

## 基於類神經網路與粗集合理論的系統識別—以網路問卷系統為例

陳明華<sup>1</sup>、周郁文<sup>2</sup>

<sup>1,2</sup> 嶺東科技大學 資訊管理研究所

<sup>1</sup> mhc@teamail.ltu.edu.tw

<sup>2</sup> vivian198715@yahoo.com.tw

### 摘要

本研究結合類神經網路與粗集合理論之知識約簡技術提出一稱為 BPNRSAR 之整合方法，此方法可針對多重輸入與多重輸出之網路問卷系統進行系統參數識別。所提 BPNRSAR 整合方法，以網路問卷進行測試，此網路問卷有 54 道問題及 12 個輸出值。經測試得知，對問卷 12 個輸出值有影響之因子不是 54 道問題之答案，而是 54 道問題之選項答案，也即此問卷以系統觀點來看，應有 216 個輸入屬性(每道問題有 4 個選項)。進一步以 BPNRSAR 進行測試，可成功識別出此問卷系統中之影響權重。**關鍵字：**系統識別、類神經網路、粗集合理論。

### Abstract

This study is to propose a consolidated methodology, so-called BPNRSAR, to identify the system parameters in the website survey system of multi-inputs and multi-outputs. This methodology is a knowledge reduction technique by combining the neural network and rough set theory. Above consolidated methodology, BPNRSAR, is tested using website survey data of right brain vs left brain creativity test which survey includes 54 questions and 12 outputs values. The results indicate that the 12 output values are not affected by the survey answers of those 54 questions, but the answer choices of these questions, i.e., 216 input attributes from 4 choices corresponding to each questions in the 54 questions survey. Using BPNRSAR, it could not only further successfully identify answer choice related to each output attribute in the survey system, but also correctly give the influential weights for each answer choice.

**Keywords:** System Identification, Neural Network, Rough Set Theory.

### 1. 前言

目前類神經網路常應用於路徑最佳化、辨識與分類、預測及評估與決策方面，而本研究透過此方法探討人類左、右腦，並利用粗集合理論、系統識別、屬性簡約等，來計算出人類左、右腦模式識別。粗集合理論是在 1982 年由 Pawlak 所提出，是

種新的數學方法，用來對不精確、模糊、不確定的資料進行分析，應用層面廣泛，涵蓋醫學工程、製程管理、財務工程等[4]。

系統識別為建立模型之一種技巧，它是利用統計理論分析系統產生之量測做為估測系統之參數，進而建立系統之模型。其系統識別可依對結構系統描述分為及非參數識別。所謂參數識別可分為時間域系統識別與頻率域系統識別。而非參數識別則是對系統不作任何物理或數學模型之假設，僅在已知的輸入和輸出資料之間，以一些合適的數學函數來表示系統的輸入與輸出間之關係，如利用類神經網路作非參數的系統識別，只要給予欲求解之相關問題數據資料作為訓練用輸入值，通常即可經由類神經網路求取輸入與輸出之映射(mapping)關係，進而得到一組可用以預測其他新數據的類神經網路權重值架構[9]。

而屬性約簡是指在保持信息系統的分類或決策能力不變的條件下，刪除其中的冗餘屬性。目前很多屬性約簡算法都是基於區分矩陣或在此基礎上進行改進的[5]。

類神經網路之研究已有 50 年的歷史，但實際應用為近 15 年來才開始，目前仍在迅速發展中。同時，類神經網路研究領域以成功地應用於控制系統之最佳化領域中。Rosenblatt (1957) 提出第一種神經網路模式-感知機(Perceptron)模式，它由二元值神經元組成，以此模仿生物的大腦及視覺系統，主要用於理論研究與樣本識別。Widrow 和 Hoff(1960) 提出自適應線性元件(Adaptive Linear Element)模式，它是一種連續值的線性網路。Rumelhart(1985) 提出著名的到傳遞類神經網路模式(Back-Propagation Network)，此網路模式之基本原理是利用最陡坡降法(Gradient Steepest Descent Method)的觀念，將誤差函數予以最小化。Kohonen(1980) 提出組織映射圖(Self-Organizing Map)模式，並且在 1988 從該模式衍生出學習向量量化網路(Learning Vector Quantization Network)。Hinton 和 Miller(1988) 對霍普菲爾-坦克神經網路在解決最佳化問題時，其收斂最小值和參數設定等問題加以改善。Barnard(1992) 探討訓練類神經，網路值目標函數最佳化之各種方法，並提出一個以隨機的觀念所建立的序列演算法。Hagan 和 Menhaj(1944) 根據 Kollias 和 Anas tassiouh 所建議的概念，提出改良式倒傳遞演算法，此法將應用與非線性最小平方法的李蒙博格-馬可渥得特演算法，配合傳統倒傳遞演算法來訓練前向式類神經網路。Flood 和 Kartam(1994) 提出將類神經網路應用於土木工程上

的明瞭性、使用性以及實用性方面的論述，並利用倒傳遞前向式網路訓練，來解決結構分析問題。Narendra 和 Parthasarathg(1990)曾驗證類神經[2]。

## 2. 研究相關理論與方法

### 2.1. 類神經網路

類神經網路(Artificial Neural Network, ANN)是利用大量的類神經元來模擬人腦，如圖1所示。每個類神經元可以接受外界輸入，再經由活化函數將所受到的刺激輸出至下一層，由多個神經元組成一個網路層，再由數個網路層架構出一個完整的類神經網路。

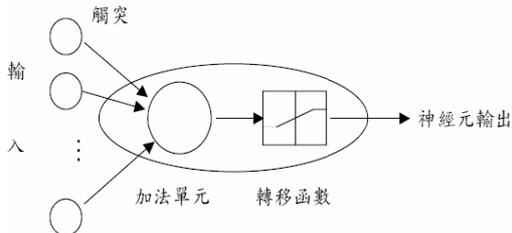
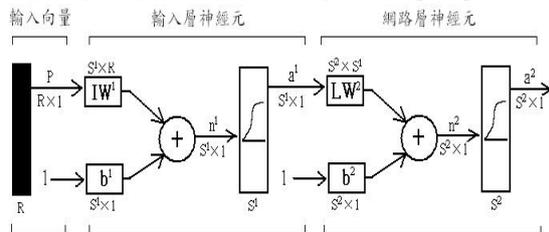


圖 1 神經元模型

### 2.2. 倒傳遞網路(BPN)

倒傳遞類神經網路 (Back-Propagation Network, BPN)為一種實際被用來訓練多層前向式類神經之演算法。

而一個倒傳遞網路包含許多層，每一層包含若干個處理單元，如圖2所示。其處理單元的個數視問題而定，使用的是非線性轉換函數[4, 5]。



兩層BP神經網路模型

圖 2 倒傳遞神經網路模型

BPN 學習完成後，其網路內部儲存之權值可進一步結合 Garson(1991)之研究，分析各輸入參數對應於某依輸出參數之相對重要性(Relative Importance, RI)，其計算式如下[3]：

$$RI = \frac{\sum_j^{n_h} \left[ \frac{I_{vj}}{\sum_k^{n_v} I_{vj}} \right]}{\sum_i^{n_v} \left[ \sum_j^{n_h} \left[ \frac{I_{vj}}{\sum_k^{n_v} I_{vj}} \right] O_j \right]}$$

$n_h$ ：隱藏層神經元總數。

$n_v$ ：輸入層神經元總數。

$v$ ：第  $v$  個輸入層的神經元，亦即第  $v$  個輸入參數。

$j$ ：第  $j$  個隱藏層的神經元。

$I_{vj}$ ：第  $v$  個輸入層的神經元與第  $j$  個隱藏層的神經元間之值，以絕對值表示。

$O_j$ ：第  $j$  的隱藏層的神經元與輸出層的神經元間之權值，以絕對值表示。

### 2.3. 粗集合理論

粗集合理論中使用決策表來描述論域中對象。它是一張二維表格，其行描述一個對象，列描述對象的一種屬性。屬性分為條件屬性和決策屬性，論域中的對象根據條件屬性不同，被劃分至不同決策屬性的決策類。信息系統約簡主要是使信息量減少，在不影響其原有的決策功能之原則下，將一些無關或多餘的信息忽略掉。其約簡後的信息重新組合而產生新的決策規則，這類決策規則的前提信息和結論信息可能不同於約簡前的任何一條決策規則，但它們能經推理而得到相同或相近的結果。因此這樣的研究成果對數據挖掘以及數據庫的進一步應用將產生新的影響[11]。

## 3. 研究數據

本研究使用的是一份『左右腦使用傾向』的英文網路問卷，當答題者把54道問題作答完，能即時將12項腦部傾向適性分析顯示出來。

本研究共發放600份問卷，回收並剔除填答不完全或不適用之無效問卷後，有效問卷為496份。其表1是將問卷 Output 做簡單的翻譯及簡寫。

表 1 問卷輸出對應表

原文	中文	簡寫
Linear	直線性	Lin
Sequential	連續性	Seq
Symbolic	圖象性	Sym
Logical	邏輯性	Log
Verbal	言辭性	Ver
Reality-based	現實性	Rea
Holistic	全面性	Hol
Random	隨機性	Ran
Concrete	具體性	Con
Intuitive	直覺性	Int
Nonverbal	非言語性	Non
Fantasy-oriented	幻想性	Fan

## 4. 討論與結果

### 4.1. 倒傳遞網路測試

本研究有兩種不同的輸入方式，第一種是題號

的方式，有54個輸入變數；第二種是選項的方式，有216個選項。先以題號的方式做訓練比較，以12項輸出指標(54:12)、6項輸出指標(54:6)、1項輸出指標(54:1)做比較。首先先以54個輸入變數做比較，其結果如表2，當R值越大時，表示相關性越高，反之則越低，由表2可看出Log(54:1)，其R值相較於前兩者高，但距期望值依然有段差距。接下來將輸改成為216個選項(例：原本為1就轉為1000、2轉為0100，依此類推)，分別以12項輸出指標(216:12)、6項輸出指標(216:6)、1項輸出指標(216:1)做訓練績效圖之比較，可發現Log(216:1)，其R值比前兩者高，且相當接近於期望值1。由表2可發現兩種輸入方式之R值，都是以單一輸出指標時較高，且選項之R值也相較於題號之R值高，由此推斷，輸入變數為選項時，應是問卷系統的確切輸入模式，而輸入變數為題號時，應為虛假輸入模式。

表 2 Log 題號與選項訓練後 R 值比較表

	54 題號	216 選項
12 輸出指標	0.418	0.439
6 輸出指標	0.562	0.844
單一輸出指標	0.629	0.949

#### 4.2. 敏感度分析

接下來利用權重值做敏感度分析(sensitivity analysis)，取得相對重要性(RI)，再對RI值做由小而大的排序(sort)，畫出相對重要性排序圖，輸出變數以Log為例，結果如圖3至圖5。

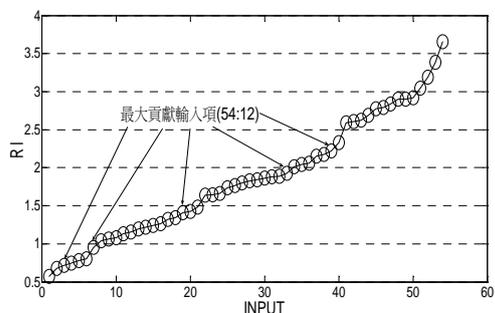


圖 3 Log(54:12)相對重要性排序圖

表3已將RI值做排序，把表3的題號與圖3做比對，發現在第5與第6輸入項之間有一段明顯的差距，將差距前的輸入項分成一群，也就是Log貢獻度為9的5個最大貢獻輸入項，但未能將次大貢獻輸入項做分群。

而圖3和圖4並未有明顯的落差，而且在經過比對後，最大貢獻輸入項的確未能顯示於圖中。接下來一樣也對選項做相對重要性排序，測試是否能找出所有的貢獻輸入項。

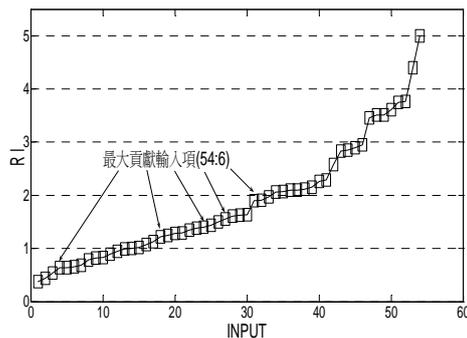


圖 4 Log(54:6)相對重要性排序圖

表4為Log(216:1)的RI值排序表，表中顯示前19項RI值的題號與選項，和Log所有貢獻項的題號與選項相同，且前五項也正是最大貢獻輸入項(貢獻度為9)，而第6到第19項次大貢獻輸入項(貢獻度為5)；由圖6可知，確實能將最大與次大貢獻輸入項做分群。

與表5做比較，發現Log(216:1)的RI值經排序後，能將最大貢獻輸入項與次大貢獻輸入項做分群。

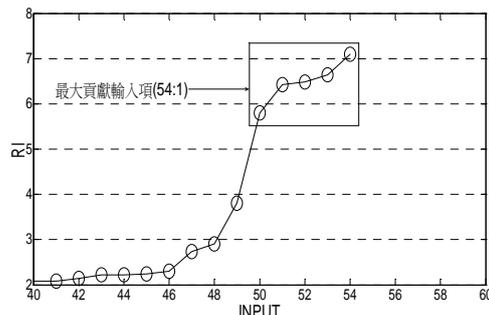


圖 5 Log(54:1)相對重要性排序圖

表 3 Log(54:1)相對重要性排序表

題號	51	10	24	43	36	31	7
RI 值	7.0925	6.6366	6.4874	6.422	5.7986	3.8056	2.9074
題號	2	50	18	29	27	5	4
RI 值	2.7347	2.2995	2.238	2.2233	2.2229	2.1448	2.0841

表 4 Log(216:1)相對重要性排序表

題號	24	51	10	43	36	39	40	50	31	48
選項	1	1	1	1	1	2	2	3	2	2
RI 值	0.918	0.917	0.852	0.851	0.834	0.725	0.702	0.691	0.685	0.682
題號	6	29	17	15	1	44	3	54	2	23
選項	2	2	3	3	3	2	2	3	2	3
RI 值	0.679	0.678	0.673	0.662	0.657	0.647	0.644	0.631	0.62	0.575

表 5 Log 題號與選項比較表

	54:1	216:1
最大貢獻輸入項	5/5(正確分群)	5/5(正確分群)
次大貢獻輸入項	4/14(未能分群)	14/14(正確分群)

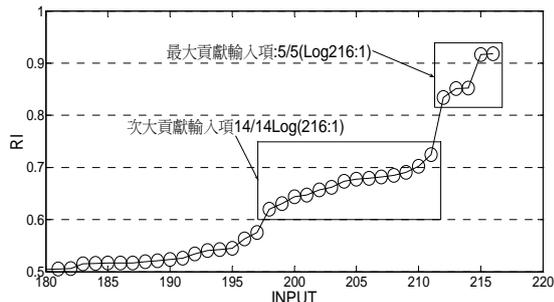


圖 6 Log(216:1)相對重要性排序圖

### 4.3. 屬性約簡

現在將12種目標屬性，經過 sort 分群找出最大與次大貢獻輸入項，先暫時對各目標屬性有貢獻項之數量簡稱為  $N_i$ 。

接下來對貢獻度大之條件屬性與冗餘條件屬性進行屬性約簡(Attribute Reduction, AR)，做型1誤差(omission error)與型2誤差(commission error)之分析比較。

由圖7可以清楚看出，當  $N_i$  越小型1誤差下降越快，及  $N_s$  增加也能下降型1誤差，所以不論  $N_i$  多寡，只要  $N_s$  增加，就可減少型1誤差的漏判行為。

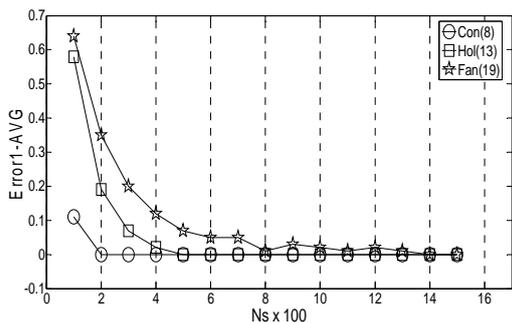


圖 7 型 1 誤差比較圖

由圖8可見，當  $N_i$  大於17時，型2誤差有了明顯的上升，且增加  $N_s$  數量也無法下降。

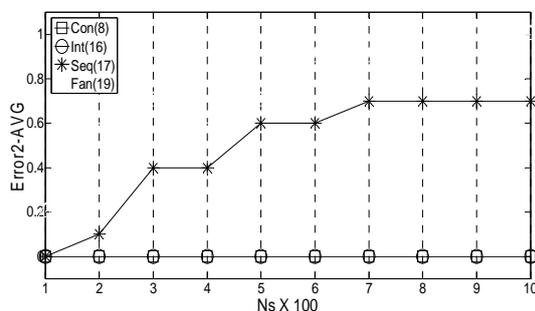


圖 8 型 2 誤差比較圖

由圖9與圖10比較，發現此問卷系統的數值實驗，做屬性約簡時，在  $N_i$  小於16時，可以正常的發揮判斷功能，但  $N_i$  大於17時，型2誤差會出現異常的情形。

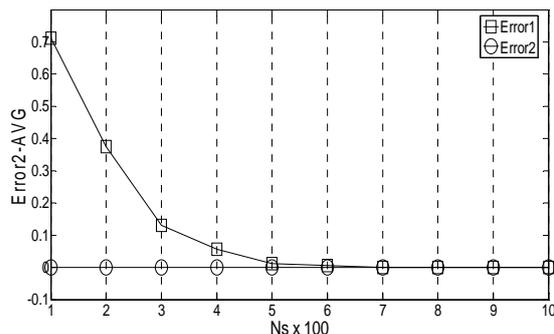


圖 9 型 1 型 2 誤差比較圖(Int)

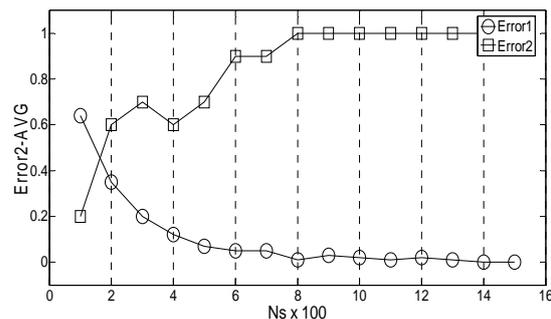


圖 10 型 1 型 2 誤差比較圖(Fan)

### 4.4. 線性迴歸分析

#### 一、相對誤差值

經過屬性約簡確認後，所得結果可能為系統確切輸入變數(Exact Input Variable, EIV)，接下來將 EIV 重新以 BPN 做訓練，將 R 值與前次相關之 R 值做比較，計算相對誤差值。

表 6 相對誤差值統計表

左腦	Lin	Seq	Sym	Log	Ver	Rea
$ \Delta R $	0.014	0.015	0.011	0.015	0.012	0.017
R	0.997	0.999	0.998	0.999	0.998	0.999
$ \Delta R /R$	0.01404	0.01502	0.01102	0.01502	0.01202	0.01702
右腦	Hol	Ran	Con	Int	Non	Fan
$ \Delta R $	0.014	0.013	0.019	0.015	0.013	0.019
R	0.999	0.999	0.996	0.998	0.999	0.999
$ \Delta R /R$	0.01401	0.01301	0.019	0.01503	0.01301	0.01902

由表6的相對誤差值皆小於0.03，則表示無法進一步改善訓練準確性，此時則跳出迴圈，接下來判斷系統是線性或是非線性的。

#### 二、線性迴歸

首先就上步驟之系統做線性多重迴歸(Linear Multiple Regression, LMR)，以所得 LMR 係數與此時之 RI 做相關性測試，所得相關性  $R(RI, LMR)$  若大於某個門檻值  $r$  (如  $r > 0.9$ )，則可判定系統為線性系統，此時之 RI 值即為本研究系統之模式係數；如果  $R(RI, LMR) < r$  則系統為非線性的，雖不能得

出確切映射關係，卻可得出系統之關鍵輸入變數 (Key Input Variable, KIV)。

#### 4.5. 系統識別

基於以上數值實驗的結果，本研究提出一整合方法，此方法可結合類神經網路與粗集合理論知識約簡之優點，針對多重輸入與多重輸出之問卷系統，進行屬性約簡與系統識別。

本研究之系統識別流程如圖11所示，首先將 IOP 以 BPN 做十次訓練，得出敏感度分析的 RI 平均值，此 RI 平均值幾乎可以將輸入屬性之相關貢獻度做出正確估計。

接下來要挑出進行屬性約簡的候選屬性數目，挑選方式分成兩階段，第一階段先消除小於總貢獻度之平均值的條件屬性，再將留下來的條件屬性做第二階段 SOM 分群。

第二階段需要將分群後的條件屬性數目，大於目標屬性對總條件屬性的平均數目，先由最大一群的條件屬性數目與平均數目做比較，如果條件屬性數目未超過平均數目，則再加入次大的一群條件屬性數目，直到數目超過平均數目為止。而這群數目的條件屬性，即進一步做屬性約簡的最終候選屬性，找出這群最終候選屬性的目的，是為了提高屬性約簡的準確度。

接下來進行首次屬性約簡，但為避免首次屬性約簡的過程中，有其他關鍵的條件屬性被排除在外，於是在對首次屬性約簡被排除在外的條件屬性，逐一加入進行第二次屬性約簡，經測試所得結果的確能夠把冗餘的條件屬性消除，留下關鍵的條件屬性，其過程與結果之重要數據，如表7所示。

表7顯示，12個目標屬性中，有9個目標屬性 (Lin、Sym、Ver、Rea、Hol、Ran、Con、Int、Non) 能夠正確的得出其確切條件屬性，其型1與型2誤差皆為0；但有3個目標屬性 (Seq、Log、Fan)，無法順利得出其 KIV，其型1誤差為0，但型2誤差為1，此結果與之前之數值實驗結果相符，造成此結果之原因並不明確，但可以推測其結果與條件屬性數目有關，當條件屬性數目大於17時，此問卷系統利用本研究提出之整合方法，無法得出確切條件屬性。

雖然本研究流程雖能順利找出問卷系統之 KIV，但必需是在兩點條件限制之下才能夠完成：1、輸出目標間需互相獨立。2、條件屬性為選項之方式。3、Ni 不可超過17個。

表7顯示，共有12個目標屬性，每個目標屬性分別為1個 Case，之前提到有9個目標屬性可以順利找出 KIV，就代表這9個 case 可順利完成，以 Lin 這個 Case 做為解說的例子。

Lin 經 BPN 訓練取得的 RI 值經第一步分群後，留下的初步候選屬性數目有64個，接著再分為5群，每一群的數目分別為：31個、18個、7個、4個、4個，而最右邊為貢獻度最大的一群，依此向左邊逐一遞減，由於分群數目總和需大於總條件屬性與目標屬性之平均數目，其平均數目為18，而第一群的數目只有4個小於18個，所以再加入第二群，加入後也只有8個，一樣小於18個，依此順序不斷加入，直到第4個加入後，共有33個條件屬性數目，符合超過平均值18個數目的條件，所以這33

個條件屬性數目，即為進行屬性約簡的最終候選屬性數目。

當屬性約簡完成，留下來的條件屬性，即為當選屬性數目，且型1與型2誤差皆為0，所以這15個條件屬性數目，即為目標屬性 Lin 的 KIV，再將 KIV 去做 RI 值與 LMR 係數之線性回歸，其相關性 R 值大於0.9，故此 RI 值即為系統之模式係數。

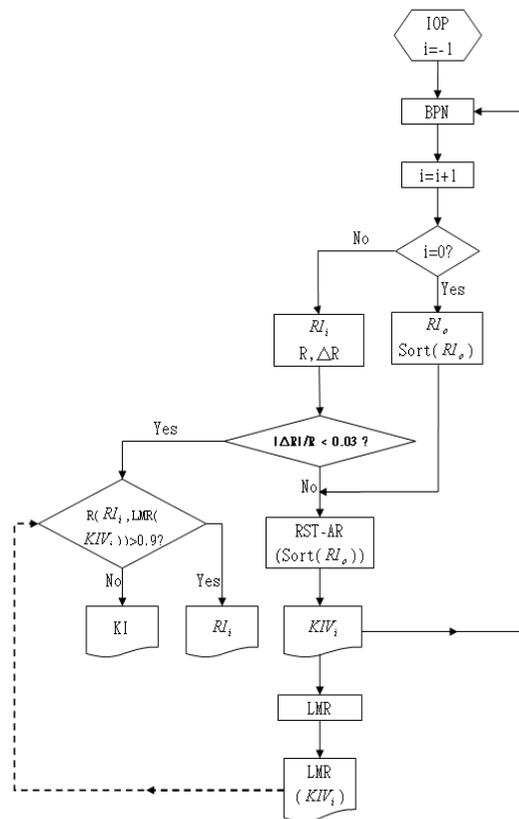


圖 11 系統識別流程图

#### 5. 結論與建議

本研究經分析討論後，提出以下結論與建議：

1. 問卷系統映射關係並非如一般想像為1對1影響關係，而是1對多關係。
2. 由 BPN 訓練績效圖之 R 值可輔助辨識問卷系統之確切輸入模式。
3. BPN 訓練後所得相對重要性 RI 值，可作為 EIV 分群依據，輔助決定出 EIV 之數目。
4. 當系統之 EIV 數目過大時，使用 RST-AR 方法，所得結果之型2誤差會出現不正常跳動變化。且 EIV 數目超過一門檻值後，型2誤差會遽增至100%。型1隨Ns增加而減少，隨 EIV 數目增加欲達相同型1誤差須增加Ns。
5. 本研究所提出之 AR-SI 模式，可針對線性系統找出 KIV，但有以下限制：IOP 為確切值、OP 相互獨立、系統之關聯性關係必須存在、首次屬性約簡須包含系統之所有輸入變數。
6. 可就其它問卷系統與非線性系統做測試，進一步評估本研究所提出之 SI-AR 模式之適用可行性。

## 6. 參考文獻

- [1] D. E. Rumelhart, J. L. McClelland and the PDP Research Group, *Parallel Distributed Processing*, MIT Press, Cambridge, MA, Vol. 1., 1986.
- [2] 卜君平、劉德俞，“隔震橋梁系統識別與類神經網路之應用”，逢甲大學土木工程系碩士論文，2003
- [3] 林大偉，“混凝土火害後強度折減之徑向基類神經網路分析”，朝陽科技大學營建工程系碩士論文，2004。
- [4] 林佑樺、余峻維、陳怡靜、廖子德，“以離散化粗集合理論分析葛拉漢淨資產投資法在台股IC 封測實證”，嶺東科技大學資訊管理系，2008。
- [5] 傅明、陳曦、劉翌南，“基於信息顆粒的粗集約簡研究”，長沙理工大學學報(自然科學版)第一期，2004。
- [6] 萬絢、陳宏杰，“模糊理論應用與實務”，儒林出版，2006。
- [7] 趙育漢，“以類神經網路分析微影覆蓋幾何誤差”，中原大學機械工程學系碩士論文，2003。
- [8] 陳鳳儀，“以多模型自適性遺忘因子法則(AFMM)輔助系統識別應用於振動監測資料之分析”，國立成功大學土木工程研究所碩士論文，2007。
- [9] 張家瑋，“結合類神經網路與基因演算法於系統識別”，朝陽科技大學營建工程系碩士論文，2003。
- [10] 傅心家，“國立交通大學資訊工程系類神經網路研究報告”，2004。
- [11] 薛定宇、陳揚泉，“高等應用數學問題的MATLAB 求解”，清華大學出版社，2004。

表 7 系統識別(AR-SI)過程數據與結果統計表

AR-SI results	Left Brain					
	Lin	Seq	Sym	Log	Ver	Rea
cRI_sort_cdd	64	64	84	57	50	59
Ncluster	5	5	6	5	4	5
class_g	[31 18 7 4 4]	[31 14 11 2 6]	[23 26 11 16 4 4]	[26 10 11 5 5]	[26 13 7 4]	[4 3 10 14 28]
N_RI_elected	33	19	24	31	24	28
cqq	15	19	8	31	11	11
R(RI,LMR(KIV))	0.985	Null	0.987	Null	0.983	0.997
AR-SI results	Right Brain					
	Hol	Ran	Con	Int	Non	Fan
cRI_sort_cdd	45	64	77	49	49	52
Ncluster	4	5	6	4	4	4
class_g	[22 10 9 4]	[28 12 14 4 6]	[32 17 12 8 5 3]	[22 12 10 5]	[27 8 11 3]	[24 11 11 6]
N_RI_elected	23	24	28	27	22	28
cqq	13	12	8	16	13	28
R(RI,LMR(KIV))	0.98	0.981	0.983	0.991	0.982	Null

註解：cRI\_sort\_cdd：初步候選屬性數目；Ncluster：分群數；class\_g：各群個數；

N\_RI\_elected：最終候選屬性數目；cqq：當選屬性數目；R(RI,LMR(KIV))：相關性