

應用柔性演算法於穩健最佳化設計

陳相弦 洪宗仁 余志成*
國立台灣科技大學 機械工程研究所

國科會補助編號：NSC89-2212-E155-019

摘要

田口方法藉由內外直交表配置因子以減少實驗次數，並計算訊噪比來估計輸出變異，以降低產品品質損失。雖然田口方法可使用加成法模式預測設計的最佳參數組合，但若系統為非線性，或是參數間存在交互作用時，會增大最佳設計的預測誤差。此外，田口方法只能用來預測因子水準點上的組合，無法以內插或外插的方式取得最佳組合。本文應用柔性演算法改良田口方法，使用類神經網路學習實驗結果，模擬系統輸入輸出之間的關係，以突破田口方法在非線性問題上的限制。再使用基因演算法搜尋模擬曲面上的最佳設計。另外，為避免網路預測離樣本點太遠時不可避免的誤差增加，本文使用模糊系統針對距離學習樣本點的遠近給予不同的信賴度，調整基因演算法的適應函數值，以避免網路預測誤差影響最佳設計的搜尋。而藉由類神經網路模擬系統的功能，將直交表上因子配置的方式重新修改，可大幅降低實驗次數，提高實驗數據分析的效率。

關鍵字：直交表實驗、類神經網路、基因演算法、模糊集合與推論

1. 研究背景

傳統的設計過程，往往忽略了設計與輸出性能不確定性的主動關聯性，這些造成產品性能輸出不穩定的潛在因子稱為設計變異 (Design Variation)，這些變異的產生可能來自製造公差、疲勞劣化與使用環境的不定性，造成控制參數偏離原先設計值。傳統控制變異的方法是採用公差設計，以緊縮製造公差來達成降低輸出誤差的目的，然製造成本亦將隨之增加，而不可控制因子 (Uncontrollable Factor) 的存在，仍會造成輸出性能的不穩定性。由圖 1 可看出參數選擇對輸出誤差的影響性，對於相同的參數分佈，設計參數選定 x_2 時，其輸出分佈範圍較設定於 x_1 的輸出分佈範圍小，也就是說 x_2 的設計對於參數變異具有較小的敏感度，亦即為較穩健的設計。穩健化設計乃運用參數設計，降低輸出性能對參

數變異的敏感度 (Sensitivity)，以不增加成本的方式提昇品質。

參數設計的目的在設計空間中尋找一組最佳參數組合，使得輸出響應滿足限制條件、性能與品質的設計需求。然而，在最佳化過程中，必須取得大量的系統資訊。對於簡易的系統而言，系統的特性可使用理論公式推導或圖表查詢來獲得；但實際工程系統的輸出入關係複雜，再加上參數間的交互作用與關聯性，使得系統的數學模式不易取得，設計者往往需藉助實驗分析或數值分析來獲得系統資訊。但這些方式卻往往需要耗費大量的時間與成本。因此，如何降低實驗次數並有效地模擬系統行為，便成為目前學者關切的焦點。




圖 1 參數選擇與輸出變異關係圖

田口玄一[1] 提出以訊噪比作為性能穩健性的指標，利用實驗直交表進行參數設計，配合因子效應分析與加法模式，推測最佳因子水準組合。直交表為部分因子實驗計畫的一種，用以配置控制因子，其因子水準設定範圍代表搜尋的設計空間，所得的參數組合即為一組可行的設計。同時田口方法可適用在系統模式不明，而須以實驗方式來進行設計，或是離散變數型態的最佳化問題。田口方法雖然可以有效地降低實驗次數，但僅能預測水準化因子的最佳組合，不能內插因子水準間的輸出，同時分析過程對於因子間的交互作用較為敏感，且無法有效處理有限制條件之最佳化問題。

另有學者[2][3]使用響應曲面法 (Response Surface Method, RSM)，使用二階的多項式來模擬系

*聯絡作者：jcyu@mail.ntust.edu.tw

統響應，來取代田口方法的加法模式。但由於 RSM 必須在模擬之前設定系統的數學型態，對於複雜的系統較不具彈性。柔性演算法[8]如類神經網路的興起，打破系統需存在特定數學型態的限制，Cios[4]使用倒傳遞類神經網路來模擬系統輸出，以舊有的實驗資料或現成的參考手冊資料做為訓練樣本，若資料數量不夠或不具代表性時，再增加實驗來補足。Nakajima 等[5] 則建議以直交表實驗結果為樣本，再以全直交表設計不同的初始設計值，用序列二次規劃 (SQP) 在網路模型上搜尋最佳值。Wang 等[6]則提出以直交表上每一列之元素加上其相對應之系統輸出的平均值與變異數，構成一組類神經網路訓練樣本，並結合網路的數學模型進行敏感度分析。另外，對於望目型目標函數的最佳化設計中，也可使用類神經網路的逆向模型[9]，將原始實驗樣本中的輸入與輸出參數對調，訓練完成後的網路模型，即可預測在預期目標輸出時應有的參數組合。

類神經網路由於使用權重矩陣來代表輸入與輸出因子的關係，所以令人不易了解其關係的規則。Sitarama 等[7]藉由全直交表實驗的參數與輸出值模糊化，經過學習之後，便產生新的模糊規則庫。使用模糊近似推論來預測系統輸出，再以基因演算法配合權重計算，進行多目標全域最佳搜尋。

本文發展出一套穩健最佳化策略，提出合併實驗計畫的方式，以減少田口方法中內外直交表實驗次數太多與外直交表製造誤差因子模擬不易等問題。而透過合併直交表實驗訓練類神經網路模型做為系統，以神經網路估計設計之訊噪比，作為穩健化設計品質指標。並提出模糊推論法則推算模擬可靠度，提升搜尋效率，配合遺傳基因演算法尋找穩健最佳設計。

2. 田口類神經網路 (Neural Taguchi Network)

對於複雜的系統，我們常希望藉由實驗或少許模擬的方式研究系統輸出與設計參數間的關係。本文採取田口方法中直交表的觀念，整合控制因子、干擾因子與訊號因子在一個實驗計畫內，再以實驗資料作為訓練樣本，建構局部的類神經網路系統。

2.1 類神經網路

類神經網路始於對生物神經網路內部傳遞的觀察，衍生出的計算觀念。不但具有平行處理與容錯的優點，另外其具有高度的學習能力與非線性對應 (Nonlinear Mapping) 的功能。目前各領域應用最成功的網路是倒傳遞網路 (Back-propagation Network, BPN)，其基本的架構如圖 2 所示，第一層為輸入層、第三層為輸出層，分別代表輸入/輸出參數；中間層

稱為隱藏層，可用來處理參數間的交互作用、關聯性與敏感度等關係。

倒傳遞網路是屬於監督式學習網路 (Supervised learning network)，若要使網路具有預測的能力就要經過學習 (Learning) 與測試 (Testing) 的過程。首先將原始範例分成學習樣本與測試樣本，學習樣本主要是訓練網路單元間的權重矩陣，即圖 2 中的 W_{ij} 與 W_{jo} 。本文訓練的方式使用最陡梯度法。測試樣本則是用來判斷網路預測的準確性與普遍性。

本文採用類神經網路來模擬系統輸出，學習樣本表現對於類神經網路預測品質有關鍵性的影響，為了維持樣本的代表性，提升資料分析的效率，同時減少實驗成本，本文採用田口方法直交表實驗，作為訓練樣本。直交表為部分因子實驗計畫的一種，用以配置控制因子，其因子水準設定範圍代表搜尋的設計空間，所得的參數組合即為一組可行的設計。然後將初始設計與從田口方法的加法模式所預測到的最佳參數水準組合當做測試樣本。訓練後的田口類神經網路，可精確的預測參數水準組合的輸出響應，且參數值不限制在水準點上。且類神經網路可模擬變數之間的交互作用，可避免以田口方法以加法模式 (Superposition Model) 預測輸出值的誤差，造成最佳因子水準時的選擇錯誤。




圖 2 動態型設計中類神經網路範例的輸出入關係

2.2 實驗計畫

田口方法將參數分為四類，其間的關係如圖 3。系統可為產品的設計或是製程的控制，M 代表使用者可控制的期望輸出，而 Y 為實際的輸出值，影響輸出 Y 值的參數則可分為控制 (X) 與干擾 (Z) 因子。田口以內外直交表的實驗方式，並提出訊噪比 (Signal to Noise ratio, S/N) 來量化參數設定對性能輸出的影響。再經由平均值分析 (Analysis of Mean) 以及線性加成法的觀念，預測最佳的參數水準組合，在求取性能最佳化同時降低產品或製程對干擾因子的敏感度。

直交表實驗具有對稱與平衡的優點，對於各個參數間有均衡的變化樣本數，因此本研究將之作為類神經網路的學習樣本。但田口方法的實驗計畫將控制因子配置於內直交表，而將干擾因子與訊號因子配置

於外直交表，容易造成實驗次數太多與外直交表製造誤差因子模擬不易等問題。以表 1 動態設計問題為例， A, B, C, D 為控制因子， N_A 與 N_B 分別為 A 與 B 的製造誤差， T 為環境或劣化干擾因子， M 為訊號因子。每個因子皆為二水準，若採用 L8 的內直交表、L4 的外直交表，總共需要 $8 \times 4 \times 2 = 64$ 次的實驗。而在估計設計因製造誤差存在對輸出產生的影響時，需控制因子值在特定誤差邊界如 $x \pm \Delta x$ ，在實際執行上十分困難。

表 1 田口方法中的動態型問題之實驗計畫

				$M = m_1$				$M = m_2$				
				T		T		T		T		
				t_1	t_2	t_2	t_1	t_1	t_2	t_2	t_1	
				N_A	$+\Delta_a$	$+\Delta_a$	$-\Delta_a$	$-\Delta_a$	$+\Delta_a$	$+\Delta_a$	$-\Delta_a$	$-\Delta_a$
				N_C	$+\Delta_c$	$-\Delta_c$	$+\Delta_c$	$-\Delta_c$	$+\Delta_c$	$-\Delta_c$	$+\Delta_c$	$-\Delta_c$
A	B	C	D	No.	1	2	3	4	1	2	3	4
a_1	b_1	c_1	d_1	1	$Y_{1,1}$	$Y_{1,2}$	$Y_{1,3}$	$Y_{1,4}$	$Y_{1,5}$	$Y_{1,6}$	$Y_{1,7}$	$Y_{1,8}$
a_1	b_1	c_1	d_2	2	$Y_{2,1}$	$Y_{2,2}$	$Y_{2,3}$	$Y_{2,4}$	$Y_{2,5}$	$Y_{2,6}$	$Y_{2,7}$	$Y_{2,8}$
a_1	b_2	c_2	d_1	3	$Y_{3,1}$	$Y_{3,2}$	$Y_{3,3}$	$Y_{3,4}$	$Y_{3,5}$	$Y_{3,6}$	$Y_{3,7}$	$Y_{3,8}$
a_1	b_2	c_2	d_2	4	$Y_{4,1}$	$Y_{4,2}$	$Y_{4,3}$	$Y_{4,4}$	$Y_{4,5}$	$Y_{4,6}$	$Y_{4,7}$	$Y_{4,8}$
a_2	b_1	c_2	d_1	5	$Y_{5,1}$	$Y_{5,2}$	$Y_{5,3}$	$Y_{5,4}$	$Y_{5,5}$	$Y_{5,6}$	$Y_{5,7}$	$Y_{5,8}$
a_2	b_1	c_2	d_2	6	$Y_{6,1}$	$Y_{6,2}$	$Y_{6,3}$	$Y_{6,4}$	$Y_{6,5}$	$Y_{6,6}$	$Y_{6,7}$	$Y_{6,8}$
a_2	b_2	c_1	d_1	7	$Y_{7,1}$	$Y_{7,2}$	$Y_{7,3}$	$Y_{7,4}$	$Y_{7,5}$	$Y_{7,6}$	$Y_{7,7}$	$Y_{7,8}$
a_2	b_2	c_1	d_2	8	$Y_{8,1}$	$Y_{8,2}$	$Y_{8,3}$	$Y_{8,4}$	$Y_{8,5}$	$Y_{8,6}$	$Y_{8,7}$	$Y_{8,8}$




圖 3 系統因子方塊圖

由於類神經網路可模擬系統所形成的響應曲面 (Response Surface)，因此可估計參數變異對系統輸出的影響。但對於一個模擬網路而言，不管是訊號、控制、或干擾因子，都屬於輸入層的參數。尤其干擾因子中的製造誤差只是造成控制因子參數值的偏移，所以在實驗計畫中並不需要配置製造干擾因子，等到需計算參數變異或訊噪比時，再使用類神經網路來預測製造變異時的輸出值。

本研究將控制因子、干擾因子中的環境與劣化因子、以及訊號因子做為網路輸入層的參數，合併在一個實驗計畫中。如表 2 中的環境噪音因子 T 、控制因子 A, B, C, D 與訊號因子 M 放置於同一個直交表內，只需使用 L8 直交表配置因子，因此只需要進行 8 次實驗，可大幅降低實驗次數。即使為增加學習精度而增加水準數至三水準，只需採用較大之直交表如 L18，實驗次數仍遠比田口方法中的 64 次實驗為少，且參數間的變化具有直交性，可有效提升樣本的效率與預測精度。

表 2 Neural Taguchi 的實驗計畫

No.	A	B	C	D	T	M	Y
1	a_1	b_1	c_1	d_1	t_1	m_1	Y_1
2	a_1	b_1	c_1	d_2	t_2	m_2	Y_2
3	a_1	b_2	c_2	d_1	t_1	m_2	Y_3
4	a_1	b_2	c_2	d_2	t_2	m_1	Y_4
5	a_2	b_1	c_2	d_1	t_2	m_1	Y_5
6	a_2	b_1	c_2	d_2	t_1	m_2	Y_6
7	a_2	b_2	c_1	d_1	t_2	m_2	Y_7
8	a_2	b_2	c_1	d_2	t_1	m_1	Y_8

2.3 估計設計訊噪比

類神經網路的輸出並非訊噪比，而是系統公稱輸出值 Y 。因此只需仿田口方法建構一外直交表，並以類神經網路計算外直交表參數組合的輸出結果，即可獲得訊噪比。如表 3 為典型動態問題的外直交表設計，在計算訊噪比時，只需將控制因子的設定值，參考製造干擾因子對餐數值的影響，再與其他的干擾因子與訊號因子值，一起輸入類神經網路以獲得預測輸出值，最後經統計計算即可算出該設計的訊噪比。

表 3 計算訊噪比

				$M = m_1$				$M = m_2$							
				T		T		T		T					
				t_1	t_2	t_2	t_1	t_1	t_2	t_2	t_1				
				N_A	$+n_a$	$+n_a$	$-n_a$	$-n_a$	$+n_a$	$+n_a$	$-n_a$				
				N_C	$+n_c$	$-n_c$	$+n_c$	$-n_c$	$+n_c$	$-n_c$	$+n_c$				
A	B	C	D		1	2	3	4	1	2	3	4	斜率	變異數	訊噪比
a_1	b_1	c_1	d_1		$Y_{1,1}$	$Y_{1,2}$	$Y_{1,3}$	$Y_{1,4}$	$Y_{1,5}$	$Y_{1,6}$	$Y_{1,7}$	$Y_{1,8}$	β	σ_e	S/N

3. 以基因演算法搜尋田口類神經網路之最佳值

基因演算法是模擬生物適者生存不適者淘汰的觀念，所衍生出來的零階最佳化方法。其主要特色是搜尋結果較接近全域最佳解，並且可以處理非線性、不連續、不可微分等複雜的最佳化問題。基因演算法雖然可以解決複雜性的最佳化問題，並獲得近似全域最佳解，但因需大量的世代演算，造成實驗成本卻過於昂貴。田口方法利用直交表實驗的平均值分析 (Analysis of Mean) 以及加成法模式，來預測全因子實驗的最佳參數水準組合。田口方法可適用在系統模式不明，而須以實驗方式來進行設計，或是離散變數型的最佳化問題。但田口方法的最佳設計預測只限於水準值上，且其結果的正確性容易受到因子水準的選擇及交互作用所影響。

本文提出 FUNTGA 穩健最佳化流程，結合柔性演算法 [8] 與田口品質工程法，導入田口類神經網路模組，以直交表實驗與加成法預測的驗證實驗作為神經網路的學習與測試樣本。訓練完成的網路可模擬設計

空間中的系統模型，之後再以基因演算法在網路空間中進行最佳化搜尋。而由於直交表實驗大幅減少了訓練樣本數，不可避免的，若預測點離學習範例太遠，會造成預測誤差的增加，本研究使用模糊推論來規範 GA 的搜尋方向，以提升最佳設計的可靠度，FUNTGA 的最佳化流程如圖 4 所示。

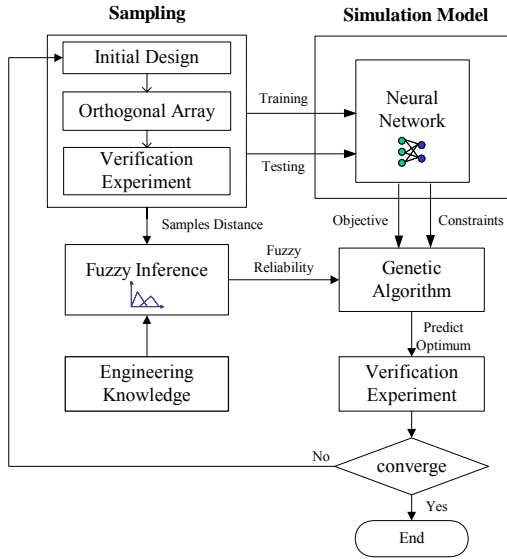


圖 4 FUNTGA 穩健最佳化流程

3.1 變數正規化

變數正規化的目的有兩點，第一是類神經網路中的轉換函數會將輸出對映至 $[0,1]$ 或 $[-1,1]$ 的區間，因此網路範例必須要經過正規化才能有正確的學習效果。另外，神經網路預測輸出的準確度與預測設計和學習樣本間的距離相關，離學習樣本越遠，其預測值的可靠度也會越差，而在計算預測設計與學習樣本之間的平均歐氏距離 (Euclid distance) 時，需考量到設計各變數的區間大小，才不至於計算結果只受到少數數值較大的變數影響 (如 IC 板的面積 \gg IC 板厚度)。

本文採用 (1) 式來對控制因子做正規化，干擾因子與訊號因子並非可設計的因子，因此在應用 GA 搜尋最佳設計時，只針對控制因子。在第 l 個設計中，第 k 個變數的 x_{kl} 尺度化成 z_{kl} 時，可將 x_{kl} 對映至 $[-1,1]$ 的區間。對於一個三水準的變數，若第一水準為最小值、第三水準為最大值，則可將水準值對映至 $(-1,0,1)$ ，而對於三水準的離散變數而言，則可等距離地對映至 -1 到 1 之間作為計算距離的標準。如一個三水準的離散變數，正規化的對映值即為 $(-1, 0, 1)$ 。

$$z_{kl} = \frac{\left(x_{kl} - \frac{(\max(x_k) + \min(x_k))}{2} \right)}{\left(\frac{(\max(x_k) - \min(x_k))}{2} \right)} \quad (1)$$

3.2 樣本信賴距離

基因演算法經過選擇、交配與突變之後獲得一群新的子代染色體，若要計算第 i 個染色體 D_i (設計) 與第 j 個網路學習樣本 S_j 的距離，可使用平均歐氏距離式 (2) 求得，其中 n 表示共有 n 個變數 (n 維)。

$$d_{ij} = \left[\frac{1}{n} \sum_{k=1}^n (D_{ik} - S_{jk})^2 \right]^{0.5} \quad (2)$$

因為距離樣本點愈近愈能相信該染色體擁有較高的信賴度，因此在計算該設計與每個樣本的距離之後，以最短的距離作為輸出預測信賴度的評斷標準，如 (3) 式。此最小樣本距離在本文稱為信賴距離 (Reliability Distance)，如圖 5 中設計 D_2 與樣本 S_1 距離為 d_{21} ，與樣本 S_2 距離為 d_{22} ，則設計 D_2 的信賴距離 RD_2 以最小值 d_{21} 表示。

$$RD_i = \min(d_{ij}) \quad (3)$$




圖 5 網路預測設計與學習樣本的信賴距離

一般類神經網路的在學習樣本空間內插設計 (Interpolating) 的預測準確度會大於外插設計 (Extrapolating) 的準確度。為區分內外插的設計，若 GA 產生的設計中，其輸入變數向量的每一維都是在樣本群個別變數的最大與最小值內則稱為內插，並將信賴距離值以負值表現 ($-RD$)；如果有任何一維是在最大最小區間之外，則稱為外插，並將信賴距離值以正值表現 ($+RD$)。如圖 5 中設計 D_1 為內插、設計 D_2 為外插。

3.3 模糊規則與歸屬函數設定

對於信賴距離多遠該給多少信賴度是屬於模糊性的概念，無法以二元邏輯來判定之，因此使用模糊系統來推論信賴度值，對於信賴距離遠的預測點給予較低的信賴度，而對於外插的設計也給予較低的信賴度。因此在歸屬函數的設定中，本文建議將外插的信賴距離依遠近分為三種描述詞：PB (Positive Big)、PM (Positive Medium)、PS (Positive Small)；對於

內插的信賴距離分為：NB (Negative Big)、NM (Negative Medium)、NS (Negative Small)；另外對於剛好距離=0 的情況以 ZE (Zero) 代表。本文歸屬函數使用三角形函數，各述詞所代表的設定值則使用隨機方式計算多次距離 (建議 3000 次以上，因為網路計算成本低廉)，再統計出距離的平均值 η 與標準差 α 作為設定標準，設定值如圖 6 所示。




圖 6 信賴距離歸屬函數

至於信賴度則分為 5 個等級，依信賴高低分別為 Excellent、Good、Fair、Poor 與 Bad。歸屬函數的定義如圖 7，圖中的 $2e$ 等於類神經網路測試中實際值與預測值最大誤差，因此 e 的表示式為：

$$e = \frac{\text{Max}\left(1 - \frac{\text{預測值}}{\text{實際值}}\right)}{2} \quad (4)$$




圖 7 信賴度歸屬函數

模糊規則的設定方面，依信賴距離述詞給予不同等級的信賴度：

- R1: If RD is [PB] then prediction reliability is [Bad]
- R2: If RD is [PM] then prediction reliability is [Poor]
- R3: If RD is [PS] then prediction reliability is [Fair]
- R4: If RD is [ZE] then prediction reliability is [Excellent]
- R5: If RD is [NS] then prediction reliability is [Excellent]
- R6: If RD is [NM] then prediction reliability is [Good]
- R7: If RD is [NB] then prediction reliability is [Fair]

在經過模糊推論與解模糊化之後，即可計算出預測設計的信賴度。

3.4 適應度函數的計算

基因演算法經過選擇、交配與突變之後獲得一群新的染色體，經過解碼計算出適應度函數(Fitness Function)，若設計落入不合理區間則需加入處罰函數(Penalty Function)來降低適應度函數值。其計算結果可用來判斷染色體(Chromosome)的生存機率，適應度函數值越大者可以獲得越大的生存機率。選擇出來的染色體經過交配(Crossover)與突變(Mutation)之後即可獲得新的族群。一直重複循環直到收斂為止，其最佳解可稱為接近全域最佳設計。

本文以田口類神經網路模擬系統輸出，並以設計的訊噪比作為適應度函數。為了計算訊噪比，需將個別的染色體解碼還原為控制因子的設定值，再與所有的干擾與訊號因子一起併入外直交表，模擬該設計受到干擾因子與訊號因子影響時的系統參數值，再將各因子的數值輸入類神經網路，以獲得預測輸出值，經由統計計算出該設計 (染色體) 的訊噪比，如圖 8 所示。

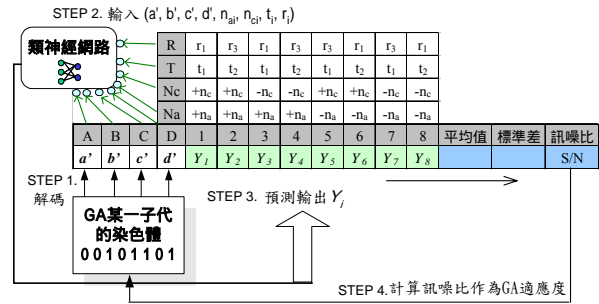


圖 8 GA 配合田口類神經網路計算訊噪比之示意圖

然而，誠如上一節所分析的，類神經網路的預測信賴度會受到預測設計與網路學習樣本間的距離所影響。因此由 GA 搜尋類神經網路所得的設計不見得是較好的設計。為補償因學習樣本數減少所造成可能的預測誤差，我們引用上一節所提出的預測信賴度，定義設計的適應度函數為經預測信賴度(PR)修正後的訊噪比，圖 9 為整個適應度函數的計算流程。

$$\text{Design_fitness} = (\text{S/N}) * (\text{PR}) \quad (5)$$

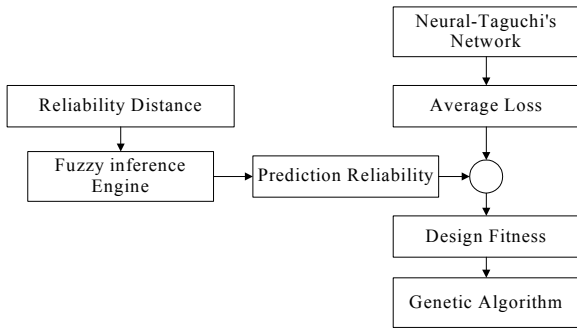


圖 9 適應度函數的計算流程

4. 應用數值例

圖 10 為一個應用懸臂樑結構的力量感測器，當懸臂樑端點受一力 F ，藉由量測懸臂樑端點 y 方向的位移量可得知 F 的大小，而受力端的位移可藉由懸樑根部的應變規與樑變形理論推算出來。此時懸臂樑如同一個彈簧，變形與受力呈線性正比關係如 (6) 式。

$$y = \beta \times F \quad (6)$$




圖 10 力量感測器示意圖

力量感測器的精度受到此懸臂彈簧的彈性係數 β 所影響，假設基於感測器對於敏感度與頻寬的需求， β 的設計規格需為 100 (mm/N)。懸樑彈性係數由樑的材料與幾何尺寸所控制，現有材料為某種合金 A，其楊氏係數為 69 (Gpa)， $h = 0.152$ (mm)， $b = 11.40$ (mm)， $L = 41$ (mm)。為減少製造誤差對感測精度的影響，希望藉由懸樑的參數設計，以求得穩健最佳化設計。

未來感測器量產時干擾因子將來自懸樑加工誤差、材料特性如楊氏係數的不穩定性、環境溫度變化等。懸樑尺寸製造上的公差假設如下，其中為說明方便，其他干擾因子暫不考慮。

$$\begin{aligned} \text{厚度公差 } \Delta h &= \pm 0.0025 \text{ (mm)} \\ \text{寬度公差 } \Delta b &= \pm 0.025 \text{ (mm)} \\ \text{長度公差 } \Delta L &= \pm 0.12 \text{ (mm)} \end{aligned}$$

此設計在穩健化設計中屬於動態望目的問題，在穩健化設計過程懸樑彈性係數是藉由實驗量測各設計的受力與樑變形量而來，也因此實驗次數也希望

愈少愈好。在本範例中， β 值將以樑變形理論所推導的下式估計。

$$\beta = \left(\frac{4L^3}{Ebh^3} \right) \quad (7)$$

4.1 實驗設計

在第一階段主要的工作是設定實驗配置並進行實驗，將實驗分析結果作為類神經網路的學習與測試樣本。在此設計中的控制因子水準設定方式如表 4，原初始設計的設定值以上標 i 表示。

而訊號因子 F 的水準設定則考慮可能的力量測定使用範圍假設為三水準 0.009, 0.022 與 0.035 (N)。我們首先以田口方法配置控制因子於 L18 內直交表，干擾因子配置於 L4 外直交表，以加法模式預測出最佳設計後，再與 FUNTGA 所得結果比較。

表 4 控制因子水準設定

控制因子	第一水準	第二水準	第三水準
E (GPa)	材料 A (69) ⁱ	材料 B(100)	材料 C (128)
b (mm)	7.62	11.40 ⁱ	15.24
h (mm)	0.127	0.152 ⁱ	0.177
L (mm)	31	41 ⁱ	51

4.2 類神經網路建構

在田口類神經網路的建構上，我們仍使用 L18 直交表配置輸入層參數，輸出層為變形量 y 值，作為類神經網路的學習範例。此時製造誤差可不必安排在實驗計畫中，但此數值例中則暫時不將訊號因子併入同一直交表實驗中，而以不同訊號因子水準下重複三次直交表的方式，以增加學習的範例數，因此共有 54 (18x3) 個學習樣本；另外以初始設計與田口加法預測所得之最佳設計作為測試樣本，共有 6 個測試樣本。

在最佳網路參數設定上，建議先使用單層隱藏層的倒傳遞網路，若效果不好再使用雙層隱藏層來學習。另外也可使用多層函數連結網路 (Multilayer Functional-Link Network, MFLN) 來改善學習效果。其主要原理是在輸入與輸出層中加入對數化神經元，可對變數的低值部分較敏銳；加入指數化神經元可對變數的高值部分較敏銳[10]。最後的網路參數設定如表 5 所示。

表 5 網路主要參數設定

網路模式	隱藏層	學習率	慣性項	學習循環
多層函數連結網路	單層 7 個神經元	1→0.1	0.5→0.1	20000

其中學習率在學習初期給予較高的學習率=1，以加快收斂速度，依循環數增加遞減至 0.1 以避免震盪，遞減係數為 0.95；慣性項也是使用相同的方式設定在 0.5→0.1。學習後的測試誤差至 0.4%收斂，收斂過程如圖 11 所示。




圖 11 網路學習收斂過程

4.3 樣本距離設定

本文由於訓練樣本數有限，為了減少類神經網路所預測的最佳值與實際驗證實驗的誤差，因此對類神經網路在設計區間各點的預測值皆有良好的表現持保守的態度。所以必須設定信賴度與樣本距離的模糊歸屬函數，以建立一模糊推論系統作為最佳值搜尋的輔助工具。信賴度歸屬函數的設定依據為類神經網路測試誤差，而最大誤差由(4)式可求得 $e \cong 5\%$ ，因此參照圖 7 設定的信賴度歸屬函數。

至於信賴距離的歸屬函數設定方面，則以隨機取樣方式求得隨機樣本群中最小樣本距離的平均值為 0.4、標準差為 0.14，因此可參照圖 6 訂立出信賴距離的歸屬函數。

4.4 訊噪比最大化

在 FUNTGA 的第一階段最佳化中，本範例屬於田口方法中的動態問題，因此其訊噪比的計算方式如下：

$$S/N_d = 10 \cdot \log_{10} \left(\frac{\beta^2}{\sigma_e^2} \right) \quad (8)$$

$$\beta = \frac{\sum_{i=1}^m \sum_{j=1}^n (y_{ij} M_i)}{n \sum_{i=1}^m (M_i^2)} \quad (9)$$

$$\sigma_e^2 = \frac{1}{(mn-1)} \sum_{i=1}^m \sum_{j=1}^n (y_{ij} - \beta M_i)^2 \quad (10)$$

而類神經網路的輸出只是變量 y ，所以使用類神經網路配合田口方法訊號因子與外直交表配置的方

式，來計算訊噪比如表 3，所得之訊噪比乘上設計的預測信賴度則得到設計的適應度函數值如式(5)。

在本次搜尋所設定的基因演算法參數如表 6 所示，其中子代的篩選方式採用線性排序，依染色體的適應度大小排序，再以設定的選擇壓力挑選子代。

表 6 基因演算法主要參數設定

族群數	選擇方式	交配率	突變率	最大世代
60	線性排序	0.6	0.008	200

4.5 調整輸出目標值

因此例為有特定目標之動態問題，在最大化訊噪比之後，需將 β 調整至目標值 100 (mm/N)。本文採用田口方法中二階段最佳化的方式，先找出對輸出有影響對訊噪比影響性小的控制因子作為調整因子。因類神經網路可預測田口內外直交表實驗結果，因此可快速的分析出斜率 β 與訊噪比的因子效果折線圖如圖 12。圖中可看出 E 、 b 對訊噪比較不敏感，對 β 值較敏感，因此以 E 、 b 兩個控制因子作為調整因子。再以 E 、 b 作為變數， h 、 L 以第一階段結果設為定值，使用基因演算法搜尋與 β 目標值最接近的設計。

因預測信賴度對於離學習範例與當初水準搜尋範圍太遠的預測點，予以處罰以降低其適應度函數值，因此 GA 搜尋結果將侷限於水準設定範圍附近，故所得之結果也將是一個局部的最佳化值。對於一般工程問題而言，局部最佳化正如田口方法所強調的一般，工程問題強調的是以較少的實驗，在低成本、短時間內獲致滿意的改善設計，對於該設計是否為全域最佳化，並不十分重視，且是否值的花費反覆實驗的成本以獲致些微的改善，也是引起爭議的地方。但若對上述的實驗結果仍然不滿意，可以此次 FUNTGA 最佳設計作為初始設計，重新設定水準範圍，以新的因子設定，仿照原先方式再作一次實驗計畫，並將第二次實驗計畫的資料併入先前的學習樣本，使神經網路重新學習，以改善網路的預測準確度，而此數值例第二次反覆 GA 搜尋所得之結果也列於表 7。而此程序也可依一般最佳化的流程一直反覆，直至結果收斂為止，如此將可獲得接近全域最佳化之設計。




圖 12 因子效果圖

4.6 結果比較與討論

由表 7 可看出 FUNTGA 與田口方法得到的結果類似，但因田口方法在第二階段調整目標值時，因採用試誤法，故在 β 的調整上尚未達到目標值。而且在實驗成本的比較上，因為 FUNTGA 在實驗設計階段並不需要考慮製造干擾因子的問題，所以只需要 60 次實驗即可訓練出類神經網路來模擬系統，而田口方法則必須要使用外直交表來模擬輸出變異的資訊，所以必須進行 216 次實驗來預測最佳設計，而在第二階段使用調整因子調整至目標值時，此例用了六次試誤法，每調整一次因子就需要 12 次實驗（外直交表 $4 \times$ 訊號因子 3），即 72 次實驗才將輸出調到目標值附近。而 FUNTGA 在第二階段調整時，不需藉由額外的實驗，直接在田口類神經網路準確的搜尋出調整因子值。

而藉由反覆執行 FUNTGA，在僅用了不到原先田口方法所需的一半實驗次數，即找到滿足目標需求且訊噪比更高的穩健化設計，由此可看出 FUNTGA 應用於穩健最佳化設計的效率與優點。

表 7 穩健最佳化結果比較（ β 目標值：100）

	E	b	h	L	β	訊噪比	實驗次數
Taguchi	69	15.24	0.177	51	101	71.9	288
FUNTGA	69	13.06	0.177	51	100	71.9	60
反覆 FUNTGA	69	10.82	0.208	55.88	100	73.3	120

5. 結論

對於實驗成本高的最佳化問題，使用田口方法可有效率地以較少的實驗次數，獲得一組改善設計。然而田口方法中的加乘法預測只能在因子水準值上，無法使用內插或外插。如果實驗結果受到控制因子間強烈交互作用的影響而導致預測失敗，則實驗數據無法再重複利用。另外對於多目標輸出的設計問題，田口方法也不容易調整。

本文所提出的柔性演算法則可彌補田口方法的不足，即使直交表實驗的預測值不理想，仍然可作為類神經網路的訓練範例。而由於在模糊推論引擎中加入預測信賴度修正適應度函數值，因此可使用更少量的數據並同時在各水準之間進行內外插搜尋，其預測的誤差也可縮小，以避免驗證實驗的浪費。

6. 誌謝

本研究承蒙國科會支持，計劃編號 NSC89-2212-E155-019，特誌謝意。

7. 參考文獻

- [1]. G. Taguchi, "Performance Analysis Design." International Journal of Production Research, 16, pp.521-530. (1978)
- [2]. Loh, N. H., Tam, S. C. and Miyazawa, S., "Use of Response Surface Methodology to Optimize The Finish in Ball Burnishing", Vol.12, 1990, pp101-105.
- [3]. Tribus, M. and Szonyi, G., An alternative view of Taguchi approach, Quality Progress, 46-52, (1989, May).
- [4]. K. J. Cios, G. Y. Baaklini and A. Vary, "Soft computing in design and manufacturing of advanced materials", Journal of engineering for gas turbines and power Vol. 177 161-165, (1995)
- [5]. Y., Nakajima, H., Kadowaki, T., Kamegawa and K., Ueno, "Application of a Neural Network for the Optimization of Tire Design," Tire Science and Technology, TSTCA, Vol. 27, No. 2, April-June 1999, pp. 62-83.
- [6]. G. J. Wang, J. C. Tsai, P. C. Tseng and T. C. Chen, "Neural-Taguchi Method for Robust Design Analysis", Journal of the Chinese Society of Mechanical Engineers, Vol.19, No.2, pp.223~230 (1998).
- [7]. P. Sitarama Chakravarthy and N. Ramesh Babu, "A new approach for selection of optimal process parameters in abrasive water jet cutting", Materials and manufacturing processes, vol. 14, No. 4, 581-600, (1999).
- [8]. J. S. Jang, C. T. Sun and E. Mizutani, "Neuro-Fuzzy and Soft Computing: a computational approach to learning and machine intelligence", Prentice-Hall, (1997).
- [9]. 張旭華、蘇朝墩, "運用柔性演算法求解最佳參數設計", 國立交通大學工業工程管理系博士論文, (2000).
- [10]. 葉怡成, "類神經網路模式應用與實作", 儒林, (2000).