

行政院國家科學委員會專題研究計畫成果報告

灰關聯分析與類神經網路於電測分析上的綜合應用

Well logging Interpretation by Neural Network and Grey Relation

計畫編號：NSC 89-2211-E-041-011

執行期限：88年8月1日至89年7月31日

主持人：張峻彬 嘉南藥理學院 資訊管理系

一、中文摘要

本研究是利用灰關聯分析與兩組類神經網路發展出一套自動選取與整合不同的井下電測資料進行地層參數預測分析模式。透過灰色關聯分析，可了解在分析不同的地層特性參數之下，於眾多可供分析使用的電測資料之中，根據灰關聯度的觀點，挑選出適合使用於特定地層特性參數資料之數組井下電測種類資料，以供倒傳遞類神經網路分析模式使用。透過本研究建立的兩組類神經網路可經由特定電測資料的輸入，預測地層的特性參數。

關鍵詞：灰關聯分析；類神經網路；井下電測分析

Abstract

The purpose of this study is to develop a computer model combined with grey relation and two set of neural network to analyze and integrate well logging data to obtain formation parameters around the well. To gain a specific formation parameter, the kinds of well logs which are suitable as input of neural network will be chosen with the help of grey relation. The neural network we have built can be used to integrate and analyze the different kinds of well logging data to obtain the formation parameters in particular depth.

Keywords: Grey Relation; Neural Network; Well logging Analysis

二、緣由與目的

在石油與地下水的工程與應用之中，常利用井下電測資料(well logging)分析推算井孔附近的地層特性參數。井下電測的好處為操作簡便、不必採岩心、依據深度連續地取得資料，是目前了解地層特性參數一重要工具。經由多種井下電測資料的組合可估算井孔附近的地層特性參數(例如，孔隙率，滲透率，含水飽和度，地層水電阻與地層真電阻及岩性等資料)，電測資料的分析在國內外的石油界與地下水工程中已行之有年了(林再興等，1996；Asquith and Gibson, 1985；Chapellier, 1992；Hallenburg, 1984)。

井下電測是一個很有效的地層特性分析工具，但是由於地層的複雜性以及井下電測資料本身

所含有的雜訊，通常工程師或地質師要花費相當多的時間去分析及解釋一口井的井下電測的資料，而且這些由工程師利用井下電測資料所解釋出的結果通常含某種程度的主觀性。為了增加分析電測資料的速度與準確性，有許多的研究便利用專家系統(expert system; Startzman and Kuo, 1996)及類神經網路(neural network)進行井下電測的分析。

在許多不同類型的類神經網路模式中，倒傳遞(back propagation)類神經網路是其中最具代表性、也是應用最廣的學習模式(Chester, 1993)。在倒傳遞類神經網路中，對於所處理的資料間相關性(輸入值與目標輸出值間的關係)並不需要在分析之前就知，因為類神經網路會透過訓練(training)的方式自動地找出資料點間的關係，因此利用類神經網路去做井下電測資料的分析，尋找電測資料與地層特性間(滲透率、岩相等)的複雜相關性是一個相當合適的方式。目前利用類神經網路分析井下電測資料有幾個主要的應用：地層滲透率的估計(Wong et al., 1998; Mohaghegh et al., 1994);複雜異質性地層的分辨(White et al., 1995; Mohaghegh et al., 1994);不同岩相的分辨(Zhou et al., 1993)等。

一般在建立類神經網路的模式時，使用者常會將所有與模式有關的資料加入類神經網路之中，譬如說在利用類神經網路分析電測資料以決定滲透率的研究之中(Wong et al., 1998)，作者便將所有可取得的電測資料均放入模式中，而利用這些參數去建立類神經網路的滲透率估計模式。實際上並不是所有的電測資料都適合拿來分析，因為可能會有一些電測資料是錯誤的(施測時操作缺失)或特性不夠明顯(例如，自然電位電測在施測時若泥漿鹽度與地層鹽度接近時，將會使自然電位變化曲線在砂頁岩間的變化不明顯)而無法用於分析之上。因此依前述方式所建立的滲透率估計模式可能會有問題，因為在類神經網路中，訓練所得到的結果是兩群資料間的相關性，當使用不適當的訓練資料，將可能會得到一個錯誤的相關性(估計模式)；或者是因為多了一些不相關(或關聯性低)的參數，雖然不致於得到錯誤的結果，但卻因參數太多了，而使類神經網路的整體的計算速率下降。為了能在選擇類神經網路的輸入參數之前，能將不適合(關聯性低)的資料種類去除掉，找出各輸入參數與目標輸出值間的關聯性大小，以便去除關聯性低的參數是相當重要的，對於解決此類問題，灰色關聯分析(grey relation)是一相當合適的工具。

灰色理論 (grey system theory) (Deng Ju-Long, 1982) 是一個新興的理論，在此理論中提出一個稱為灰色關聯分析的方法，在此法中提供了分析離散序列間的相關程度的一種測度方式。此分析中定義一個稱為灰關聯度的值來表示兩個序列間的關聯程度的高低(此數值介於 0 與 1 之間)，如果在比較時只有一個參考序列(母序列)時，稱為局部(localized)灰關聯度。由灰關聯度可決定出所有序列的灰關聯序，根據灰關聯序可了解各序列與母序列間關聯程度的高低。此灰關聯序可應用於預先了解類神經網路中輸入值與目標輸出值間的關聯性大小，以便事先篩選出關聯度低的輸入參數值，供建模者參考，適當地去除不合適的參數，以便更加正確地建立類神經網路模式。

本研究的主要目的是利用灰關聯分析與兩組類神經網路發展出一套自動選取與整合不同的井下電測資料進行地層參數預測分析模式。透過灰色關聯分析，可了解在分析不同的地層特性參數之下，於眾多可供分析使用的電測資料之中，根據灰關聯度的觀點，挑選出適合使用於特定地層特性參數資料之數組井下電測種類資料，以供倒傳遞類神經網路分析模式使用。透過本研究建立的兩組類神經網路可經由特定電測資料的輸入，預測地層的特性參數。

三、方法與成果

由於在各種電測是根據各種不同的特性與技術來蒐集地層相關的資料，因此各種電測資料其所代表的物理意義是不同的，這導致各電測資料的大小(scale)與範圍也不一定相同。由於數字的大小與範圍的不同，在比較同一組母序列時(灰關聯分析)會比較難以得到一個客觀正確的結果。為了能得到較客觀正確的結果，使各電測資料在與母序列的相比時，能具有相同的計算基礎，因此需對原始數據進行處理。在灰關聯分析中常使用的數據轉換方法有：

(1) 初值化處理

將數列中的所有的數據均除以第一個數據，而得到一個新的數列。這個新數列表示的是原始數列中不同時刻相對於第一個數列值的倍數值。

(2) 均值化處理與

將數列中的所有的數據均除以本數列的平均值，而得到一個新的數列。這個新數列表示的是原始數列中不同時刻相對於數列平均值的倍數值。

(3) 區間值化處理

將序列中的所有數據化為介於某數字範圍之間的數字，其做法如下：

原序列： $X(1), X(2), \dots, X(n)$

x_{\max} ：序列中的最大值

x_{\min} ：序列中的最小值

所要使用的範圍介於 I_{\min} 至 I_{\max}

新序列為 $Y(1), Y(2), \dots, Y(n)$

$$Y(n) = I_{\min} + \frac{x(n) - x_{\min}}{x_{\max} - x_{\min}} * (I_{\max} - I_{\min})$$

在本研究中針對所有電測資料(包括三組母序列)處理，將數字化為介於 0~1 之間的數值(即正規化 normalize 的意思)。

底下描述本研究中局部灰關聯分析的作法

(1) 將原有的資料區間值化

本精簡報告做為例子之井所用的資料有 14 種不同的電測資料及三個母序列資料(包括頁岩質含量、孔隙率及水飽和度)，這些資料均做區間值化的處理化為介於 0-1 中間的數值(作法如前所述，電測種類與符號意義如附表一)。

附表二

灰關聯序	電測種類	灰關聯度
1	1-LDL	0.85611
2	CNL	0.82291
3	BHC	0.75298
4	1-POT	0.74533
5	SGR	0.74514
6	PEF	0.74382
7	SP	0.7437
8	1-CGR	0.74096
9	1GR	0.73161
10	THO	0.72712
11	ILD	0.72313
12	ILM	0.71845
13	URA	0.71511
14	SFL	0.70592
15	1-BHC	0.68567
16	1-THO	0.67816
17	CGR	0.67771
18	1-SP	0.66407
19	POT	0.64923
20	1-PEF	0.63138
21	1-1GR	0.61804
22	LDL	0.58653
23	1-CNL	0.5847
24	1-ILM	0.57684
25	1-SGR	0.57561
26	1-ILD	0.55138
27	1-SFL	0.51326
28	1-URA	0.50979

附表一

符號	意義
1GR	Gammay Ray
BHC	Sonic
CGR	Uranium-free Gamma
CNL	Compensated Neutron
ILD	Deep Induction
ILM	Medium Induction
LDL	Lithodensity
PEF	Photoelectric
POT	Potassium
SFL	Spherically Focused
SGR	NGS Total Gamma Ray
SP	Spontaneous Pot.
THO	Thorium
URA	Uranium (from NGT)
Vsh	Shale Volumes
POR	Porosities
Sw	Water Saturations

(2) 產生各種電測資料的反轉曲線

產生反轉曲線的方式是直接將數值 1 減去步驟(1)所產生的數值而產生一個新的曲線。此反轉曲線主要是為避免電測資料跟母序列本來有很大的相關性，不過因為曲線變化的趨勢剛好跟母序列完全相反而造成所做出的灰關聯數字很小，因而在選取類神經的輸入序列中沒有選上。

(3) 利用區間化電測資料、反轉區間化資料與三個不同的母序列(水飽和度、頁岩質含量及水飽和度)

找出各電測資料的灰關聯序並排出其關聯性的高性(以孔隙率為母序列, 28 組電測資料為子序列所得到的灰關聯度與排序如附表二, 表中 1-XXX 所表示的意義是 XXX 電測曲線的反轉曲線)。

根據灰關聯序可了解各序列與母序列間關聯程度的高低。由灰關聯序可了解輸入值與目標輸出值間的關聯性大小, 以便供建模者參考, 適當地去除不合適的參數, 以便更加正確地建立類神經網路模式。在本研究中所採用的類神經網路是採用三層架構的倒傳遞類神經網路(5 個輸入層單元, 6 個隱藏層單元及 1 個輸出層單元)。

在一些研究中指出(Lippmann, 1989; Widrow and Lehr, 1990; Wong et al., 1995), 在類神經網路中, 利用輸入參數資料間的差異, 將其相加、相減或是其他的運算組合出一新的參數值(通常會有某特定的物理意義), 做為此類神經網路的輸入值, 將會改善此類神經網路的執行效率, 因此本研究中利用一個類神經網路來組合不同的電測資料產生一新的參數(在本研究中稱組合因子)。

本研究中為了瞭解反轉的電測曲線於灰關聯排序及電測種類的選取中, 會對類神經網路預測的結果所造成的影響, 以及組合因子的使用, 將會對類神經網路預測的結果所造成的影響有所瞭解, 因此將 5 個輸入單元使用 6 個不同的選擇方式:

Case 1

由 28 組資料(包括 14 組電測資料與 14 組反轉的電測資料)中選取 4 組與母序列關聯度最高的資料序列, 另加上一組組合因子(由多個不同的電測資料組合出來的參數)做為類神經網路的 5 組輸入值。

Case 2

由 28 組資料中選取 5 組與母序列關聯度最高的資料序列, 做為類神經網路的 5 組輸入值。

Case 3

由 28 組資料中選取 4 組與母序列關聯度最高的資料序列, 使用這 4 組序列的原始曲線資料(原來的電測資料), 另加上一組組合因子做為類神經網路的 5 組輸入值。

Case 4

由 28 組資料中選取 5 組與母序列關聯度最高的資料序列, 使用這 5 組序列的原始曲線資料(原來的電測資料), 做為類神經網路的 5 組輸入值。

Case 5

由 14 組原始的電測資料中選取 4 組與母序列關聯度最高的資料序列, 另加上一組組合因子做為類神經網路的 5 組輸入值。

Case 6

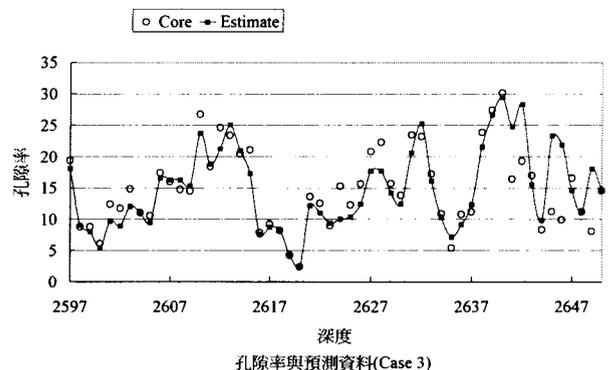
由 14 組原始的電測資料中選取 5 組與母序列關聯度最高的資料序列, 做為類神經網路的 5 組輸入值。

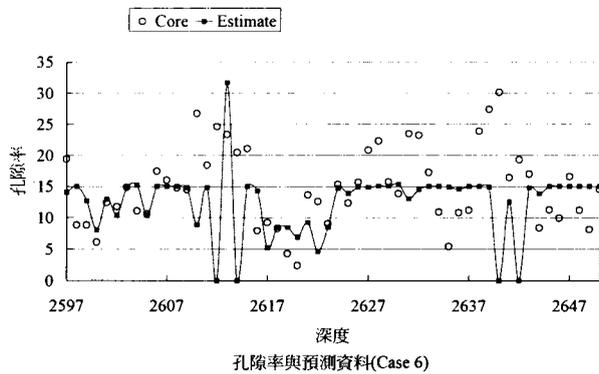
底下為 6 個不同 Case 中, 在完成類神經網路的訓練之後, 以已知孔隙率資料的井之電測資料(此組資料並未用於類神經網路的訓練之中), 來比較由類神經網路估計出的結果與真實值的差異(如附表三)所繪出的圖形(Case 3 與 Case 6)。為了有一個統一的標準來比較各 Case 的優劣區別, 本研究利用類神經網路與真實孔隙率的平方差總和的大小為比較的標準(愈小愈佳)。

由附表三可以看出 6 個 Case 中以 Case 3 所得到的結果最好, 也就是說利用所有正反轉的電測曲線選取 4 組與孔隙率(母序列)關聯度最高的資料序列(1-LDL, CNL, BHC, 1-POT), 使用這 4 組序列的原始曲線資料(原來的電測資料 LDL, CNL, BHC, POT)做為類神經網路預測的 4 個輸入值, 剩下一個輸入值為組合因子(由 SGR, PEF, SP, CGR, 1GR 結合的綜合表現), 這 5 個輸入值所訓練的類神經網路能獲得最佳的孔隙率預測結果。6 個 Case 中以 Case 6 所得到的結果最差, 也就是說不使用反轉曲線, 完全使用原始的電測資料, 以這些電測資料與孔隙率(母序列)關聯度最高的 5 組資料序列(CNL, BHC, SGR, PEF, SP) 做為類神經網路預測的 5 個輸入值所得到的孔隙率預測結果最差。

附表三

	Case1	Case2	Case3	Case4	Case5	Case6
與真實地層參數值(孔隙率)之方差	1522.323	2370.26	722.516	2426.494	1930.356	9201.677
類神經網路1之輸入資料	1-LDL	1-LDL	LDL	LDL	CNL	CNL
	CNL	CNL	CNL	CNL	BHC	BHC
	BHC	BHC	BHC	BHC	SGR	SGR
	1-POT	1-POT	POT	POT	PEF	PEF
類神經網路2之輸入資料(求取組合因子)	組合因子	SGR	組合因子	SGR	組合因子	SP
	SGR		SGR		SP	
	PEF		PEF		1GR	
	SP		SP		THO	
	1-CGR		CGR		ILD	
		1GR		ILM		





四、結果與討論

在本研究之中類神經網路輸入的電測種類之選擇是由灰色關聯分析來主導，也就是在電測種類之選擇上純粹是數值與數值間的關係，完全沒有考慮到各電測種類的基本意義，所以若是能將類神經網路結合專家處理與判斷電測資料的經驗法則，亦即是結合專家系統，應該能得到更加準確的地層特性參數預測值。這些“專家知識”應包括各種電測資料在不同狀況下(岩性、孔隙率，滲透率，含水飽和度，地層水電阻與地層真電阻等)的變化特性，以及如何搭配各種電測資料、各種資料變化狀況而能判定與計算地層特性的法則。

本研究所完成的主要工作包括(1)以灰色關聯分析計算各種電測資料(含反轉電測資料曲線)與母序列(地層特性參數資料)間局部灰關聯度的高低，並藉此數值挑選出與地層特性參數相關度最高的幾組電測資料做為類神經網路的輸入值。(2)建立兩組類神經網路分別用於電測資料組合因子的計算及地層參數預測之用。(3)以局部灰關聯度的高低挑選用於產生組合因子的電測資料。(4)針對各種地層特性參數以六種不同的組合狀況，建立類神經網路的預測模式。(5)比較不同的組合狀況所得預測模式的分析結果。(6)利用已知地層特性參數的電測井資料，做為類神經網路的訓練範例，於訓練完成，以此類神經網路辨識地層特性參數，並利用已知的地層特性參數來驗證預測結果的正確度與可信度。

所完成的地層特性統合分析系統，可讓工程師在取得電測資料後，能在最短的時間內，以最少的人力，將許多口井地層參數(孔隙率、滲透率、水飽和度等)，以最客觀的方式找出，這將對地下水工程或石油工程的相關應用上將會有相當大的助益。

五、參考文獻

- [1] 林再興等，“雲林地層下陷區之地層分層及水文特性之調查研究”，經濟部水利司，1996
- [2] Asquith, G., and Gibson, C., Basic well Log Analysis for Geologists, Methods in Exploration Series, AAPG, Tulsa, Oklahoma (1985)
- [3] Chapellier, D., Well Logging in Hydrogeology, A. A. Balkema publishers, Brookfield, VT (1992)
- [4] Chester, M., Neural Networks: A Tutorial, PTR Prentice Hall, New Jersey, 1993
- [5] Deng Ju-Long, “Control Problems of Grey System,” System & Control Letters, vol.1, no.5, 288-295, 1982
- [6] Hallenborg, J. K., Geophysical Logging for Mineral and Engineering Applications, PennWell Publishing Company, Tulsa, Oklahoma (1984)
- [7] Lippmann, R. P., “Pattern Classification Using Neural Networks,” IEEE Communication Magazine (1989) 27, No. 11, 47
- [8] Mohaghegh, S. et al., “Design and Development of an Artificial Neural Network for Estimation of Formation Permeability,” Petroleum Computer Conference 1994, SPE, Richardson, TX, USA, 147-154 SPE 28237
- [9] Mohaghegh, S. et al., “A Method Approach for Reservoir Heterogeneity Characterization Using Artificial Neural Networks,” Annual Technical Conference & Exhibition 1994, SPE, SPE 28394
- [10] Startzman, R. A. and Kuo, T. B., “Rule-Based System for Well log Correlation,” Expert Systems in Engineering Applications SPE Reprint Series n.41 1996 120-128
- [11] White, A. C. et al., “The Application of ANN for Zone Identification in a Complex Reservoir,” Eastern Regional Conference & Exhibition 1995, SPE, SPE 30977
- [12] Widrow, B. and Lehr, M. R., “30 Years of Adaptive Neural Networks: Perception, Madeline and Back propagation,” Proc. Of IEEE (1990) 78, No. 9, 1415
- [13] Wong, P. M., Gedeon, T. D. and Taggart, I. J., “An Improved Technique in Porosity Predictions: A Neural Network Approach,” IEEE (1990) Trans. on Geoscience and Remote Sensing (1995) 33, No. 4, 971
- [14] Wong, P. M., Henderson, D. J. and Brooks, L. J., “Permeability Determination Using Neural Networks in the Ravva Field, Offshore India,” SPE RE, (April 1998) 99-104
- [15] Zhou, C. D., Wu, Xi-Ling and Cheng, Ju-An, “Determining Reservoir Properties in Reservoir Studies Using a Fuzzy Neural Network,” Annual Technical Conference & Exhibition 1993, SPE, SPE 26430