

演化型局部類神經網路結合遺傳演算法於工程設計最佳化

余志成*、曾譽龍

國立高雄第一科技大學 機械工程研究所

jcyu@ccms.nkfust.edu.tw*

摘要

本文探討稀少的初始學習樣本，對類神經網路模型預測準確度的影響，並藉由信賴半徑的模糊推論法則，提出網路模型的信賴空間，應用於基因演算法最佳化設計的搜尋。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，或需以現有資料，來訓練類神經網路模型，因而影響模擬網路的全域準確性。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。鑑於稀少學習樣本的類神經網路模型，其預測可信賴區域，常侷限於訓練樣本的附近，且內插設計較外插設計具有較高的預測準確度，本文提出模糊推論準則來演化網路模型的之信賴空間，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，使得學習樣本集中在可能發生最佳點的附近採樣，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：演化型最佳化，基因演算法、模糊推論、工程最佳化、類神經網路

1. 前言

模擬演化型最佳化(Simulated Evolutionary Optimization) [5]，如基因演算法(Genetic Algorithms, GA)及模擬退火法(Simulated Annealing SA)，由於可以處理非線性、不連續、不可微分等複雜的最佳化問題，常應用於全域最佳化的搜尋。Chen等[3]等更整合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。

類神經網路始於對生物神經網路內部傳遞的觀察，衍生出的計算觀念。具有平行處理與容錯的優

點，以及高度的學習能力與非線性對應 (Nonlinear Mapping) 的功能。其中倒傳遞網路 (Back-propagation Network, BPN)的架構是以第一層為輸入層、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。藉由學習(Learning)與測試(Testing)樣本訓練網路單元間的權重矩陣與判斷網路預測的準確性與普遍性[6]。由於類神經網路不需要隨設計型式而選擇特定的數學函數，適宜模擬複雜系統之響應曲面。智慧型最佳化便結合類神經網路與遺傳演算法於工程問題最佳化，由有限的學習樣本訓練網路模型以模擬原有的工程系統，再以藉由遺傳演算法搜尋網路模型的全域最佳解，可避免因遺傳世代演化運算所需的大量運算，造成工程應用所需實驗成本的增加。

Cios等人[4]使用舊有的實驗資料作為倒傳遞類神經網路的訓練樣本，藉以模擬系統輸出入關係，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。Nakajima等[8]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。Chakravarthy等[2]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。Nandi則結合遺傳演算法於類神經網路的最佳化搜尋，並應用於製程參數設計與最佳容差設計[9]。

然而為確保模擬系統的全域準確性，一般類神經網路仍需採用大量的學習樣本，當實驗點數目受限，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具可信，模擬系統的準確性可能侷限於局部的設計空間。但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，便能有效降低採樣成本[10]。

本文發展出一套智慧演化型最佳化搜尋策略，以最小的直交表實驗作為網路模型的初始訓練樣本，並以模糊推論規範類神經網路的可信賴區間，結合基因演算法於局部網路模型的最佳設計搜

*聯絡作者： jcyu@ccms.nkfust.edu.tw

尋，提昇預測結果的有效性，再以反覆演化學習與搜尋的方式，求得最佳解。以有效解決工程最佳化中，因實驗成本高所造成實驗樣本受限的問題。

2. 稀少樣本之局部類神經網路模型

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準性有相當大的影響。但對於實際工程問題而言，若利用現有的實驗資料作為初始的訓練樣本，這些樣本的數目與分佈是不可預期的，可能產生採樣不均 (biased distributed) 的問題，但若能有有效的運用這些現場樣本 (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 (Orthogonal Array, OA)，作為初始範例的採樣規劃。直交表的選用是以建立線性模式 (linear model) 需最少自由度作為標準判定，並且以此方式所能置入之最小直交表視為初始學習樣本。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，此時的訓練樣本稱為稀少樣本。圖 1 中為三個變數的採樣例，以 L_9 作為學習樣本， L_4 直交表作為測試樣本。可確保原始訓練範例的均佈性與代表性。




圖 1. 以直交表配置訓練範例之三變數例

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，方能夠獲得極佳的預測結果，但若只是應用於最佳化設計點的搜尋，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。

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)。

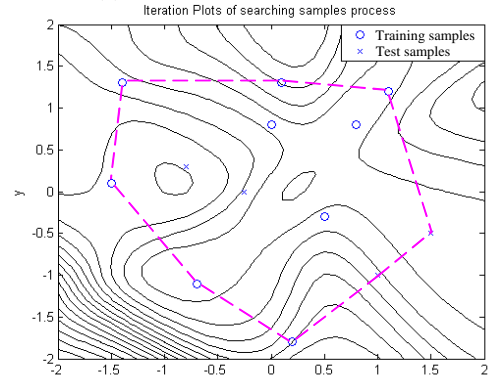
2.2 稀少樣本對網路模型之準確特性

由最小直交表所配置的稀少樣本作為類神經網路的訓練樣本，對於系統行為較為複雜或存在非線性時，將可能不足以訓練出高準確度的系統全域模式 (System global model)。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 [1]。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。

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



(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 Peaks 函數與網路模型之等高線圖比較

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，雖然模擬模型具有大致的曲面趨勢，但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，統計其網路模型預測值與實際值之誤差列於表 1。

表 1 均勻取樣於預測值與實際值之誤差

Judge the Design	The min. dist. of Learning samples	Estimate error of average
Interpolation Design	Under 0.28	1.028
	0.28—0.70	1.802
Extrapolation Design	Under 0.28	1.079
	0.28—0.70	3.315
	0.70—1.41	5.804

圖 2(b)中將學習樣本的外圍以直線連接成一凸多邊形，藉以區分內插與外插設計點。從表 1 中可以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

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) 定義為樣本包覆空間 (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。在包覆空間內點稱為內插設計，而在空間外的點則稱為外插設計。

樣本包覆空間邊界的判斷，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。

$$\sum_{j=1}^n (c_{ij}x_j + c_{i0}) = 0 \quad (2)$$

n 表示維度， i 表示第 i 組超平面

$$y_i(X) = \sum_{j=1}^n (c_{ij}x_j + c_{i0}) \quad (3)$$

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覆空間的邊界面，在反覆檢驗所有的超平面之後，可將 SES 的包覆超平面全部找出來。

2.4 樣本距離

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(4)先對輸出變數進行正規化。將類神經網路的輸入層參數 x 對映至 $[-1,1]$ 的 z 區間。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

由類神經擬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. 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) 流程如圖 3。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。

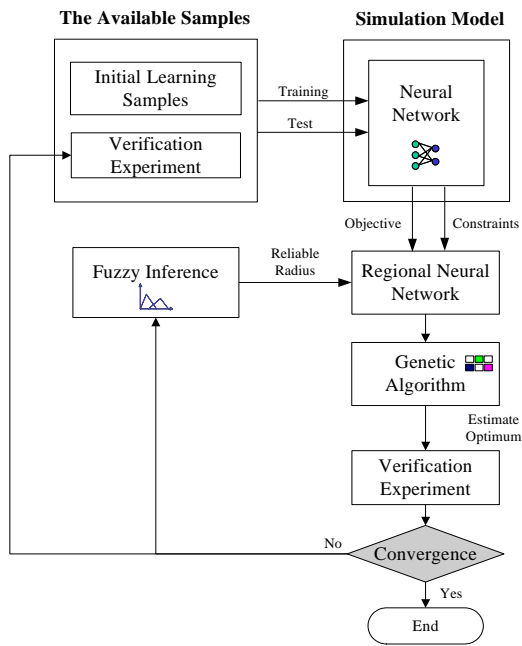


圖 3. 演化型類神經基因演算法最佳化流程圖

3.1 類神經網路之信賴空間

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。由圖 2(a)的實際模型與類神經模擬模型(圖 4)的比較可看出，因採樣樣本點的稀少(13點)，即使經由網路學習的最佳化，所模擬出的類神經網路與實際模型仍存在相當大的差異，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。




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比較以遺傳演算法搜尋這兩種網路模型所得的結果，可看出過度信賴稀少樣本所訓練的神經網路，所搜尋到的模型最佳值其驗證誤差非常大，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)，區間內的最佳解，而其模型最佳值(Model optimum)與驗證值(Verified optimum)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。

表 2. GA 搜尋全域與區域神經網路的比較

GA Search	x	y	Model Opt.	Verified Opt.
Global NN	-3.555	3.978	13.831	1.07e-023
Regional NN	0.015	1.639	9.403	7.593

3.2 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，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)作來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，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。

$$MEI = \frac{|Y_j - T_j|}{RMSE_{Test}} \quad (7)$$

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 $RMSE_{Test}$ 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。

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。




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

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)：

Rule:

- 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，以式(8)與式(9)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

應用本文所提出之演化型局部類神經網路結合基因演算法。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，來驗證本方法的穩健性。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、交配及突變過程找出局部類神經網路的最佳設計 (Model Optimum)；另一方面再以公式(1)進行實驗獲得實際值 (Verified Optimum.)，由上述兩者之間的差異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。運用本文所提出的方法 (ERNGA)，並與傳統的全域類神經網路結合基因演算法 (Neural Network with Genetic Algorithm, NNGA) 搜尋方式比較。

4.1 二變數數值例

4.1.1 直交表實驗取樣

利用 Peaks 函數，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。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。

另外，為測試當最佳設計在初始的包覆空間外時，演化模型是否會向外擴張，本研究也再規劃一次直交表實驗，其迭代結果已是在第 16 次迭代時收斂到最佳值。證明初始設計範圍對搜尋結果並沒有明顯的影響。

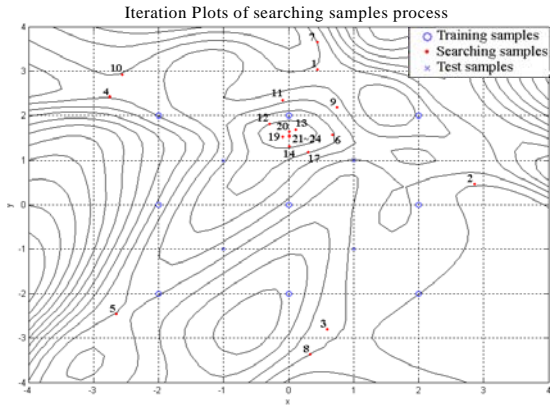


圖 7 搜尋最佳點之迭代過程

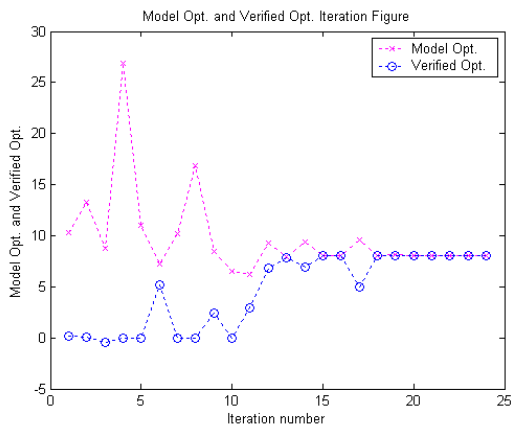


圖 8 最佳設計在初始直交表的包覆區內以 ERNGA 的迭代

4.1.3 結果比較

若以同樣的網路模型訓練，直接以基因演算法搜尋整個區域的最佳值，但因傳統類神經基因演算法對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，如圖 10 所示。且將 ERNGA 迭代結果 (圖 7) 與 NNGA 迭代過程 (圖 11) 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。尤其對於採樣分佈不良的類神經網路，其於外插區域模擬誤差往往過大，使基因演算法誤以為找到最佳值，雖然震盪過程中曾接近理論最佳設計，但因無收斂現象，無法確認最終結果。

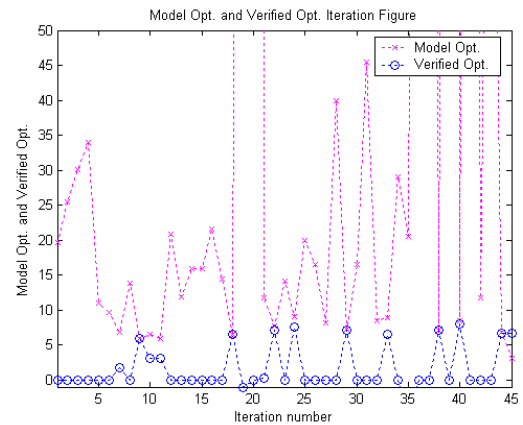


圖 10 初始訓練樣本為直交表實驗以傳統 NNGA 最佳化迭代收斂結果

4.1.2 隨機樣本取樣

接著利用隨機抽樣方式產生初始訓練樣本，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 9 所示，雖然隨機採樣無法保證一開始的採樣分佈為均勻，但仍順利搜尋到最佳值。




圖 9 初始訓練樣本為隨機樣本時以 ERNGA 的迭代

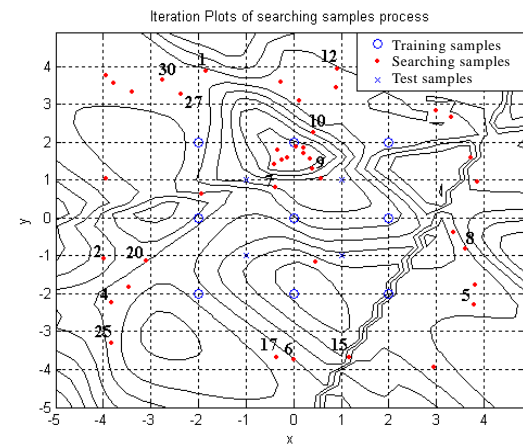


圖 11 搜尋最佳點之迭代過程 (GA 搜尋區域[-4,4])

表 3 ERNGA 與 NNGA 於二變數之最佳化結果

Opt. Method	Samples Number	Theoretical Opt.	Searched Opt.	Exp. Num.	Relative error (%)
ERNGA	Random samples	8.1062	8.0798	43	1.06
	Optimum inside the initial OA samples		8.0484	37	0.71
	Optimum outside the initial OA samples		8.1053	29	0.01
NNGA	Optimum inside the initial OA samples		7.9775*	58	1.59

* Not yet converge at iteration 58. The result is the best value in all the iterations

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 9 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。

4.2 七變數數值例

為測試在多變數的典型數值例的適用性，我們採用，並以七變數數值例[7]作為網路模擬對象，函數如式(10)，此函數存在一全域極小值，運用本文所提出的方法進行設計最佳化，並與傳統的全域類神經網路結合基因演算法 (Neural Network with Genetic Algorithm, NNGA) 搜尋方式比較。

$$f(x) = \sum_{i=1}^7 x_i^2 = x_1^2 + x_2^2 + x_3^2 + x_4^2 + x_5^2 + x_6^2 + x_7^2 \quad (10)$$

七變數的初始學習範例選定 $x_i \in [-2,4]$, $i=1 \sim 7$ ，其中訓練樣本與測試樣本分別配置於 L_{18} 與 L_8 直交表，總共包括 26 組學習範例。而 NNGA 搜尋初始範例方面，也是選擇與 ERNGA 相同。此外最佳化尋優方面，將設定邊界於 $x_i \in [-4,6]$, $i=1 \sim 7$ 作為設計搜尋範圍。傳統類神經結合基因演算法對於多維度單極值問題，從圖 12 可知，在尋優過程中不但無法收斂，亦會形成輸出極值劇烈的震盪，雖其在 70~74 次迭代時曾近似於理論值，但因參數間身處於不同位置無法收斂。主因係為多維度設計空間相當龐大，在學習樣本點稀少之前提下，當最佳化搜尋過於信服網路模型之全域準確度時，將使得尋優最佳值與理論值存在相當大的差異，而造成預測之學習樣本無法有效運用，以致於尋優失敗而耗費經濟成本。

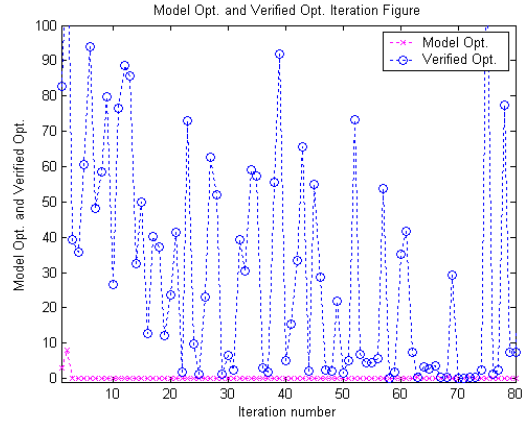


圖 12 七變數以 NNGA 於初始學習樣本為直交表之迭代收斂結果

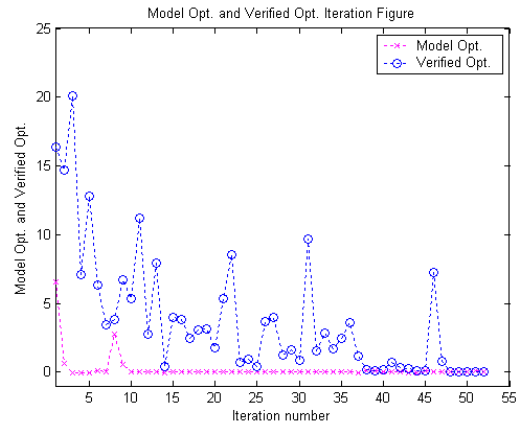


圖 13 七變數以 ERNGA 於初始學習樣本為直交表之迭代收斂結果

表 4 ERNGA 與 NNGA 於七變數之最佳化結果

Seven variables			
Opt. Method	Theoretical Opt.	Searched Opt.	Experiment Number
ERNGA	0	0.0655	78
NNGA		0.0726*	106

* Not yet converge at iteration 106. The result is the best value in all the iterations.

由表 3 與表 4 所列，應用 ERNGA 最佳設計除了能找到近似最佳解（若緊縮收斂誤差可能尋求至理論最佳值），相對於 NNGA 也能以較少的次數尋優；而後者因振幅過大且迭帶次數過多，故在此例並無持續學習，也許日後迭代結果能搜尋至最佳解，但已無經濟實益。綜合以上多變數的分析可知，本研究提出信賴半徑與樣本包覆空間所建構之信賴空間，避免基因演算法搜尋網路模型極值時的過度震盪，且利用模糊推論法則動態的調整信賴半徑，進而反覆演化網路模型之信賴空間，藉以提升預測結果的有效性。利用 ERNGA 的策略，對於單極值與多極值等問題，皆可獲得一較穩定收斂趨勢，不僅能有效的降低成本，亦能符合實際工程所需。

5. 結論

本文所提出演化型局部神經網路的概念，利用信賴半徑與樣本包圍空間結合基因演算法，合乎邏輯予以演化網路模型之信賴空間，配合模糊決策推論而使信賴半徑具有內縮與外擴的能力，藉此提升最佳化搜尋之準確性。應用演化型局部類神經之最佳化設計，在文中以單極值與多極值等案例，測試在多變數的典型數值例的適用性。由雙變數結果顯示無論初始樣本範圍如何規劃，皆能以漸近收斂之趨勢而達成有效的尋優；且在七變數案例中，相較於傳統類神經結合基因演算法，也可獲得一相對穩定結果且符合經濟成本的最佳化設計。

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。

參考文獻

- [1]. 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。
- [2]. P. S. 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.
- [3]. 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.
- [4]. K. J. Cios, G. Y. Baakliini 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]. D.B. Fogel, “A Introduction to Simulated Evolutionary Optimization”, *IEEE transactions on Neural Networks*, vol. 5, No. 1, Jan. 1994.
- [6]. 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.
- [7]. Y. W. Leung and Y. Wang, 2001, “An Orthogonal Genetic Algorithm with Quantization for Global Numerical Optimization”, *IEEE Trans. On Evolutionary Computation*, vol.5, pp.41-53.
- [8]. 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.
- [9]. 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.
- [10]. 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.

Integration of Evolutionary Regional Neural Network and Genetic Algorithm to Engineering Optimization

Jyh-Chen Yu* and Yu-Lung Tseng

Department of Mechanical and Automation Engineering,
National Kaohsiung First University of Science and
Technology

Abstract

This study proposes a soft computing based optimization methodology, the Evolutionary Regional Neural network and Genetic Algorithm (ERNGA), for engineering applications with limited number of experiments. Existed field data or planned experiments such as orthogonal arrays can be used to train a simulated neural network model followed by an optimum search. The number and the distribution of training samples are essential to the prediction accuracy of the network model. However, existed field data will not guarantee an even distribution of samples. Although the use of Taguchi's orthogonal arrays for the experimental design provides a small and evenly distributed sampling strategy, scarce training samples might result in the lack of modeling generality for a complex problem. 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 work sets up a fuzzy inference to define the reliable space surround the training samples, and confines the GA search of optimum in the reliable space for a reliable quasi-optimum. The generated quasi-optimum from GA search is introduced to the training samples to retrain the evolutionary neural network. The searching process iterates until the convergence of the global optimum. The proposed scheme is applied to three benchmark numerical examples and compared with a conventional approach to demonstrate the robustness and efficiency.

Keywords: Evolutionary Optimization, Genetic algorithm, Fuzzy inference, Engineering optimization, Regional Neural Network