

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

余志成* 曾譽龍[§]

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* ext.2267[§]

Fax : (07) 6011066

E-mail : jcyu@ccms.nkfust.edu.tw* u9314820@ccms.nkfust.edu.tw[§]

本研究承蒙國科會支持，計畫編號 NSC93-2216-E-327-001

摘要

本文探討當類神經網路的初始學習樣本稀少時，對網路模型準確度的影響，並提出神經網路信賴空間的觀念，與信賴半徑的模糊推論法則，應用於遺傳演算法最佳化設計的搜尋。類神經網路常應用模擬複雜的數值的問題上，但實際的工程問題常受制於時間與成本之考量，不能提供足夠或均佈的實驗樣本，或是直接以現有的現場資料來建立模型，往往造成模擬網路不具有全域的準確性，若直接應用於全域最佳化搜尋，其搜尋結果往往具有相當大的誤差而缺乏實用性。鑑於類神經網路模型的特性，即當模擬點離學習樣本越近，其準確度越高，而內插設計的預測值準確度也會高於外插設計的準確度，本文訂定模糊準則來調整內、外插信賴半徑，建立網路模型之信賴空間，來限制迭代過程中基因演算法所搜尋的範圍，藉以提昇預測結果的有效性。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。文末利用直交表實驗與隨機採樣結合典型的數值案例，論證此方法於演化型最佳設計之優點。

關鍵字：類神經網路、基因演算法、信賴空間、工程最佳化

Abstract

This paper studies the effect on the prediction accuracy of neural network if the model has limited initial training samples. We propose the concept of evolutionary Neural Network model that is consisted of reliable regional space, and apply to the search of the global optimum using Genetic Algorithm. Neural networks are often applied to simulate the response of a complex numerical system. However, in practice, the number and the distribution of training samples are limited due to cost and time constraints. Sometimes,

existed field data, which might be not well designed, are applied to establish the model. Therefore, the initial network model usually lacks the global accuracy and the optimum search directly from the model is liable to significant errors. General heuristic rules of network model suggest that the prediction accuracy of the model is closely related to the distances between sampling points and the evolved designs, and the interpolation designs usually have better prediction accuracy than the extrapolation. This paper proposes the interpolation and extrapolation radii to define the reliable space surround the training samples, and confine the GA search of optimum in the reliable space to ensure the searching reliability.

The generated local optimum from GA search is introduced to the training samples to retrain the evolutionary neural network. The sampling points will then congregate on the most probable regions of global optimum, and increase the sample efficiency. The searching process iterates until the convergence of the optimum. The numerical examples for the cases of orthogonal array experimental design and random samples for the initial training samples are presented at last to illustrate the advantage of the proposed scheme.

Keywords: Neural network, Genetic algorithm, Evolutionary reliable region, Engineering optimization

1. 前言

最佳化方法大致可分為傳統數值最佳化方法與啟發式隨機搜尋法(Heuristic random search)，傳統最佳化方法易陷於局部最佳解，求得的解往往是所謂的近似最佳解。另一方面主要是智慧型模擬演化型最佳化(Simulated Evolutionary Optimization)，如基因演算法(Genetic Algorithms, GA)及模擬退火法(Simulated Annealing SA)，與禁忌搜尋法(tabu search, TS)等，主要應用於全域最佳化。Su[1]等利用基因演算法(Genetic Algorithm, GA)可以處理

* 聯絡作者

非線性、不連續、不可微分等複雜的最佳化問題之特性，應用於氣體輔助射出成型，在非線性的網路模型中獲得近似全域最佳解。Su[9]等則使用模擬退火法 (Simulated Annealing, SA) 來進行最佳化搜尋，其效果與基因演算法相當。Jang[5][10]等整合 GA 與 SA 的特徵，先以每一實驗點為中心劃分各自局部信任空間，以隨機方式在各空間內選取一些候選點；再以新的候選值為中心逐漸縮小各搜尋空間。最終的候選點則利用模糊分類 (Fuzzy Classification) 將之分成數類，以各分類的中心點做為下一次的實驗點。然而這些方法，常需要大量的世代搜尋，多適用於數值模擬的最佳化，不適用需以實驗獲得系統參數與輸出的工程問題。

類神經網路不需要隨設計型式而選擇特定的數學函數，所以常用來模擬複雜系統之響應曲面，藉以配合演化型搜尋法，進行全域的設計最佳化。Cios 等人[3]使用舊有的實驗資料作為倒傳遞類神經網路的訓練樣本，藉以模擬系統輸出關係，若當訓練樣本數量不夠或不具代表性時，再增加新的實驗資料來彌補其不足。Sitarama[4]等藉由全因子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水刀的切割厚度，再以基因演算法配合權重計算，進行多目標全域最佳搜尋。雖然模糊近似推論的規則比類神經網路的權重矩陣較易直覺訂定，但必須另外調整歸屬函數與規則衝突等問題。

為確保模擬系統的全域準確性，一般類神經網路需採用大量的學習樣本，然而當成本與實驗點數目受限時，因無法提供足夠或均佈的實驗點，此時並非全域的模擬空間皆可信，模擬系統的準確性可能侷限於局部的設計空間，而全域的準確性在最佳化搜尋中並非必要，若能在最佳化可能出現的區間增加訓練樣本，提升該區域的準確性，便能有效的不必要採樣成本。然而一般文獻中，對於如何結合最佳設計搜尋法的影響與採樣策略並無詳細的探討。

2. 類神經網路的訓練與預測準確性

2.1. 類神經網路的採樣與訓練策略

本文採用倒傳遞類神經網路(Back-propagation Neural Networks, BPNNs)，BPNN 屬於監督式學習網路，樣本多寡與採樣分佈對於類神經網路的精確性有相當大的影響。但對於實際工程問題而言，可利用現有的實驗資料作為初始的訓練樣本，當然這些樣本的數目與分佈是不可預期的，可能產生採樣不良(ill sampling)的問題，但若能有效運用這些現場樣本(field data)，將可節省許多實驗成本。

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，以直交表配置規劃實驗，不僅可利用統計學的優點降低實驗的採樣數量，亦具有均佈的特性。我們利

用 3 水準點直交表規劃學習樣本 (learning samples)，而在學習樣本的內部空間，規劃 2 水準點的直交表作為測試樣本。圖 1 中為三個變數的採樣例，以 L9 作為學習樣本，L4 直交表作為測試樣本。

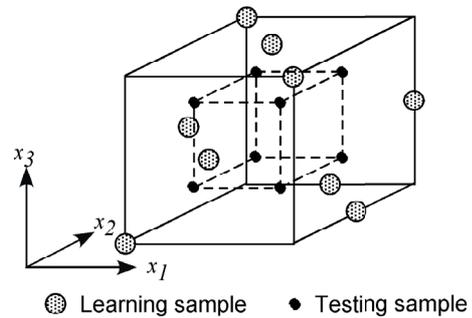


圖 1. 以直交表作為訓練樣本

當利用少量的實驗樣本去訓練類神經網路模型時，其預測結果將明顯有別於多樣本點之神經網路。一般訓練類神經網路模型必須利用大量的實驗樣本，方能獲得極佳的預測結果，但若只是應用於最佳設計點的搜尋，系統擬合的精度的整體提昇也並非必要，尤其在成本與時間的考量下，更是限制了實驗樣本的數量。有鑑於此，只要在有機會存在最佳化設計點的附近增加採樣，提升類神經網路局部的模擬準確度與學習樣本的效率，屆時只需針對局部做最佳化搜尋，即可符合工程最佳解的應用需求。

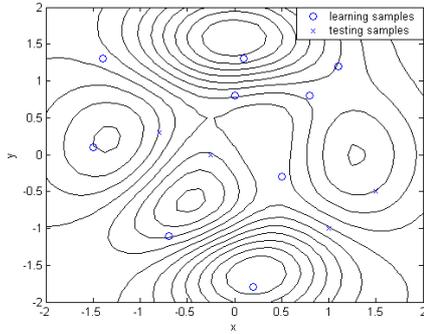
對於樣本不足的網路模型其準確性自然有其限制，因此在神經網路的訓練應避免過度學習的問題。本文採用及早停止之條件，當學習誤差小於工程容差，或是測試均方差與學習訓練樣本的均方差大於一定比例時，即停止訓練，以免影響網路模型的普遍性(generality)。

2.2. 稀少訓練樣本之網路模型的準確特性

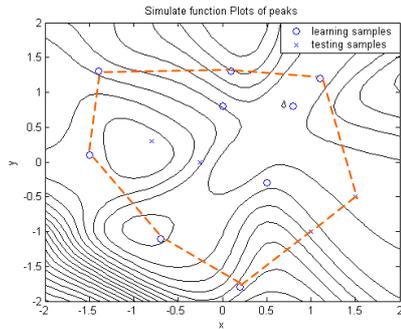
類神經網路的模擬準確度一般將隨著實驗樣本數目的減少而降低，一般工程問題受限於時間與成本，樣本數目往往不足，所訓練出來的神經網路模型，其準確度自然受到限制，因此必須設立相關的有效區間機制，以免模擬誤差太大，造成最佳化搜尋過程的發散或效率不佳。而由擬合模型的特性可知，一般存在著當預測點距離學習樣本點越近其準確度將會提高；反之，距離學習樣本點越遠其準確度將隨之降低；而內插設計的準確性也會高於外插設計的固有特性[11]。本節將以一個二維多極值 peaks 非線性函數數值例，來說明預測準確度的特性。

$$z = 3(1-x)^2 e^{-x^2-(y+1)^2} - 10\left(\frac{x}{5} - x^3 - y^5\right) e^{-x^2-y^2} - \frac{1}{3} e^{-(x+1)^2-y^2} \quad (1)$$

以隨機九個學習樣本點如圖 2(b)中的空心圓點，訓練一個類神經網路其模擬模型的預測響應曲面如圖 2(b)等高線圖所示，可看出與實際系統響應圖 2(a)存在相當的誤差。為了瞭解倒傳遞類神經網路預測模型的準確度的分佈特性，我們利用隨機取樣方式在等高線圖面範圍內隨機採樣 180 點，並計算預測設計與學習樣本點間之最小距離，並統計其網路模型預測值與實際值之誤差列於表 1。



(a) 實際 Peaks 函數的等高線圖



(b) 類神經網路模擬之響應曲面

圖 2 實際與類神經網路模擬之 Peaks 函數等高線圖

表 1 內外部隨機抽樣點預測值與實際值誤差

內外設計區域別	距離學習樣本的最小距離	預測誤差平均值
內插設計	0.2 以下	1.028
	0.2-0.5	1.802
外插設計	0.2 以下	1.079
	0.2-0.5	3.315
	0.5-1.0	5.804

圖 2(b)中將學習樣本的外圍以直線連接成一凸多邊型，藉以區分內插與外插設計點。從表 1 中可以清楚的驗證之前的經驗假說：

- (1) 當預測點距離訓練樣本點越遠其預測準確度將會越低。
- (2) 內插設計的模擬準確性高於外插設計的準確度。

2.3. 內、外插設計的定義

在多維變數的設計空間中，本文將包圍所有訓練樣本點的最小凸多邊體 (Convex Hyper Polyhedron) 定義為樣本包圍空間 (Sampling Enclosure Space, SES)，藉此作為判斷該預測點為網路模型內插或外插的邊界。在包圍空間內點稱為內插設計，而在空間外的點則稱為外插設計。

樣本包圍空間邊界的判斷，是從訓練樣本 m 點中取出不共面的 n 點，以求出一組 n 維度的超平面 (Hyperplane) 如式(2)，最多可找出超平面方程式組合有 C_n^m 個。

$$\sum_{j=1}^n c_{ij}x_j + c_{io} = 0 \quad (2)$$

n 表示維度， i 表示第 i 組超平面

將 m 點差集 n 點之學習點，依序帶入每一組 n 維所組成的通式中計算出函數值 $y_i(X)$ 如式(3)。若存在一超平面其所有的 $y_i(X)$ 值皆同號或等於零，則代表此平面為學習樣本包圍空間的邊界面，在反覆檢驗所有的超平面之後，可將 SES 的包圍超平面全部找出來。

$$y_i(X) = \sum_{j=1}^n c_{ij}x_j + c_{io} \quad (3)$$

2.4. 樣本距離

為了計算預測點與每個樣本的距離，必須先對輸出變數進行正規化，以式(4)將類神經網路的輸入層參數 x 對映至 $[-1,1]$ 的 z 區間，以便於推論法則的運用並增進網路的學習效果。另一方面也可避免各變數間的尺度問題 (Scaling Problem)，造成計算結果受少數數值較大的參數所主導。

$$z_{kl} = \frac{\left(x_{kl} - \frac{(\max(x_k) + \min(x_k))}{2} \right)}{\left(\frac{(\max(x_k) - \min(x_k))}{2} \right)} \quad (4)$$

本文使用平均歐氏 (Mean Euclid Distance) 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，第 i 個預測點至第 j 個樣本點的歐氏距離如(5)式所示。

$$r_{ij} = \left[\frac{1}{n} \sum_{k=1}^n (P_{ik} - S_{jk})^2 \right]^{0.5} \quad (5)$$

n 表示維度， P_i 為預測點 i ， S_j 為樣本點 j

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氏距離後，採用最短的距離作為輸出預測信賴度的評斷準則如式(6)。本文將此稱為最小樣本距離 (Minimum Sampling Distance, MSD)。

$$MSD_i = \min(r_{ij}) \quad (6)$$

3. 類神經網路與演化型設計最佳化

本文所提出的演化型類神經網路最佳化方法，主要探討實際工程問題中，實驗樣本數目受於時間與成本的限制，因此影響模擬網路的全域可信賴性，藉由類神經網路訓練樣本分佈與準確性的關聯性，提出以信賴半徑(Reliable Radius)限制類神經網路模型的可信區間(Reliable Region)，以提供基因演算法(Genetic Algorithm)搜尋可信區間內的最佳設計，反覆學習演化局部模擬模型。並藉由驗證局部最佳化設計的準確性，以模糊推論法調整類神經網路模型的可信區間，使其逐漸趨近最佳解，以解決類神經網路因學習樣本不足而延伸的全域不準確性，避免基因演算法搜尋過程發散，並能增進搜尋最佳解之效率，圖 3 為演化型類神經基因演算法最佳化流程圖。

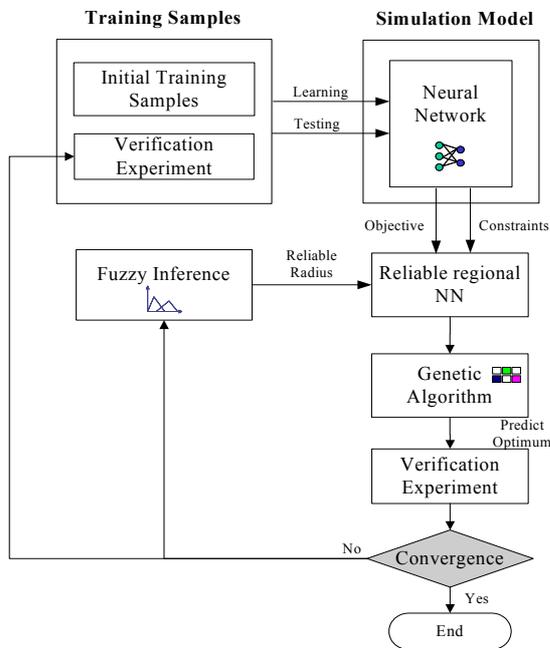


圖 3. 演化型類神經基因演算法最佳化流程圖

3.1. 類神經網路的信賴空間

對於稀少學習樣本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局部區域，由 2.2 節的分析，可瞭解預測點與學習樣本間的距離越遠，其預測誤差越大，而內插點的設計較外插點設計具有較高的準確性。

由實際模型(圖 2(a))與類神經模擬模型(圖 4)的比較可看出，因採樣樣本點的稀少(13 點)，即使藉由網路學習的最佳化，所模擬出的類神經網路與實際模型存在相當大的差異，自然不具有全域的可信賴，若直接使用 GA 搜尋模擬網路的最佳解，其預測結果往往具有非常大的誤差。反之，因為訓練樣本附近的模擬結果具有較大的可信度，若

能夠藉此制訂網路模型的信賴空間，並限制基因演算法於信賴空間搜尋，便可求得區域的最佳解。表 2 比較這兩種方式，可看出過度信賴稀少樣本所訓練的神經網路，所搜尋到的最佳化結果誤差非常大，而若只搜尋訓練樣本點附近的區間(如圖 4 的灰色區間所示)，則可找到區間內的最佳解，而其模擬結果與實際值相當接近。雖然搜尋方式趨於保守，而結果也非全域最佳化，但可藉由將此次搜尋結果加入訓練樣本，藉由逐步演化擴張信賴空間，便可有效的在可能出現最佳化值的區域增加樣學習樣本，進而增加搜尋結果的效率與準確性，因此接下來的課題便是如何定義信賴空間。

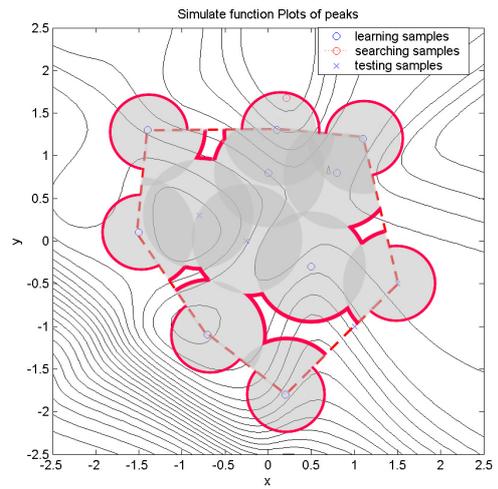


圖 4. 類神經網路模擬之響應曲面與局部信賴空間 (RIR = 0.3, RER = 0.2)

表 2. GA 搜尋全域與區域神經網路的比較

GA Search	x	y	Simulat. Value	Exact Value
Global NN	-3.555	3.978	13.831	1.07e-023
Regional NN	0.015	1.639	9.403	7.593

3.2. 信賴半徑的模糊推論

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，另一則為預測點與實驗點的誤差值如式(7)，本研究提出模型誤差指標(Modeling Error Index, MEI)作為評估網路模型預測準確性的，MEI 係藉由模型預測 GA 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訓練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，文中所有的歸屬函數將利用典型的三角形及梯形函數表示。

$$\text{Modeling Error Index (MEI)} = \frac{|Y_j - T_j|}{RMSE_{Total}} \quad (7)$$

Y_j 為類神經預測輸出，

T_j 為實驗點輸出，

$RMSE_{Total}$ 為訓練樣本的均方根誤差

當最佳設計預測誤差接近 $RMSE_{Total}$ 時，代表模型預測準確度與一般性佳，因此在下一次迭代時可考慮放大信賴半徑，藉以增加 GA 搜尋的空間。而當最佳設計預測誤差大於 $RMSE_{Total}$ 時，代表模型預測準確度不佳，可考慮降低信賴半徑，避免 GA 搜尋到不可靠的網路模型區間，而得到錯誤的結果。因此本節將模型誤差歸屬函數的設定如圖 5 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 6 所示。

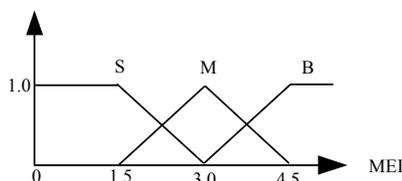


圖 5. 模型誤差指標之歸屬函數

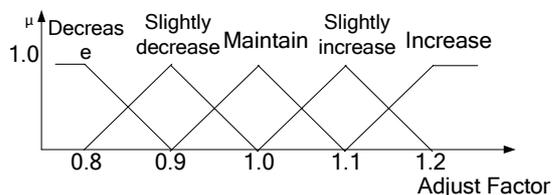


圖 6. 調整信賴半徑之歸屬函數

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。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。

當 GA 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，則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，將會逐漸朝往最佳值區域接近，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。即使在極端例子中，模型預測不準確，造成內、外半徑持續遞減，但因增加的學習樣本點仍會使的搜尋空間逐漸擴大，方不至於搜尋空間封閉於固定區域。或是對於

簡單的模型，少數樣本點就可訓練出很準確的網路模型時，也會自動放大搜尋區間，減少遞迴的次數。

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 [Increase] RER and [Increase] RIR
- (2) If Extrapolation and prediction error is [Medium] then [Slightly Increase] 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)，調整內插與外插信賴半徑，使用於下一次的迭代：

$$RIR_{i+1} = AF_i \times RIR_i \quad (8)$$

$$RER_{i+1} = AF_e \times RER_i \quad (9)$$

4. 典型數值案例分析

本節利用 Peaks 函數，如式(1)；說明所提出最佳化策略的應用。此函數為一雙變數之三維空間圖形，其輸出值分佈等高線如圖 2(a)所示。應用本文所提出之演化型神經網路信賴空間 (Evolutionary Reliable regional Neural network, ERN) 於全域極大值之搜尋。我們採用兩種不同的訓練採樣方式：隨機樣本與直交表實驗計畫，運用本文所提出的方法進行設計最佳化，並與傳統的全域 NN 與 GA 搜尋方式比較。

首先，利用先前類神經網路學習與測試之初始樣本點，作為基因演算法之初始設計族群，隨後在訓練好的神經網路中搜尋，經由選擇、交配及突變過程篩選出較佳之新設計族群。計算適應函數值；另一方面則以公式(1)進行實驗獲得實際值，由實驗值與適應函數值間的誤差作為調整下一次神經網路信賴空間的推導，並將此組參數組合加入類神經網路之學習樣本點，反覆逐至誤差收斂求得最終之全域最佳設計。

4.1. 直交表實驗取樣

假設目前並無任何現場資料，而需藉由實驗計畫規劃訓練樣本，我們以先前所提出的直交表實驗方式進行採樣，學習與訓練樣本的分佈如圖 7，此時理論的最佳化設計點是落在初始的包覆空間內，但由學習點的分佈比對實際的函數等高線圖 2(a)，可知其採樣點大多落於平坦的區域，將會造成初始訓練網路的誤差很大，但隨著 ERNGA 的迭代其如圖 7 的最佳點迭代編號，初始最佳點會逐步的依照信賴區間內搜尋，當搜尋迭代不斷增加時，會在較佳點附近不斷增加採樣點，以提高局部模擬準確度，而逐漸收斂到最佳設計，其迭代結果如圖 8 所示。

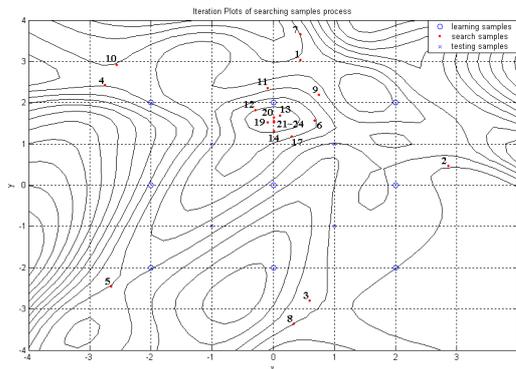


圖 7 搜尋最佳點之迭代過程

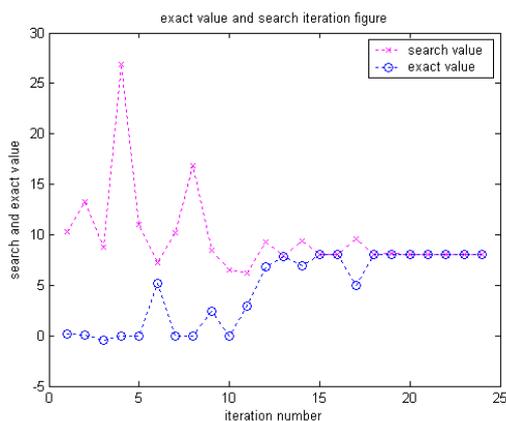


圖 8 以 ERNGA 迭代收斂結果 (最佳設計在初始直交表的包覆區內)

另外，再規劃一次直交表實驗，但使其最佳設計在初始的包覆空間外，藉以測試演化模型是否會向外擴張，其迭代結果如圖 9 所示。

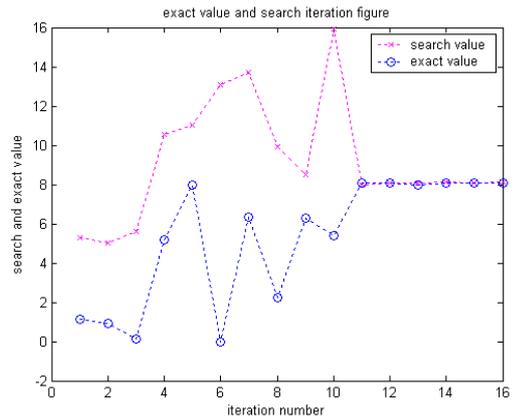


圖 9 以 ERNGA 迭代收斂結果 (最佳設計在初始直交表的包覆區外)

4.2. 隨機樣本取樣

利用隨機抽樣方式於初始訓練樣本，模擬既有現場實驗資料的情形。每組包含 13 個樣本點；任意選取其中 4 個作為測試樣本，其迭代結果如圖 10 所示，也順利搜尋到最佳值。

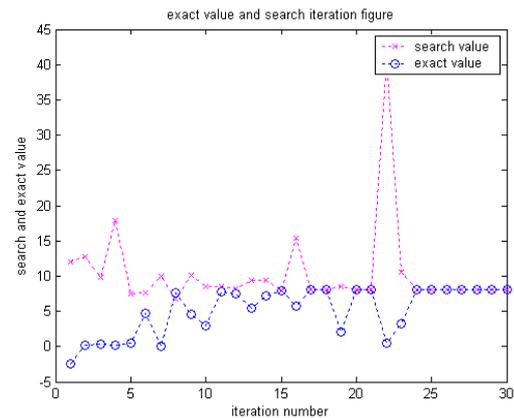


圖 10 以 ERNGA 迭代收斂結果 (初始訓練樣本為隨機樣本)

4.3. 結果比較與討論

將傳統類神經基因演算法的迭代結果 (圖 11) 與演化型類神經網路最佳化 (圖 8~圖 10) 比較。以同樣的網路模型訓練與 GA 搜尋策略，傳統類神經基因演算法對神經網路的全域準確性相當敏感，迭代過程會有明顯震盪的現象，難以收斂於一定值。且將演化型類神經網路最佳化 (圖 7) 與類神經基因演算法的迭代過程 (圖 12) 比較，發現後者即使曾經搜尋至較佳解的附近，但仍因稀少樣本訓練的模擬模型在全域並非可信，而造成較佳值無法收斂或迭代效率較差。尤其對於採樣不良的類神經網路，其於外插區域模擬誤差往往過大，使 GA 誤以為找到最佳值，雖然震盪過程中曾接近理論最佳設計，但因無收斂現象，無法得知最終結果。

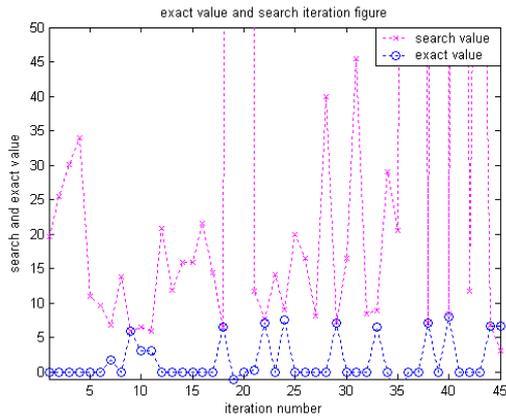


圖 11 傳統 NNGA 最佳化迭代收斂結果(初始訓練樣本為田口樣本)

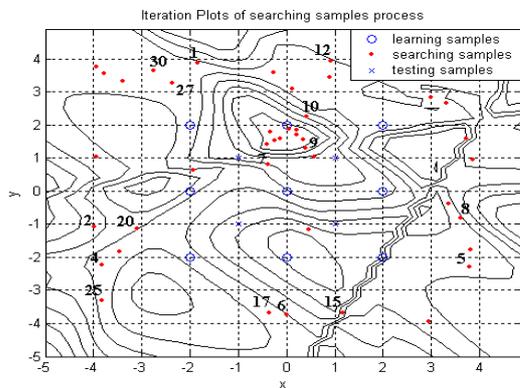


圖 12 搜尋最佳點之迭代過程 (GA 搜尋區域[-4, 4])

而在演化型神經網路信賴空間的搜尋結果，不論初始訓練樣本是直交表實驗或是隨機採樣，都順利收斂到全域最佳設計，GA 搜尋侷限於學習樣本點附近的信賴空間，而信賴空間隨網路模型的準確性自動調整，藉由迭代反覆演化學習，逐漸逼近最佳值，如圖 10 中在第 22 次迭代時雖有很大的誤差，但系統隨即於下一次迭代過程調整信賴空間，避免過度震盪的情形發生。而藉由逐步演化的方式，即使因樣本點數目的限制無法搜尋至收斂，甚至中途停止，運用模糊類神經網路仍可提供合理的較佳設計。

5. 結論

本文所提出演化型神經網路型信賴空間的概念，利用超幾何樣本包覆空間內外插設計的判別，配合模糊推論法調整信賴半徑，智慧的調整網路模型的信賴空間，以 GA 進行設計最佳化，成功的應用於稀少學習樣本點情況下。藉由限制基因演算法搜尋於逐步演化擴張的神經網路信賴空間，增加 GA 搜尋結果的可信度，避免因過度信賴網路模型的全域準確性，造成應用最佳化設計搜尋時的震盪。未來將測試在多變數的典型數值例的適用性。

6. 誌謝

本研究承蒙國科會支持，計劃編號 NSC93-2216-E-327-001，特誌謝意。

7. 參考文獻

- [1]. C. T. Su, C. C. Chiu and H. H. C, "Parameter Design Optimization via Neural Network And Genetic Algorithm", *International Journal Of Industrial Engineering*, 7(3), 224-231, 2000.
- [2]. D.B. Fogel, "A Introduction to Simulated Evolutionary Optimization", *IEEE transactions on Neural Networks*, vol. 5, No. 1, Jan. 1994.
- [3]. K. J. Cios, G. Y. Baakliimi 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.
- [4]. 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.
- [5]. J. Chen, D. S. H. Wong, S. S. Jang and S. L. Yang, "Product and Process Development Using Artificial Neural-Network Model and Information Analysis", *Journal of the AIChE*, Vol. 44, No. 4, 876-887, April 1998.
- [6]. S. Nandi, S. Ghosh, S. S. Tambe, B.D. Kulkarni, "Artificial neural-network-assisted stochastic process optimization strategies", *Journal of the AIChE*; v.47, n.1, pp. 126-141, Jan, 2001.
- [7]. J. Yu, X. Chen, T.R. Hung and F. Thibault, "Optimization of Extrusion Blow Molding Processes Using Soft Computing and Taguchi Method", *Journal of Intelligent Manufacturing*, 15, 625-634, 2004.
- [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]. 曾衍迪、金光海、鄭西顯，"人工智慧類神經網路實驗設計軟體(ANNDOE)之發展"，*化工技術*第七卷第三期，1999。
- [11]. 莊志勇、余志成，"應用模糊局部類神經網路於演化型最佳化方法之研究"，*中華民國第十二屆模糊理論及其應用會議論文集*，2004。