$k = 1: 001\ 001\ 001\ 001\ 001\ 001$$

$$k = 2: 010\ 001\ 001\ 001\ 001\ 001$$

⋮

$$k = 3^5: 100\ 100\ 100\ 100\ 100\ 100$$

于是,可得出如下表达式

$$k = \sum_{i=1}^5 s(k, i) 3^{i-1} - \sum_{i=1}^4 3^i \quad (5)$$

其中, $s(k, i)$ 按如下规则确定:

$$1) s(k, i) = \left[k + \sum_{j=1}^4 3^j - \sum_{j=1}^{i-1} s(k, j) 3^{j-1} \right] / 3^{i-1}, \text{ mod } 3 \quad (6)$$

2) 若 $s(k, i) = 0$, 则置 $s(k, i) = 3_0$.

第5层:反模糊化层.所有第4层的规则节点都与该层输出节点连接.该层完成中心平均反模糊化操作.设该层有 p 个节点,第 j 个输出分量为

$$y_j = \frac{\sum_{k=1}^K b_{kj} z_k}{\sum_{k=1}^K b_{kj}} = \sum_{i=1}^n \mu_{A_{ij}}(x_i) \quad (7)$$

4 学习样本的筛选

实际中,许多异类样本在样本空间中距离较近的情况是由白噪引起的,有些是样本本身的选取发生了错误.因此,这些样本应处理掉,否则将影响网络的学习和推广能力.有关去噪的方法很多,这里给出一种按模糊隶属函数值相近样本向量类别矫正策略.实验证明,该方法对于样本错误划分和去掉冗余样本的情况很有效.

设 A 为所考虑原始样本集,样本个数为 M ,其中部分样本存在冗余或若干个样本类别与指标值矛盾; B 为处理后的样本集.按模糊隶属函数值相近样本向量类别矫正方法如下:

1) 统计样本中心向量矩阵 $m = (m_{ij})_{n \times n_i}$ 和方差向量矩阵 $\sigma = (\sigma_{ij})_{n \times n_i}$,并按式(1)计算 $\mu_{A_{ij}}(x_i), i = 1, 2, \dots, n; j = 1, 2, \dots, n_i$

2) 随机从 A 中抽取一个样本 x ,计算其它样本 $A \setminus \{x\}$ 与 x 的模糊距离 $d = \sum_{i,j} |\mu_{A_{ij}}(z_i) - \mu_{A_{ij}}(x_i)|$,若 $d < T$ (阈值),则将 z 放入 B 集合,重复此过程直到遍历所有 $z \in A \setminus \{x\}$.将 x 放入 B 集合.

3) 统计 B 集合中样本的类型,设属于 a 类的样本个数最多.

4) 将 B 集合中样本的类型改写为 a 类,利用模糊超球神经网络聚类算法,选择适当的 θ (θ 是选定

常数,用来限制超球大小),把 B 集合中样本划分为若干类,以各类中心构成 a 类训练样本集.

5) 置 $A = A \setminus B$,若 A 空则结束;否则返回 2)。

注意:阈值 T 及 θ 的选取随问题的特点而发生变化,若取得太小则起不到样本类别矫正的目的,网络的学习不会有太大的改进;取得太大,虽然网络学习很快,但却容易发生类别过矫正错误.

5 正则化模糊神经网络的学习算法

用梯度下降法学习调整NFNN的参数.极小化误差函数为

$$E = \frac{1}{2} \|D - Y\|^2 \quad (8)$$

其中, Y 是NFNN的实际输出向量, D 为期望输出向量.

若 w_{ij} 是待调参数,则学习规则为

$$w_{ij}(t+1) = w_{ij}(t) - \eta \frac{\partial E}{\partial w_{ij}} + \alpha \Delta w_{ij}(t) \quad (9)$$

$$\Delta w_{ij}(t) = w_{ij}(t) - w_{ij}(t-1)$$

其中, η 为学习速度, α 为惯性系数.令 $w_{ij} = b_{ij}, m_{ij}$ 和 σ_{ij} ,可分别得到

$$\frac{\partial E}{\partial b_{kj}} = (y_j - d_j) z_k \quad (10)$$

$$\frac{\partial E}{\partial n_{ij}} = \sum_{j=1}^p ((y_j - d_j) \times \sum_{k=1}^K b_{kj} \left(\frac{\delta(j, s(k, i))}{X} - \frac{Y}{X^2} \right)) \frac{\partial \mu_{A_{ij}}(x_i)}{\partial n_{ij}} \quad (11)$$

$$\frac{\partial E}{\partial \sigma_{ij}} = \sum_{j=1}^p ((y_j - d_j) \times \sum_{k=1}^K b_{kj} \left(\frac{\delta(j, s(k, i))}{X} - \frac{Y}{X^2} \right)) \frac{\partial \mu_{A_{ij}}(x_i)}{\partial \sigma_{ij}} \quad (12)$$

其中

$$X = \sum_{j=1}^{n_i} \mu_{A_{ij}}(x_i) \quad (13)$$

$$Y = \mu_{A_{i, s(k, i)}}(x_i) \quad (14)$$

$$\frac{\partial \mu_{A_{ij}}(x_i)}{\partial n_{ij}} = \frac{2(x_i - m_{ij})}{\sigma_{ij}^2} \mu_{A_{ij}}(x_i) \quad (15)$$

$$\frac{\partial \mu_{A_{ij}}(x_i)}{\partial \sigma_{ij}} = \frac{2(x_i - m_{ij})^2}{\sigma_{ij}^3} \mu_{A_{ij}}(x_i) \quad (16)$$

$$\delta(j, s(k, i)) = \begin{cases} 1, & j = s(k, i) \\ 0, & j \neq s(k, i) \end{cases}$$

将式(10~12)代入式(9),即得NFNN网络的参数更新规则.



6 沉积微相识别

在油藏沉积微相模式识别中, 可表征沉积微相类型变化的测井特征参数有 20 余项^[2]。经大量取心井岩心实验分析资料的相关分析和统计, 并结合专家经验, 最终选用地层厚度 h 、电阻率 R 、自然电位 SP 、声波时差 AC 和微电位 R_m 等 5 个参数作为沉积微相识别特征参数, 而输出为沉积微相类型。

这里选择大庆萨北油田某油层段进行实际资料处理。根据萨北油田取心井分析资料和专家解释结果, 初步选取 5 类 376 个小层沉积微相样本, 采用按模糊隶属函数值相近样本向量类别矫正策略对其进行筛选, 确定出 208 个作为训练集学习样本。

样本举例如表 1 所示。

表 1 小层沉积微相训练集部分样本

h	R	SP	AC	R_m	微相类型
1.60	20.00	15.00	315.00	2.50	2
0.90	11.00	11.00	280.00	2.00	3
0.30	17.00	6.50	148.00	1.40	4
3.2	28.70	23.30	226.00	5.10	1
⋮					

表中微相类型 1, 2, 3, 4, 5 分别代表分流河道、小分流河道、废弃河道、席状砂和道间泥等类型。

正则化模糊神经网络的拓扑结构确定为 5-15-15-243-1 型, 即 5 个输入节点, 15 个模糊化层节点(对应每个输入取 3 个隶属函数), 15 个正则化层节点, 243 个规则层节点和 1 个输出层节点。

网络的学习过程采用单样本循环误差修正方式, 即从样本集中随机抽取一个样本进行网络学习, 直到满足误差精度为止, 再选取下一个样本...。学习参数选取如下: 最大学习次数 30 000, 学习速度 0.7, 惯性系数 0.5, 学习精度 0.1(每个样本实际输出与希望输出的最大偏差)。实际中网络训练次数约

为 5 819(每一次包含 208 个样本得到满足精度的修正)。部分学习结果见表 2。

表 2 样本集部分样本学习结果

希望输出	实际输出	绝对偏差	判属类别
3	2.942 496 7	0.057 503 3	3
2	1.901 825 5	0.098 174 5	2
4	3.910 887 8	0.089 112 2	4
1	1.051 453 6	0.051 453 6	1
5	5.007 815 0	0.007 815 0	5
⋮			

将学习好的网络用于其它井的沉积微相类型识别。对同一区块 358 个小层的测井数据进行识别, 判对 312 个小层, 识别正确率达到 86.8%。这在沉积微相自动识别方面已属较高的精度。

7 结 语

根据沉积微相自动识别的实际需要而构造的一类 5 层结构的正则化模糊神经网络, 较好地解决了原始资料信息完整、客观的提取和沉积微相学习及自动识别问题。同时, 针对样本未经筛选会在同一个训练集中出现样本矛盾或冗余现象, 按模糊隶属数值相近样本向量类别矫正策略对样本集中样本进行有效筛选, 较好地解决了以往沉积微相识别模型的不完备及算法的不适应性问题。实际资料处理结果表明, 该方法对解决沉积微相识别问题具有良好的适应性和实用性, 为实现计算机自动识别沉积微相提供了一条有效途径。

参考文献(References):

(上接第 331 页)

- [8] 吴方向, 史忠科, 戴冠中. 区间系统的 H 鲁棒控制[J]. 自动化学报(Acta Automatica Sinica), 1999, 25(5): 703-708
- [9] 吴方向, 史忠科. 离散区间系统的 H 鲁棒控制[J]. 控制与决策(Control and Decision), 2000, 15(4): 479-481
- [10] Jamshidi M. Large-scale systems, modeling and control[M]. New York: Elsevier Science Publishing Co Inc, 1983
- [11] YH Chen. Decentralized robust control for large-scale

uncertain systems: A design based on the bound of uncertainty[J]. J Dynamic Syst Measurements Contr, 1992, 114(1): 1-9

- [12] G M Schoen, H P Geering. A note on robustness bounds for large-scale time-delay systems[J]. Int J Systems Sci, 1995, 26(2): 2441-2444
- [13] Gong Z. Decentralized robust control of uncertain interconnected systems with prescribed degree of exponential convergence[J]. IEEE Trans on Autom Contr, 1995, 40(4): 704-707.