

演化型局部類神經網路於穩健最佳化設計

曾譽龍 余志成*

國立高雄第一科技大學機械與自動化工程系

高雄市楠梓區811卓越路2號

Tel : (07)6011000 ext.2228*

Fax : (07) 6011066

E-mail : jcyu@ccms.nkfust.edu.tw*

摘要

穩健化是在設計過程中考慮製程製造公差、疲勞劣化與使用環境的不確定性，造成輸出性能的變異，運用參數設計，降低輸出性能對誤差因子的敏感度，以提升設計品質。一般常用田口方法予以實現，但當實際運用在工程穩健最佳化問題時，受限於參數間不得存在交互作用的假設，最佳設計受限於因子水準，且在以外直交表實驗估計性能穩健性的控制成本太高等影響。本文應用演化型局部類神經網路，將田口方法中所有因子併入單一直交表實驗，訓練類神經網路來近似系統模擬，再以網路模型重現外直交表而模擬輸出訊噪比，其能夠大幅減少實驗次數與降低外直交表實驗的控制成本。而在以基因演算法搜尋網路模型的極值時，為避免因學習樣本數的降低影響網路模型的預測精度，進而造成遺傳演算法搜尋最佳設計的錯誤，本文提出信賴半徑限制基因演算法的搜尋空間，並以模糊準則來動態的調整信賴半徑，反覆演化網路模型之信賴空間，以提升搜尋之可靠度與學習樣本的效率，對於穩健最佳化實際應用於工程問題，有非常大的助益。

關鍵字：類神經網路、基因演算法、模糊推論、工程最佳化、穩健化設計

Abstract

Robust design considers the performance variation due to the manufacturing tolerances, deterioration, and environmental factors, and applies parameter design to reduce the output sensitivity to these noise factors. Taguchi method has been an effective tool for quality engineering. However, the optimum prediction using the additive model is liable to parameter interactions, and the parameter combination is restricted to the factorial levels. Also, the use of outer orthogonal array to estimate the S/N ratio will incur high controlling costs in engineering optimization. This work proposes a single experimental design for all the system factors, and applies the orthogonal array experiments to train a neural network model to simulate the system response. The network is then applied to the calculation of the S/N ratio from an outer OA, which greatly reduces the number of experiments and the experimental cost in

the parameter level control. However, the number of training samples is limited due to the use of orthogonal array experiments, which might jeopardize the generality of the simulate network model. The optimum from the direct search of the network model using GA might become doubtful. In light that the prediction accuracy of the model is likely limited to the neighboring space of the training samples, this paper proposes the Reliable Radius using Fuzzy inference to restrain the search space of the genetic algorithm (GA) in the network model. The optimum searched in the reliable regional network model is reintroduced to retrain the network model that continues to evolve until a global optimum is obtained. The proposed scheme can greatly reduce the controlling cost in experiments and increase the sampling efficiency, which is particularly useful in engineering applications.

Keywords: Neural Network, Genetic algorithm, Fuzzy Inference, Engineering Optimization, Robust Design

1. 研究背景

穩健化設計 (Robust Design) 目的在於不增加成本之前提下，以參數設計降低因誤差因子產生的輸出變異，使得產品與製程在生命週期中面臨各種使用狀況，仍夠保持其預設機能。主要藉由參數設計，以減少系統輸出對於誤差因子之敏感性。Taguchi[1]提出直交表(Orthogonal Array)實驗，利用統計學的優點有效降低實驗的採樣數量，藉此預測整體模擬系統輸出之趨勢，並提出訊噪比(Signal to Noise, S/N)作為實驗效能之績效評估(Performance Measure)，並運用外直交表(Outer Orthogonal Array)來配置雜訊因子(Noise Factor)，以極端干擾因子表達輸出性能的分佈，能使估計設計的輸出品質。

田口方法預測的最佳參數組合限於因子實驗的水準點上，且其實驗多寡是由內外直交表配置的乘積來決定，倘若當雜訊因子持續增加時，實驗次數更是隨倍數成長。而為了期望系統預測能更為準確，需將噪音因子精確的控制在水準誤差範圍內，使得實驗成本上明顯增加。再者，因實際工程系統

*聯絡作者： jcyu@ccms.nkfust.edu.tw

的輸入輸出關係複雜，參數間的交互作用與關聯性，將造成最佳水準設定的誤差。

有文獻直接結合田口方法與最佳化搜尋，進行穩健最佳化，如 Ho *et al.*[2]建議在進行非線性規劃前運用田口式方法，減少實驗次數並找出主要的設計參數，以所得的最佳水準組合作為初始設計，縮短最佳化時間。D'Entremont *et al.*[3]，則以非線性規劃的方法找出公稱最佳設計，再應用望目型損失函數的觀念修改目標函數，以得穩健化設計。Balaji *et al.*[4]以二次損失函數的概念，極小化其輸出變異達穩健化設計，並分別針對設計參數變異為定值與變動的情況提出穩健化策略。

為突破實驗方法上述的限制並加速最佳化設計的過程，部分研究學者提出將實驗資料建構近似模型。如 Tribus *et al.*[5]使用響應曲面法 (Response Surface Methodology, RSM) 取代田口的變異數分析 (Analysis of Variance, ANOVA)，運用二階的多項式作回歸分析來模擬系統響應。但模擬之前必須先行設定系統數學模式，對於複雜系統較不具彈性。Tay 與 Butler[6]建議以直交表實驗分為訓練與測試範例，並將數據置入類神經網路 (Neural Network, NN) 模擬，倘若資料數量不足或系統預測性不佳時，則需增加因子的水準數或以隨機方式增加範例。Yu *et al.*[7]則提出信賴半徑 (Reliable Radius) 與樣本包圍空間 (Sampling Enclosure Space, SES) 所建構之局部類神經模型。針對稀少樣本與類神經網路之關聯特性分析，在搜尋網路模型極值時，避免過度的信賴全域準確性而震盪，藉以提升預測結果之可靠性與有效性。

在尋解演算法方面，Su[8]等使用基因演算法 (Genetic Algorithm, GA) 處理非線性、不連續等複雜的最佳化問題之特性，在非線性的網路模型中獲得近似全域最佳解。另有研究指出[9]使用混合式演算法來進行非線性數值例最佳化搜尋，皆能有不錯的結果，而基因演算法與模擬退火法 (Simulated Annealing, SA) 雖然可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，易造成實驗成本卻過於昂貴。

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過多與外直交表製造誤差因子難以控制等問題。透過合併直交表實驗訓練類神經網路模型，並善用回想過程以估計輸出訊噪比，以作為穩健化設計品質指標，並結合搭配模糊推論網路模型的信賴空間，以基因演算法搜尋並演化信賴網路模型，以求得穩健最佳化設計。

2. 田口類神經網路 (Taguchi-Neural Network)

2.1 田口實驗計畫

田口方法主要將參數分為四類：訊號因子，控制因子，干擾因子，與設計輸出。品質工程中依照其特性可分為靜態特性與動態特性，當係屬靜態特性時，品質特性值是固定不變的；而當其為動態特

性時，品質特性將會依據訊號因子輸入的不同，而產生輸出目標的變化。

田口方法的實驗計畫將控制因子與干擾因子分別配置於內直交表與外直交表，容易造成實驗次數太多，且難以控制於特定水準點上等問題。以表 1 靜態設計問題為例， 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。每一因子皆為 2 水準，若採用 L_8 的內直交表、 L_4 的外直交表配置時，總共需要 $8 \times 4 = 32$ 次的實驗。且在評估設計時，為了準確的預測輸出結果，通常會對外直交表誤差精度提升要求，容易造成實驗成本明顯的增加，且在實際工程問題中，執行上相當困難。

表 1. 田口方法之因子配置於直交表

				T	t_1	t_2	t_2	t_1
				N_B	$-A_b$	$+A_b$	$-A_b$	$+A_b$
				N_A	$-A_a$	$-A_a$	$+A_a$	$+A_a$
A	B	C	D	No.	1	2	3	4
a_1	b_1	c_1	d_1	1	$Y_{1,1}$	$Y_{1,2}$	$Y_{1,3}$	$Y_{1,4}$
a_1	b_1	c_1	d_2	2	$Y_{2,1}$	$Y_{2,2}$	$Y_{2,3}$	$Y_{2,4}$
a_1	b_2	c_2	d_1	3	$Y_{3,1}$	$Y_{3,2}$	$Y_{3,3}$	$Y_{3,4}$
a_1	b_2	c_2	d_2	4	$Y_{4,1}$	$Y_{4,2}$	$Y_{4,3}$	$Y_{4,4}$
a_2	b_1	c_2	d_1	5	$Y_{5,1}$	$Y_{5,2}$	$Y_{5,3}$	$Y_{5,4}$
a_2	b_1	c_2	d_2	6	$Y_{6,1}$	$Y_{6,2}$	$Y_{6,3}$	$Y_{6,4}$
a_2	b_2	c_1	d_1	7	$Y_{7,1}$	$Y_{7,2}$	$Y_{7,3}$	$Y_{7,4}$
a_2	b_2	c_1	d_2	8	$Y_{8,1}$	$Y_{8,2}$	$Y_{8,3}$	$Y_{8,4}$

2.2 類神經網路的訓練與採樣策略

對於實際工程問題而言，若能有效的運用這些現場樣本 (field data)，將可節省許多實驗成本。但對於沒有現場的樣本資料的新工程問題，本文建議以田口方法的直交表，作為初始的採樣規劃，其不僅可利用統計學的優點降低實驗的採樣數量，也能提升樣本點對稱性與均佈性而配置於空間上。

由於類神經網路可模擬系統所形成的響應曲面，因此可估計參數變異對系統輸出的影響。干擾因子中所分佈的誤差只是造成控制因子參數值的偏移，故在實驗計畫中並不需要額外配置干擾因子，只需將控制因子與干擾因子整合於一實驗計畫內。且利用此實驗資料作為學習樣本而建構類神經網路，等到需計算參數變異或訊噪比時，再以網路模型預測參數變異時的輸出值即可。本研究將干擾因子中的環境噪音因子 T 、製造因子 N_A 與 N_B 以及控制因子 A, B, C, D 放置於同一個直交表內，並作為網路輸入層的參數。只需使用 L_8 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 3 水準，只需採用較大之直交表如 L_{18} ，實驗次數仍遠少於田口方法中的 32 次實驗，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。

本文採用倒傳遞類神經網路 (Back-propagation Neural Networks, BPNNs)，來當作模擬工程問題的網路模型。倒傳遞類神經網路係屬於監督式學習網路，故範例品質與數量對於類神經網路的精準性有

相當大的影響，故建議以田口方法的直交表，作為初始範例的採樣規劃。我們將控制因子配置於3水準之直交表，而製造因子也隱含其中可忽略不計；其它噪音因子則予以2水準化。如此一來，不但能使原始範例具有均佈性，且也能改進以往訓練樣本與測試樣本由直交表取樣，造成實驗組合而失去直交性或範例組合過多等問題。此外，為使網路性能較佳且具代表性，導入田口實驗計畫來調整類神經網路的學習參數，並使用基因演算法結合LM演算法(Levenberg-Marquardt Algorithm, LM)之複合搜尋機制架構傳遞。首先使用統計模型之直交表以決定最佳網路訓練參數，再以基因演算法解決傳統以隨機亂數決定初始權重而使效果不彰的問題，並透過類神經LM快速收斂的演算特性，期望提升網路預測模式的表現。

2.3 網路模型估計輸出訊噪比

類神經網路的輸出並非訊噪比，而是系統公稱輸出值 Y 。因此需仿田口方法建構一外直交表，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2為典型靜態問題的外直交表設計，每單一設計參數在計算訊噪比時，需將控制因子的設定值配合干擾因子水準變異的偏移，一同輸入至類神經網路，然後網路模型予以回想而獲得預測輸出值，最後經統計估算即可輸出該設計之訊噪比。

表 2. 網路模型估計輸出訊噪比

		T	t_1	t_2	t_1							
		N_B	$-n_b$	$+n_b$	$-n_b$	$+n_b$						
		N_A	$-n_a$	$-n_a$	$+n_a$	$+n_a$						
A	B	C	D	No.	1	2	3	4	Average value	Standard Deviation	Signal to Noise	
a_1	b_1	c_1	d_1		1	$Y_{1,1}$	$Y_{1,2}$	$Y_{1,3}$	$Y_{1,4}$	y	σ_c	S/N

3. 演化型局部類神經網路結合基因演算法

本文提出演化型局部類神經網路結合基因演算法(Evolutionary Regional Neural network with Genetic Algorithm, ERNGA)，並導入田口品質工程法，能夠建構非線性模型與表達變數間的交互作用，並可應用於各式函數映射與數列預測等問題，整體流程如圖1。雖然類神經網路可以模擬任何線性或非線性函數的能力，採樣數目無限多與網路學習迭代次數無窮大等相關參數的配合前提下才可行，此意味著當前述條件有限制時，其網路並不一定近似模擬模型。故針對實際新工程問題中，以直交表中的驗證實驗作為神經網路的學習樣本與測試樣本，能夠以較少的學習範例數量而均佈設計空間，有效掌握網路模型分佈之趨勢。在基因演算法搜尋網路模型的極值時，為避免因學習樣本數的降低，進而影響網路模型的精度。本文提出以信賴半徑與樣本包覆空間限制基因演算法的搜尋空間，並以模糊準則來動態的調整信賴空間，來限制最佳化過程中搜尋範圍，藉以提升預測結果的有效性。再將所得的暫態最佳設計加入學習樣本，重新訓練網

路模型，使得學習樣本增加在最佳點附近的採樣，提升類神經網路於該區域的模擬準確度與學習樣本的效率，讓設計點不受田口直交表水準點上的限制。

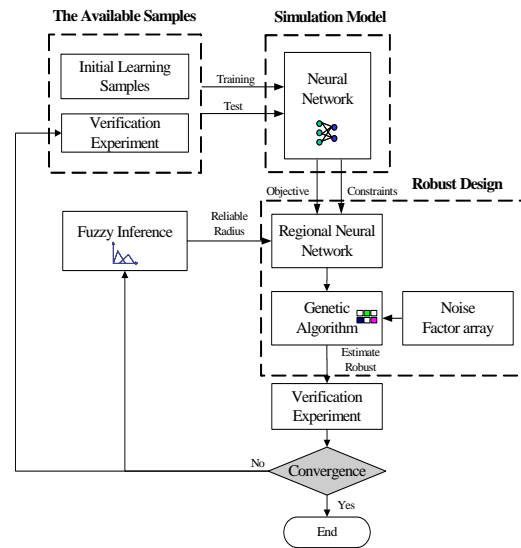


圖 1. 演化型局部類神經結合基因演算法之流程圖

3.1 網路模型之信賴半徑

依照類神經網路模型特性，當預測點距離學習點越近則準確度將越高。故為能統一計算前述兩者間之距離，使得網路範例能有正確的學習效果，首先必須以式(1)先對輸出變數進行正規化。可輸入參數對映至 $[-1,1]$ 的區間，也可避免各變數間的尺度問題 (Scaling Problem)，造成計算結果受少數維度之數值變化較大所主導。

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

本文使用平均歐氏 (Mean Euclid Distance) 如式(2)作為計算類神經網路的預測點與學習樣本點間的距離指標，使其在多維空間能夠保有相同的長度。

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

n 表示維度, P_i 為預測點 i 個, S_j 為樣本點 j 個

由類神經拟合模型的特性研判可知，當預測點距離學習樣本越近，其準確度相對會較高。因此計算預測點之平均歐式距離後，採用最短的距離作為輸出預測信賴度的評斷準則如式(3)。本文將此稱為最小樣本距離 (Minimum Sampling Distance, MSD)。

$$MSD_i = \min(r_{ij}) \quad (3)$$

3.2 網路模型之信賴空間

一般工程問題受限於時間與成本，現有資料數目往往不足，所訓練出來的類神經網路模型，其準確度自然受到限制，因此必須設立相關的有效區間機制，以免模擬誤差太大，造成基因演算法搜尋過程的發散或效率不佳。對於稀少學習範例所訓練的類神經網路，全域性的預測準確性並不實際，可信賴的區間往往侷限於部份區域。鑑於類神經網路模型的特性，Yu *et al.*[7]證實預測點在內插設計之準確度優於外插設計。如圖 2 所示，我們以學習樣本為中心定義信賴半徑，並依照內外插設計準則可分別定義信賴內插半徑 (Reliable Interpolation Radius, *RIR*) 與信賴外插半徑 (Reliable Extrapolation Radius, *RER*)，以建構出局部模型信賴空間，藉此降低預測模型的失效等問題。

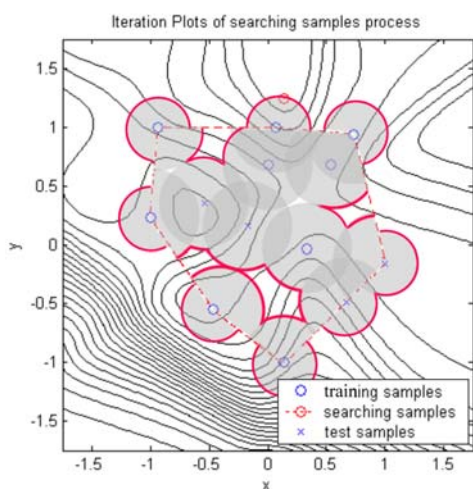


圖 2. 類神經網路模擬之響應曲面與局部信賴空間

3.3 以模糊法則推論信賴半徑

本文將依兩個準則訂定模糊規則與歸屬函數，一則為預測點屬於內插或外插設計時，給予不同的內外插半徑決策。本研究提出模型誤差指標 (Modeling Error Index, *MEI*) 如式(4)作來評估網路模型預測準確性。*MEI* 係藉由模型預測基因演算法搜尋網路模型信賴空間所得的最佳設計預測誤差與網路模型測試樣本均方根誤差的比值。輸出與時 *MEI* 的大小來決判內外半徑所應調整的比值，並利用典型的三角形及梯形函數予以表示所有的歸屬函數。

$$MEI = \frac{|Y_j - T_j|}{RMSE_{Test}} \quad (4)$$

Y_j 為類神經預測輸出， T_j 為實驗點輸出
 $RMSE_{Test}$ 為測試樣本的均方根誤差

當最佳設計預測誤差接近 $RMSE_{Test}$ 時，代表此次模型預測準確度佳且此次信賴空間訂定佳，因此在下一次迭代時可考慮放大信賴半徑，藉以增加最佳化搜尋的空間；而當最佳設計預測誤差大於 $RMSE_{Test}$ 時，代表模型預測準確度不佳且此次信賴空間訂定不恰當，故可考慮降低信賴半徑，避免因

最佳化搜尋到網路模型準確度極差的區間，而得到預測失效之結果。因此本節將模型誤差歸屬函數的設定如圖 3 所示，對預測點的誤差大小分為三種語意述詞：*B* (Big)、*M* (Medium) 及 *S* (Small)；初始信賴度的歸屬函數，係將全集合對應到 [0,1] 區間，其設定信賴半徑的調整參數 (Adjust Factor) 依 *MEI* 的高低分為 Increase、Slightly increase、Maintain、Slightly decrease 及 Decrease，共 5 個調整等級，其歸屬函數的設定如圖 4 所示。




圖 3. 模型誤差指標之歸屬函數




圖 4. 調整信賴半徑之歸屬函數

為了改善最佳化方法的搜尋效率及漸進收斂程度，本文提出動態內外半徑自我調整法。最佳化搜尋範圍將隨著每一迭代過程中所預測之新的設計參數，根據內外插與模型誤差指標的準則，進行動態調整信賴度值而改變信賴空間。

當基因演算法所搜尋的最佳設計預測值與實驗值誤差越小時，代表所模擬的網路模型具有較高的一般性 (Generality)，因此應增加下一迭代的信賴半徑，相當於信賴空間將會被放大，使基因演算法可搜尋較大的範圍。反之，若其預測值與驗證實驗值相差應緊縮。整體而言，利用此法將使基因演算法於搜尋過程中，將會逐漸朝向最佳值區域接近，且其附近將不斷新增學習樣本點，並依照模型預測的準確性動態調整信賴空間，使得最佳化的搜尋不會過度依賴每一次網路模型訓練的準確性。

本節由上所述於網路模型預測準確度的經驗法則，進一步根據上述所提及內外插之 3 個模擬誤差指標，分別搭配不同等級的內外插半徑歸屬函數語意述詞，設定 6 條模糊規則，如下列所示，藉以調整信賴內插半徑 (Reliable Interpolation Radius, *RIR*) 與信賴外插半徑 (Reliable Extrapolation Radius, *RER*)：

- 1 If Extrapolation and prediction error is [Small] then [Slightly Increase] *RER* and [Increase] *RIR*
- 2 If Extrapolation and prediction error is [Medium] then [Maintain] *RER* and [Slightly Increase] *RIR*
- 3 If Extrapolation and prediction error is [Large] then [Slightly decrease] *RER* and [Maintain] *RIR*
- 4 If Interpolation and prediction error is [Small] then [Maintain] *RER* and [Slightly increase] *RIR*
- 5 If Interpolation and prediction error is [Medium] then [Maintain] *RER* and [Slightly decrease] *RIR*
- 6 If Interpolation and prediction error is [Large] then [Slightly decrease] *RER* and [Decrease] *RIR*

在經由模糊推論與解模糊化後，計算出信賴半徑的調整因子 (AF) 如式(5)與式(6)，作為調整內外插信賴半徑的計算，進而影響下一次的信賴空間範圍。

$$RIR_{i+1} = AF_i \times RIR_i \tag{5}$$

$$RER_{i+1} = AF_e \times RER_i \tag{6}$$

4. 微加速度計穩健最佳化設計

4.1 工程問題描述

圖 5 為一壓電式懸樑型加速度感測器之模型，係由四根對稱懸樑結構固定於基座上，支撐著中央的振動質塊。在此為了能獲得較大的敏感度，在每一根懸樑上各鍍上兩片 PZT 作為壓電材料，將其位置分別放置於懸樑變形時的拉伸區域及壓縮區域，主要目的為藉由此兩壓電材料的位置不同以檢測出非預期的訊號。

若在振動質塊與本體間置入一壓電材料作為轉換器，藉由材料之壓電效應可得到電量變化，而換算出感測加速度。相關研究[10]已對壓電式微加速度計，作系統模擬與設計分析上的詳細分析，其整體系統的轉移函數為下式(7)。

$$\beta = \left| \frac{e_o}{\ddot{z}_i} \right| = \left| S_T \cdot \frac{\tau(i\omega)}{\tau(i\omega)+1} \cdot \frac{\omega_n^2}{(i\omega)^2 + 2\zeta \cdot \omega_n(i\omega) + \omega_n^2} \right| \tag{7}$$

$$S_T = \frac{3Md_{31}bl^2y(c_{11}-\varepsilon \cdot c_{12})}{20EIC} \cdot G, \text{ 微加速度計敏感度}$$

度

此例微加速度計為一靜態問題，在輸出指標方面，理想的微加速度感測器之敏感度值為越大越好。本研究採用訊號噪音比作為目標函數，並將此問題定義為望大型 (Larger-the-better) 的設計問題，除希望得以增加輸出增益，也應同時降低輸出因噪音所產生的變異，定義目標函數如式(8)。

$$\eta = -10 \cdot \log_{10} \left(\frac{1}{n} \sum_{i=1}^n \frac{1}{\beta_i^2} \right) \tag{8}$$

4.2 微加速度計穩健化設計

微感測器具有跨領域系統整合的優勢，故其分別在材料、機與電特性方面皆可能存在相當的影響。其中誤差不僅影響機械結構，也將使微感測器在量測時造成輸出變異。而此些影響因素在製程中相當難以預期或者控制成本相當昂貴，若要有效達成穩健化設計，必須考慮各種設計變數中主要影響輸出變異的因子。我們分別使用田口品質工程與 ERNGA 兩種方式進行設計穩健化，並比較此兩者之間的差異。

4.2.1 設計參數與誤差因子

本微加速度計的初始設計採用四懸樑對稱結構，在每一懸樑上分別鍍上兩片 PZT 壓電材料及電極做為轉換器，結構外型尺寸如圖 5 所示。




圖 5 加速度微感測器結構尺寸

由系統轉換函數可知，影響微加速度計輸出的因子包括了機械結構及電性控制因子：如懸樑的長度 l 、懸樑的寬度 b 、懸樑的厚度 h 與振動質塊重量 M 共 4 個控制因子。這些控制因子不管對於機械敏感度或電性敏感度皆有影響，而懸樑寬度 b 不但影響整個結構之剛性，同時也關係到 PZT 薄膜尺寸，影響其電容值，故以此作為控制因子並予以 3 水準化，各水準值設定如表 3 所列。

表 3 微加速度計控制因子水準設定

	Level 1	Level 2	Level 3
懸樑長度 l	400	500	<u>600</u>
懸樑寬度 b	160	<u>200</u>	240
懸樑厚度 h	<u>15</u>	25	35
質塊質量 M (質塊寬度 l_M)	0.2749 mg (800)	0.3690 mg (900)	<u>0.4775 mg</u> (1000)

注：加著底線之水準為初始設計

(單位：μm)

表 4 微加速度計噪音因子水準設定

Parameter	Level 1	Level 2	Level 3	Level 4
ω (rad/sec)	380	10345	21070	31416
Δl (μm)	-2.0	+2.0		
Δb (μm)	-2.0	+2.0		
Δh (μm)	-2.5	+2.5		
ΔM (μm)	-5%	+5%		
ΔE (GPa)	-2.0	+2.0		
$\Delta \varepsilon$ (F/m)	-0.05×10 ⁻⁹	+0.05×10 ⁻⁹		
Δd_{31} (C/N)	-5×10 ⁻¹²	+5×10 ⁻¹²		
ΔG	-10	+10		

噪音因子方面，由於在製造上所產生的誤差變化，主要可分為兩類：其一為微感測器結構之製造誤差，包括微影轉換誤差 (Lithographic Transfer Errors) 與微細加工誤差 (Micromachining Errors)。其主要是因光阻上的圖案未被完全無誤地轉移至薄膜上，以及取決於蝕刻劑的穩定性；另一則為相同材料特性的差異。在製作過程中，可能因製程及周遭環境之影響而造成材料特性誤差。尤其是薄膜的機械參數變異，一般具有目標值 10—20% 之不確定性。這些誤差包括：楊氏模數 (Young's modulus)、柏松比 (Poisson's Ratio)、密度

(Density)、介電常數 (Dielectric constant) 及電阻率 (Resistance) 等。另外，若在基材上沈積一層不同於基材的薄膜材料，可能會因為薄膜的晶體方向、兩材料間不同的熱膨脹係數及匹配性等問題，使得材料介面應力及彼此間之交互作用的產生，而影響薄膜之組成及性質。

綜合上述說明，這些誤差在微機電製程中係難以穩定操作或控制成本過高的因子，若忽略此些因子，可能使得系統輸出結果突然驟變，而影響產品或元件性能，故我們在設計階段過程中一併列入考慮。微結構尺寸誤差方面，主要歸劃影響甚鉅的 4 個干擾因子：懸樑的長度 Δl 、懸樑的寬度 Δb 、懸樑的厚度 Δh 及振動振動質塊重量 ΔM 。而材料特性的不確定性方面，其所造成干擾因子有 4 個：懸樑的楊氏係數變化 ΔE 、PZT 壓電材料的介電常數變化 $\Delta \epsilon$ 、壓電係數 Δd_{31} 及放大電路之放大倍率 G 之誤差等。此外，微加速度微感測器之輸出在不同工作頻域下頻率響應增益值的變化，也是一個重要的誤差來源，因此將微加速度之振動頻率 ω 視為噪音因子，共計 9 個噪音因子。

4.2.2 田口方法

本實驗具有 4 個 3 水準之控制因子，因此選擇 $L_{18} (2^1 \times 3^7)$ 為內直交表。而噪音因子共計有 1 個 4 水準及 8 個 2 水準因子，故選用 $L_{16} (2^{15})$ 外直交表。將選定的控制因子及噪音因子之各水準設定值分別代入內外直交表中，以進行實驗配置。如圖 6 所示根據 S/N 比極大化的準則，將量小化於各因子對性能設計目標的影響，再經由平均值分析以及線性加成法的計算，預測使產品品質損失最低之參數水準組合。




圖 6 微加速度計於各因子影響訊噪比之折線圖

4.2.3 類神經網路建構

在學習樣本配置於直交表方面，其中 l, b, h, M 此 4 個控制因子賦以 3 水準化，而將 $\Delta E, \Delta \epsilon, \Delta d_{31}, \Delta G$ 此 4 個噪音因子予以 2 水準化，而為使振動頻率 ω 能廣泛分佈於各頻域中，故給予其 4 水準化。而相對於田口方法中的 $\Delta l, \Delta b, \Delta h, \Delta M$ 共 4 個因子，在此並無需配置於直交表內，因我們可善用類神經網路中非線性內插特性，將控制因子的偏移以網路模型中的回想方式擬合求得，故在此實驗計畫中並不需要額外配置干擾因子。我們選用 $L_{36} (4^1 \times 2^8 \times 3^{12})$ 直交表，以行合併法將第 1、2 與第 3 行合併成為 1 個 4 水準行，放置參數 ω ，將選定的控制及噪音共 9 個因子置入於單一 L_{36} 直交表，以進行實驗配置。

此外，為更加貼近實際驗證設計所面臨問題，突破田口方法中難以將噪音因子精確的控制在此特定誤差水準值的問題。在實際進行實驗時容許誤差在一個標準差內，模擬製造上誤差的考量以降低成本

控制成本。故我們分別在此 36 組實驗樣本中加入隨機誤差 (除 ω 之外)，以當作實際驗證欲控制水準值所面臨因子之誤差。將原始學習範例配合隨機容差依序改變後，作為類神經輸入層的學習範例。假設其公差範圍分佈於六標準差 (6σ) 內，因此可訂定為每一個因子標準差為 ($\sigma = \Delta / 3$)，並使水準點隨機分佈在此範圍內，以擬作實際驗證所得之偏差。

4.3 結果比較與討論

圖 7 為 ERNGA 預測與理論值之訊噪比迭代關係圖。然而雖在第 7 次迭代時存有相當大幅的誤差變化，但下次迭代經過此點學習範例加入後，網路模型即能夠增加此區域的擬合而修正整體趨勢。在 ERNGA 逐步演化後，最佳點預測也漸進入一平穩收斂傾向。

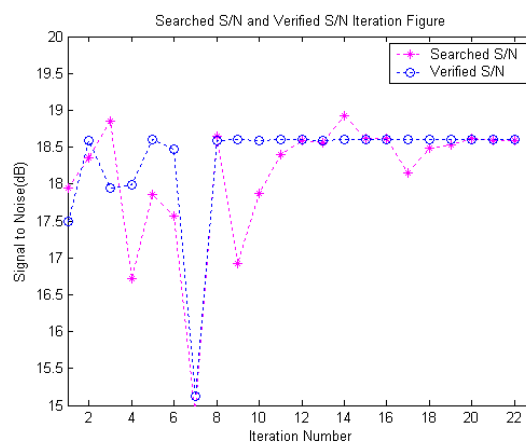


圖 7 ERNGA 於微加速度計之訊噪比迭代圖

表 5 微加速度計穩健最佳化參數比較

Design Parameter	Taguchi	ERNGA
$l (\mu m)$	600	600
$b (\mu m)$	160	160
$h (\mu m)$	15	15
$M (mg)$	0.4775	0.4775
$l_{mt} (\mu m)$	(1000)	(1000)
Simulate S/N (dB)	18.31	18.59
Verified S/N (dB)	18.60	18.60
Experimental Number	288	136

初始設計訊噪比輸出為 16.52 dB。在 ERNGA 與田口皆以相同的設計水準範圍以作比較，由表 5 可清楚的比較兩者方法的結果。田口方法雖能找一較穩健設計，但其實驗多寡是由為內 (L_{18}) 與外直交表 (L_{16}) 配置的乘積來決定，相較於實驗次數卻高達 288 次。反觀 ERNGA 尋優方面，其只需初始學習範例 48 組加上 22 次迭代，總共 136 次實驗即可預測出與田口方法之訊噪比相當的設計點，所耗費之成本相對的將省一倍之多。此外，ERNGA 在驗證實驗中，並不需要將噪音因子精確的控制在此特定水準值上，只需依照一般加工精度或控制標準即

可，大幅的簡化實驗程序與降低控制成本，並賦與實際工程問題有更多的彈性。

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成法預測只能在因子水準值上，無法使用內插或外插。如果實驗結果受到非線性系統與控制因子間強烈交互作用的影響而導致預測失敗，則使得實驗數據無法再重複利用。

若以 ERNGA 方式尋優，實驗次數只需 136 次實驗即可預測出與田口方法之訊噪比相當的設計點，相較於田口方法需 288 次才能完成，節省成本高達一倍以上。此外，ERNGA 在驗證實驗中，並不需要將噪音因子精確的控制在此特定水準值上，只需依照一般加工精度或控制標準即可，大幅的簡化實驗程序與降低控制成本，將賦與實際工程問題有更多的彈性。綜合以上論述與結果，ERNGA 所獲得最佳值與實驗次數都較田口方式更具競爭優勢。代表本研究所提之方法，能有效降低實驗成本，且亦能提升設計品質。

參考文獻

- [1]. G. Taguchi, "Performance Analysis Design.", *International Journal of Production Research*, vol.16, pp.521-530, 1978.
- [2]. Ho, N. C. , Lee, S. S. , Loh, G. Y. L. and Nee, A. Y. C., "Two-Stage Approach for Optimizing Simulation Experiment.", *CIRP Annals*, vol. 42 no.1, pp.501-504, 1993.
- [3]. D'Entremont, K.L. and Ragsdell, K.M., "Design for Latitude Using TOPT. ", *ASME Advance in Design Automation*, DE-vol. 14, pp.265-272, 1988.
- [4]. Balaji Ramakrishnan and S.S.Rao, "A General Loss Function Based Optimization Procedure for Robust Design", *Engineering Optimization*, pp.255-275, 1994.
- [5]. M. Tribus and G. Szonyi, "An alternative view of Taguchi approach", *Quality Progress*, pp.46-52, 1989, May.
- [6]. K. M. Tay and C. Butler, "Modeling and Optimizing of A Mig Welding Process-A case Study Using Experimental designs and Neural Networks", *Quality and Reliability Engineering International*, vol.13, pp.61-70, 1997.
- [7]. 余志成、曾譽龍，"演化型類神經網路信賴空間於稀少訓練樣本的設計最佳化"，*中華民國第十三屆模糊理論及其應用會議論文集*，高雄、台灣，2005。
- [8]. C. T. Su, C. C. Chiu and H. H. C., "Parameter Design Optimization via Neural Network And Genetic Algorithm", *International Journal Of Industrial Engineering*, vol.7, pp.224-231, 2000.
- [9]. T. Taguchi, T. Yokota, and M. Gen, "Reliability Optimal Design Problem with Interval Coefficients Using Hybrid Genetic Algorithms", *23rd International Conference on Computer and Industrial Engineering*, vol.35, no.1-2, pp.373-376, 1998.
- [10]. 賴富信，余志成，"壓電薄膜微加速度計之設計系統模擬與頻率響應穩健化"，*中國機械工程學會第十七屆全國學術研討會論文集*，高雄，2000。