

# 基于 NNFR 神经模糊推理的储层参数识别与评价

张方舟,张媛媛,金宗泽,邱露露,宋经纬  
(东北石油大学 计算机与信息技术学院,黑龙江 大庆 163318)

**摘要:**随着勘探技术的不断发展,研究的不断深入,对油气层预测的精度越来越高。为了提高参数识别的精度,同时,为了应用地化数据实现储层的参数识别与评价,文中通过引入数据归一化算法来克服各方面因素对预测结果的干扰,并借助基于 NNFR 的神经模糊推理来帮助实现参数的识别与评价。通过建立参数预测的分析步骤方法最终完成对储层参数的识别。并为验证理论模型的正确性,通过对 7 口井 12 个试油井的井段数据井进行测试与验证,证实了该方法的可行性。

**关键词:**数据归一化;神经网络;模糊推理;储层预测

中图分类号:TP389.1

文献标识码:A

文章编号:1673-629X(2015)06-0211-05

doi:10.3969/j.issn.1673-629X.2015.06.047

## Fuzzy Inference Reservoir Parameter Identification and Evaluation Based on NNFR

ZHANG Fang-zhou, ZHANG Yuan-yuan, JIN Zong-ze, QIU Lu-lu, SONG Jing-wei  
(College of Computer and Information Technology, Northeast Petroleum University,  
Daqing 163318, China)

**Abstract:** With the continuous development of exploration technology and research is studied deeply, the hydrocarbon reservoir prediction accuracy is higher and higher. In order to improve the precision of parameter identification, at the same time, apply geochemical data to achieve the parameters identification and evaluation of reservoir, by the introduction of data normalization algorithm, overcome the various interferences on the prediction results, and by means of NNFR to identify and evaluate the parameters. By establishing the procedure of analyzing method, it recognizes the reservoir parameters. In order to verify the correctness of the theory and model, it tests the data units of 12 test wells in 7 wells, which proves the feasibility of the method.

**Key words:** data normalization; neural network; fuzzy inference; reservoir prediction

## 0 引言

随着勘探对象向深层系、低孔低渗储集层扩展,大斜度、水平井技术和 PDC 钻头的使用,导致钻井岩屑越来越细。即使在同一口井,其深、浅层岩屑的破碎程度、原油性质等方面有极大变化<sup>[1]</sup>。由于存在过多的影响因素,导致了地质数据中地化数据有不同程度的缺失,从而使评价结果不准确。文献[2]中提到了神经网络模拟人脑在实际应用中具有很多的优势,理论证明了神经网络具有很好的非线性映射能力<sup>[3]</sup>。文献[4]详细地介绍了模糊集理论,同时引进了模糊算子、模糊关系等概念。而实际应用中,神经网络与模糊推理都存在一些不足。文献[5]中提到了在信息融合中

神经网络的特征提取较难且应用范围有限。文献[6]中提到了采用模糊推理获取知识较为繁琐,同时,具有自适应能力较差等不足<sup>[7]</sup>。因此针对神经网络和模糊推理在工程应用中的独特优点以及不足,文中采用地化数据归一化方法结合神经模糊推理(Neural Networks driven Fuzzy Reasoning, NNFR)<sup>[8]</sup>对油气层储层参数进行预测与评价。

## 1 地化数据归一化框架

### 1.1 地化数据

地化录井技术现已普遍应用于油气勘探,地化数据即为地化录井资料,通常分为岩屑热解数据和罐装

收稿日期:2014-07-28

修回日期:2014-10-29

网络出版时间:2015-05-06

基金项目:黑龙江省科技攻关项目(F2004-01);黑龙江省教育重大科研项目(10051x0001);黑龙江省教育科学技术研究项目(11551016)

作者简介:张方舟(1973-),男,教授,硕士生导师,研究方向为计算机网络、计算机仿真、人工智能;张媛媛(1989-),女,硕士研究生,研究方向为计算机系统结构。

网络出版地址: <http://www.cnki.net/kcms/detail/61.1450.TP.20150506.1630.030.html>

气录井数据。岩屑热解数据包括现场基础数据、热解色谱分析数据、钻井地质数据、取样密度数据和取样重量数据;罐装气录井数据包括现场基础数据和化验分析数据。地化录井可获得 14 项数据参数,其中原始分析数据 5 个,派生数据 9 个。地化数据主要是定量评价储油岩,分析的数据主要是储集层有机地化数据,在钻探现场随钻进行分析录井,并且地化数据在烃源岩层识别与评价、油气层评价的地质应用上也具有重要意义。

## 1.2 数据归一化

地化数据的量值有很大差别,因此需要将其进行统一整理和分类,才能形成规范的数据集,只有形成规范的数据集,才能统一各个维度的信息,而且不易忽略极其重要的信息,从而极大程度地发挥原始数据的价值。因此采用数据归一化<sup>[9]</sup>技术能够很好地挖掘数据应用的价值,完成地化数据的分析。通过模糊技术对数据进行归一化处理<sup>[10-11]</sup>。所谓的数据归一化,通过将原始数据中所有待测的训练样本按照同时特征分量进行比例尺的缩小与放大,使之最后的值域在 $[-1,1]$ 或 $[0,1]$ 之间。数据归一化流程如图 1 所示,通过数据的归一化处理可以有效地缩小属性权重对初值的影响。




图 1 数据归一化流程

由于不同的属性之间存在差别较大的联合特征矢量,输入数据归一化方法在一定程度上减小了这种差别<sup>[10]</sup>。下面介绍文中采用的四种数据归一化方法。

### (1) 线性归一化。

线性归一化满足如下的线性方程:

$$\tilde{s}_j^{(p)} = a_j s_j^{(p)} + b_j \quad (1)$$

在 $\tilde{s}_j^{(p)} \in [\tilde{s}_{jmin}, \tilde{s}_{jmax}]$ 中,表示所有样本的第 $j$ 个输入特征分量归一化;在 $P$ 模式下, $s_{jmin}$ 为第 $j$ 个分量的最小值,而 $s_{jmax}$ 为第 $j$ 个分量的最大值。则可得到:

$$\tilde{s}_j^{(p)} = a_j s_j^{(p)} + b_j = \frac{(\tilde{s}_{jmax} - \tilde{s}_{jmin})s_j^{(p)}}{s_{jmax} - s_{jmin}} + (\tilde{s}_{jmax} - \frac{(\tilde{s}_{jmax} - \tilde{s}_{jmin})s_{jmax}}{s_{jmax} - s_{jmin}}) \quad (j = 1, 2, \dots, J) \quad (2)$$

通常可取 $\tilde{s}_{jmin} = 0, \tilde{s}_{jmax} = 1$ 或者 $\tilde{s}_{jmin} = -1, \tilde{s}_{jmax} = 1$ 。

### (2) 分量白化。

分量白化是一种类似白化的处理方法。分量白化所采用的方式是对训练集中样本的同一分量进行处理,令每个分量的均值为 0,且具有一致的方差。可获

得的归一化数据为:

$$\tilde{s}_j^{(p)} = \frac{s_j^{(p)} - \bar{s}_j}{\sigma_j} \quad (j = 1, 2, \dots, J) \quad (3)$$

其中, $\bar{s}_j$ 由式(4)计算得到,而 $\sigma_j$ 由式(5)计算得到。

$$\bar{s}_j = \frac{1}{P} \sum_{p=1}^P X_j^{(p)} \quad (j = 1, 2, \dots, J) \quad (4)$$

$$\sigma_j^2 = \frac{1}{P-1} \sum_{p=1}^P (s_j^{(p)} - \bar{s}_j)^2 \quad (j = 1, 2, \dots, J) \quad (5)$$

(3) 去稳能量归一化。

去稳能量归一化是训练集中所有样本的同一个特征值,通过去除稳态分量的方式后采用归一化方法。

$$\tilde{s}_j^{(p)} = \frac{s_j^{(p)} - \bar{s}_j}{\|s_j\|_n} \quad (j = 1, 2, \dots, J) \quad (6)$$

其中, $\bar{s}_j$ 为 $P$ 模式第 $j$ 个特征分量的均值,为去稳能量归一化的稳态分量; $\|s_j\|_n$ 的含义表示矢量 $s_j$ 的 $n$ 范数, $n$ 取 $1, 2, \dots, \infty$ 。

(4) 同类特征规整化。

文献[12]采用了如下的归一化方法:针对类别属性的不同分别对模式去稳态分量(均值),然后相对于能量进行归一化(或称协方差均衡),从而使输入数据分布于 $[-1,1]$ 之间。

文中将这种对同类特征进行归一化的处理称作规整化。假设训练集包含 $C$ 个模式类别 $\omega_i (i = 1, 2, \dots, C)$ ,每个类别 $\omega_i$ 包含 $N^{(i)} (i = 1, 2, \dots, C)$ 个模式样本,则 $\omega_i$ 类的数据构成的子集可记为

$$\Omega_i = \{x_i^{(p)} (p = 1, 2, \dots, N^{(i)}; i = 1, 2, \dots, C)\}$$

规整化方法的具体实现如下:

求得 $\omega_i$ 类第 $j$ 个分量的统计均值为

$$\bar{s}_{j,i} = \frac{1}{N^{(i)}} \sum_{p=1}^{N^{(i)}} s_{j,i}^{(p)} \quad (i = 1, 2, \dots, C; j = 1, 2, \dots, J) \quad (7)$$

这样经过去稳态分量后的模式样本为

$$s_{j,i}^{(p)} = s_{j,i}^{(p)} - \bar{s}_{j,i} \quad (i = 1, 2, \dots, C; j = 1, 2, \dots, J) \quad (8)$$

最后进行类别内能量的归一化:

$$\tilde{s}_{j,i}^{(p)} = \frac{s_{j,i}^{(p)}}{\|s_{j,i}\|_n} \quad (i = 1, 2, \dots, C; j = 1, 2, \dots, J) \quad (9)$$

式中, $\|s_{j,i}\|_n$ 表示 $\omega_i$ 类中所有样本去稳后的第 $j$ 个分量构成的矢量 $s_{j,i}$ 的 $n$ 范数, $n$ 取 $1, 2, \dots, \infty$ 。

## 2 油气层地化参数识别与评价

### 2.1 NNFR

在对参数进行神经网络的定量计算和解释时,会遇到很多难点,如建立的 ANN 解释模型对输入信息的干扰能力有限,对所选学习训练集中的学习样本可靠性要求较高,等等。因此,得出使用建立的解释模型技

能对数值信息进行处理,又可以嵌入专家的模糊性知识,提高抗干扰能力和预测精度。模糊系统可以较好地处理模糊性的信息,但模糊系统的规则集和隶属度函数等设计参数大多依靠经验来选择。通过利用神经网络的学习方法对输入输出样本进行自动设计和调整设计参数,实现自适应与学习的能力,将是研究的重点。文中也是在此基础上,引入了基于神经网络的模糊推理(NNFR)。采用的结构如图2所示,并通过这种方式对地化数据所提供的参数进行储层预测。

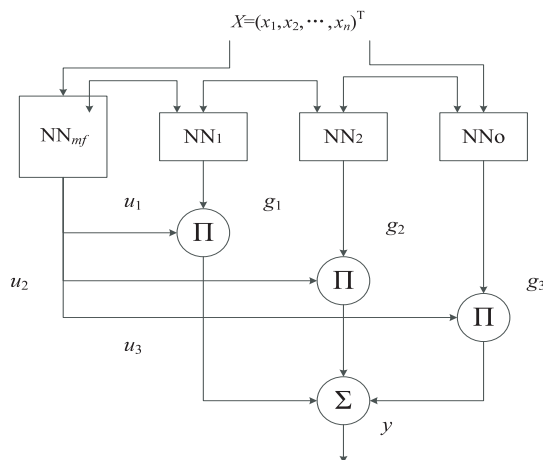


图2 基于神经网络的模糊推理

NNFR 算法的实现步骤如下：

第一步：使用者首先选取待 NNFR 神经网络的训练样本集。其中，样本具有如下关系：

$$(x_1, x_2, \dots, x_m) \rightarrow Y$$

第二步：将输入输出数据对  $(x_i, y_i)$  分成两组，一组作为待 NNFR 的训练数据，共有  $n_t$  个；另一组数据作为检验数据集，用以对之前数据集训练的神经网络的检验，共有  $n_c$  个，则  $n = n_t + n_c$ 。

第三步：采用 FCM 聚类方法，将待训练的数据分成  $r$  个维度，用  $R^s (s = 1, 2, \dots, r)$  表示。 $R^s$  中的训练数据用  $(x_i^s, y_i^s)$  表示，其中  $i = 1, 2, \dots, (n_t)^s ((n_t)^s$  用以表示  $R^s$  中训练数据的个数)。

第四步：决定 NN<sub>mf</sub> 网络的关键，是各规则的“if”部分，通过神经网络的反馈，每个“if”部分都会获得一个隶属度。如果  $x_i$  是 NN<sub>mf</sub> 的输入层上的一个矢量，那么由式(10)给出网络输出层上的期望输出：

$$W_i^s = \begin{cases} 1, & x_i \in R^s \\ 0, & x_i \notin R^s \end{cases}, i = 1, 2, \dots, (n_t)^s; s = 1, 2, \dots, r \quad (10)$$

在 NN<sub>mf</sub> 网络中，输入层节点为  $m$  个，输出层节点数为  $r$  个，中间为隐含层。 $x_i$  属于各个规则的“if”部分的隶属度：

$$\mu_A^s(x_i) = \bar{W}_i^s, i = 1, 2, \dots, n \quad (11)$$

第五步：完成规则的操作，即“then”部分的网络构

造。第  $S$  条规则对应的网络为 NN<sub>s</sub>，将训练数据  $x_{i1}^s, x_{i2}^s, \dots, x_{im}^s$  作为它的输入值， $y_i^s (i = 1, 2, \dots, (n_t)^s)$  作为它的输出，然后训练神经网络 NN<sub>s</sub>。NN<sub>s</sub> 训练完毕，输入相应的数就可以通过该网络得到一个权值，即规则对其作出的回应。通过引入准则(12)来避免神经网络发生过学习现象，从而提高神经网络的训练和学习能力。

$$I^s = \frac{n_c}{(n_t)^s + n_c} \sum_{i=1}^{(n_t)^s} [y_i - g_s(x_i)]^2 + \frac{(n_t)^s}{(n_t)^s + n_c} \sum_{i=1}^{n_c} [y_i - g_s(x_i) \mu_A^s(x_i)]^2 \quad (12)$$

当  $I^s$  值在网络 NN<sub>s</sub> 的训练中取最小值时，可停止训练。当 NN<sub>s</sub> 构造完后，用检验数据  $(x_{i1}, x_{i2}, \dots, x_{im}) (i = 1, 2, \dots, n_c)$  作为这些网络的输入，由式(13)计算出该规则网络的误差量：

$$\theta_M^s = \sum_{i=1}^{n_c} [y_i - g_s(x_i) \mu_A^s(x_i)]^2 \quad (13)$$

式中， $\mu_A^s$  是由 NN<sub>s</sub> 网络输出得到的值。

在训练每个 NN<sub>s</sub> 网络过程中，都使用相同的输入变量，但对于结论部的  $\mu_A^s(x)$ ，也许只是部分输入变量的函数，此时，可以简化所构成的 NN<sub>s</sub> 网络，即消去那些无关的变量，这是接下来的工作。

第六步：通过降低维数的方法来运算，通过消去任意一个  $X^p$  变量，这种方式减少了一个输入的维数，同时用这些数据重复第五步，得到模糊规则的“then”部分的神经网络，并由式(14)计算出在消除  $X^p$  的情况下，第  $S$  条规则控制量的误差平方和  $\theta_{m-1}^{SP}$ ，比较  $\theta_m^s$  和  $\theta_{m-1}^{SP}$ ，如果：

$$\theta_m^s > \theta_{m-1}^{SP} \quad (14)$$

则说明输入变量  $X^p$  在所有输入变量中对于第  $S$  条规则所起作用很小，所以  $X^p$  分量可以忽略。

第七步：继续进行第五步，通过重新构造网络 NN<sub>s</sub> ( $S = 1, 2, \dots, r$ ) 的方式，来计算  $\theta_{m-1}^{SP}$ ，并循环执行第五步和第六步，直到式(14)对剩余的任意变量都不成立为止。能使  $\theta^s$  取最小值的模型是最好的 NN<sub>s</sub> 神经网络模型。

第八步：推导出最终的预测值或控制量  $y_i^*$ ：

$$y_i^* = \sum_{s=1}^r \mu_A^s(x_i) \cdot g_s(x_i) (i = 1, 2, \dots, n) \quad (15)$$

## 2.2 参数识别与评价步骤

油气田地地质资料富含大量的原始信息，为了充分挖掘其价值，能够最大程度地利用信息，需要对其地质资料进行统计、处理、分析操作，对其进行综合分析的过程称为参数预测。通过参数预测，结合油气田的发展和勘探分析的规律，可以有效对其进行科学的探索和研究。近年来，由于地化数据得到了广泛使用，因此

在数据采集和数据处理等阶段都有了很大的提高。如图 3 参数预测步骤所示,通过该方法可以结合地化数据对预测区域进行相应的参数预测。




图 3 参数预测步骤

- (1)预测地区调查。是对预测油区的先行分析,其中不仅仅包含了解该区域的地质情况,同时也需要了解和收集整理地球物理资料,采集该地区的地化数据等先行工作。
- (2)调用地化数据集。对地化数据进行归一化处理之后,能够统一不同单位,不同测量精度上的地化数据,通过统一后对数据统一输入,完成预测。
- (3)建立预测方法。预测方法的设立与参数的预测结果息息相关,预测方法采用 NNFR 的神经网络的模糊推理算法,采用地化数据对储层参数进行预测。
- (4)应用预测方法。相关的专业人员要根据具体情况,即所要预测区域的地化数据,通过 NNFR 的神经网络的模糊推理方法,结合油量轻重的分析图版,应用地化数据的归一化后数据分析集对数据进行操作管理。

(5)综合分析。由于地化数据的复杂性、参数的预测结果多样性和分析方法自身的多解性,并且在分析的同时还要考虑环境噪声的影响,因此需要对每一个问题都进行具体的调研、分析与对比后才能最终得出结论。

3 应用实例与结果分析

为了验证所建立模型的正确性,需要对所收集的数据进行结果验证与分析。表 1 为某油田的地化数据一览表。该表为该地区的原始数据,根据该表可确定储集层的含油判别标准,含油层( $P_c > 5, S_{1\text{比值}} > 20$ )和非产油层( $P_c < 5, S_{1\text{比值}} < 20$ )。通过在表 1 中 7 口井 12 个试油井的井段数据井进行测试与验证,得出的验证数据结果如表 2 所示。其准确率达到了 90% 左右,证明了该方法在地化解释中是有效的。

4 结束语

文中通过分析近年来对储层预测上的研究不断深入带来的难度,以及神经网络与模糊推理各自的不足之处,提出了基于 NNFR 神经网络的模糊推理理论<sup>[13-14]</sup>。并在数据集的归一化处理上进行了深入的研究和分析,总结出适用于地化数据的四种归一化方法,便于理论模型的验证,同时通过具体的实验和数据对预测结果进行了分析和比较,证实方法是可行的。

表 1 某油田地化数据一览表

序号	井号	井段	地化录井参数							试油结果			
			$S_1$ 基值	$S_1$ 储集层	$S_1$ 比值	$S_2$ 基值	$S_2$ 储集层	$S_2$ 比值	$\frac{S_2\text{比值}}{S_1\text{比值}}$	$P_c$	含水因子	日产油	日产水
1	M162	2 084.9 ~ 2 089.4	0.06	8.27	139	0.22	4.60	21.90	0.17	14.02	2.55	34.90	0
2	M167	2 137.3 ~ 2 142.8	0.07	9.10	132	0.23	3.62	16.39	0.11	14.26	5.51	33.01	0
3	M163	2 143.8 ~ 2 147.5	0.07	5.85	84	1.31	3.55	2.68	0.03	20.30	4.66	44.30	0
4	J33	1 645.3 ~ 1 649.7	0.15	4.06	27	0.13	1.52	11.60	0.44	6.68		1.62	3.2
5	J33	1 671.7 ~ 1 675.2	0.15	4.00	27	0.13	1.55	11.85	0.44	6.17		7.91	0
6	J33	1 787.2 ~ 1 798.2	0.07	1.87	27	0.18	1.71	9.50	0.36	3.95		5.19	0
7	M164	1 805.8 ~ 1 815.2	0.06	4.14	83	0.21	1.98	9.86	0.12	6.63	6.13	13.42	0
8	Z10	2 136.9 ~ 2 142.3	0.11	5.52	50	0.41	2.58	6.24	0.12	8.95	5.12	10.52	0
9	J34	2 088.9 ~ 2 095.4	0.29	1.95	7	0.43	2.67	6.15	0.92	4.98		油花	3.1
10	J35	1 777.7 ~ 1 782.5	0.07	6.63	95	0.16	2.20	14.67	0.15	9.50	4.11	10.02	0
11	M180	2 113.9 ~ 2 119.4	0.17	12.11	71	2.55	5.24	2.05	0.03	18.95		24.91	0
12	Z161	2 041.8 ~ 2 049.6	0.05	4.31	84	0.12	2.36	21.62	0.25	7.21		12.35	0
13	F12	1 722.1 ~ 1 731.2	0.08	2.00	25	0.26	0.61	2.35	0.09	2.91	68.21	油花	16.2
14	F12	2 183.6 ~ 2 186.3	0.08	5.13	63	0.16	2.37	14.82	0.23	8.25	9.25	0	0



表 2 验证数据表

序号	井号	井段	地化录井参数										NNFR 预测 结论	试油结果	
			$S_1$ 基值	$S_1$ 储集层	$S_1$ 比值	$S_2$ 基值	$S_2$ 储集层	$S_2$ 比值	$\frac{S_2\text{比值}}{S_1\text{比值}}$	$P_c$	含水因子	日产油		日产水	
1	M162	2 084.9 ~ 2 089.4	0.06	8.27	139	0.22	4.60	21.90	0.17	14.02	2.55	水层	油花	3.11	
2	M167	2 137.3 ~ 2 142.8	0.07	9.10	132	0.23	3.62	16.39	0.11	14.26	5.51	含水油层	0.61	0.79	
3	M163	2 143.8 ~ 2 147.5	0.07	5.85	84	1.31	3.55	2.68	0.03	20.30	4.66	油层	4.28	0	
4	J33	1 645.3 ~ 1 649.7	0.15	4.06	27	0.13	1.52	11.60	0.44	6.68		水层	油花	6.72	
5	J33	1 671.7 ~ 1 675.2	0.15	4.00	27	0.13	1.55	11.85	0.44	6.17		水层	油花	7.30	
6	J33	1 787.2 ~ 1 798.2	0.07	1.87	27	0.18	1.71	9.50	0.36	3.95		水层	油花	7.30	
7	M164	1 805.8 ~ 1 815.2	0.06	4.14	83	0.21	1.98	9.86	0.12	6.63	6.13	油层	21.36	0	
8	Z10	2 136.9 ~ 2 142.3	0.11	5.52	50	0.41	2.58	6.24	0.12	8.95	5.12	油层	1.02	0	
9	J34	2 088.9 ~ 2 095.4	0.29	1.95	7	0.43	2.67	6.15	0.92	4.98		油层	油花	3.6	
10	J35	1 777.7 ~ 1 782.5	0.07	6.63	95	0.16	2.20	14.67	0.15	9.50	4.11	含水油层	油花	5.2	
11	M180	2 113.9 ~ 2 119.4	0.17	12.11	71	2.55	5.24	2.05	0.03	18.95		含水油层	油花	5.2	
12	Z161	2 041.8 ~ 2 049.6	0.05	4.31	84	0.12	2.36	21.62	0.25	7.21		水层	0	2.0	
13	F12	1 722.1 ~ 1 731.2	0.08	2.00	25	0.26	0.61	2.35	0.09	2.91	68.21	油水同层	5.20	1.6	
14	F12	2 183.6 ~ 2 186.3	0.08	5.13	63	0.16	2.37	14.82	0.23	8.25	9.25	油层	12.01	0	

参考文献:

[1] 录井技术编辑部. 录井技术文集[M]. 北京:石油工业出版社,2003:152-167.

[2] Hornik K, Stinchcombe M, White H. Multilayer feedforward networks are universal approximator[J]. Neural Computing, 1990,2:210-215.

[3] Jenkins B K, Tanguay A R. Optical architectures for neural network implementation, handbook of neural computing and neural network[M]. Boston:MIT Press,1995.

[4] 赵振宇. 模糊理论与神经网络的基础与应用[M]. 北京:清华大学出版社,1996.

[5] Li C H, Lin C T, Kuo B C, et al. An automatic method for selecting the parameter of the RBF kernel function to support vector machines[C]//Proc of IEEE international geoscience and remote sensing symposium. Honolulu: IEEE, 2010:836-839.

[6] 吴 馨. 基于粗糙集的证据融合方法研究[D]. 长沙:中南大学,2010.

[7] 地质监督与录井手册编辑委员会. 地质监督与录井手册[M]. 北京:石油工业出版社,2001.

[8] 肖辞源,朱白文. 综合多种地震信息预测油气富集区的模糊数学方法[J]. 石油地球物理勘探,1990,25(2):191-200.

[9] 刘爱锋. 测井资料归一化方法探讨[J]. 中国石油大学胜利学院学报,2008,22(2):14-16.

[10] 程 淑,桂 林,冀 航. 主观评分的归一化算法及误差分析[J]. 高等函授学报:自然科学版,2007,20(5):28-30.

[11] Duda R O, Hart P E, Stork D G. Pattern classification[M]. 2nd ed. Beijing:China Machine Press,2003.

[12] 黄德双. 神经网络模式识别系统理论[M]. 北京:电子工业出版社,1996.

[13] 陆星宇,何 鹏,唱江华. 基于模糊神经网络的电梯群控系统调度方法研究[J]. 计算机技术与发展,2008,18(1):220-222.

[14] 何星星,孙德山. 模糊神经网络与 SARIMA 结合的时间序列预测模型[J]. 计算机技术与发展,2008,18(8):61-64.

基于NNFR神经模糊推理的储层参数识别与评价

作者:

张方舟, 张媛媛, 金宗泽, 邱露露, 宋经纬, ZHANG Fang-zhou, ZHANG Yuan-yuan, JIN Zong-ze, QIU Lu-lu, SONG Jing-wei

作者单位:

东北石油大学 计算机与信息技术学院, 黑龙江 大庆, 163318

刊名:

计算机技术与发展 

英文刊名:

Computer Technology and Development

年, 卷(期):

2015(6)

引用本文格式: 张方舟. 张媛媛. 金宗泽. 邱露露. 宋经纬. ZHANG Fang-zhou. ZHANG Yuan-yuan. JIN Zong-ze. QIU Lu-lu. SONG Jing-wei 基于NNFR神经模糊推理的储层参数识别与评价[期刊论文]-计算机技术与发展 2015(6)