

應用智慧型最佳化於導光板微射出成型之轉寫控制

¹余志成 黃明賢 梁智富 林穎志 古洪華

國立高雄第一科技大學 機械與自動化工程學系

¹E-mail: jcyu@ccms.nkfust.edu.tw

經濟部在地型產業加值學界科專計畫編號：97-EC-17-A-07-S1-108

國科會計畫編號：NSC 97-2221-E-327 -011 -MY2

摘要

本文應用演化型局部類神經網路結合基因演算法，於導光板微結構的射出成型製程參數最佳化。藉由高週波感應加熱線圈快速昇溫的特性，控制成形模仁表面溫度，以改善微結構成型轉寫性。影響特徵轉寫率的製程參數包括射出速率、保壓壓力、保壓時間、模溫、冷卻時間、與模面溫度等六個參數，業界常採用田口方法進行參數設計，但參數間的交互作用與系統非線性，容易造成預測錯誤。為降低實驗次數與提升搜尋效率，本研究以實驗計畫樣本建構出類神經網路的近似模型，再以基因演算法，搜尋最佳品質特性。然而為避免因實驗計畫學習樣本稀少，使得近似模型的普遍性不足，造成最佳設計的預測誤差，搜尋限於模型的「信賴空間」，信賴空間由距離學習樣本小於信賴半徑的範圍所定義。藉由預測最佳參數的驗證實驗，重新訓練近似模型，並依預測準確性，以模糊邏輯自動調整信賴半徑，反覆演化近似模型與最佳搜尋遞迴直到收斂。文中以兩吋導光板微V溝成形為載具，並與田口方法結果比較，本研究以田口實驗作為初始學習樣本，在12次遞迴達到收斂結果，平均轉寫高度達到92%，驗證了本方法的優點與效率。

關鍵詞：導光板、感應加熱、射出成型、類神經網路、基因演算法、模糊邏輯

Abstract

This study applies a soft computing based optimization methodology, the Evolutionary Regional Neural network with Genetic Algorithm, (ERNGA), to the parameter optimization for the injection molding of light guides. A high frequency induction heating coil is applied to control the surface temperature of mold insert to improve the transcribing property of microfeatures. To reduce the number of simulation, the proposed scheme first establishes a neural network (NN) model from a small experimental design to simulate the system response, and searches for the model optimum using genetic algorithm (GA). Because the prediction accuracy of NN is likely restricted to the neighboring space of training samples especially for a complex system with limited samples,

this work sets up a fuzzy reasoning for the prediction reliability of the NN model to guide the evolutionary search of GA for a quasi-optimum. The verification of the provided optimum is added to the learning samples to retrain the evolving model, and the process iterates until the reach of convergence. The design of a 2-inch light guide with micro V-grooves is used to illustrate the application of the proposed methodology, and to compare with Taguchi method. Converged optimum is reached at 12 iterations with an outstanding feature transcribing ratio of 92%, which demonstrates the design efficiency.

Keywords: Light guide, Induction Heating, Injection Molding, Neural Network, Genetic Algorithm, Fuzzy Logics

1. 前言

導光板主要應用於液晶顯示器(TFT-LCD)中，其功用是將側邊之點或線光源，藉由導光板上內的微結構(micro structure)轉成在出光平面上均勻之成像光源。微V溝常應用於導光板上用以均勻導光[1]，但由於導光板薄形化的趨勢，微結構的尺寸可能下降至微米等級，若使用一般傳統模具的進行射出製程，則易造成塑膠射出成型過程中產品充填不足(short shot)、翹曲(warping)及變形(strain)等缺陷，將使微結構的轉寫誤差大，致造成透過不良及輝度條紋等異常。

使用單一參數法常用於初期探討不同製程參數對微結構轉寫性之影響[2]，研究發現對於導光板微結構成形的轉寫性，其成型製程影響性因子以模具溫度最重要，其次為保壓壓力，再其次為射出溫度。為提高模具溫度以改善微結構成形的轉寫性，但隨著模具溫度的提高，將會使得整個成型週期過長或加熱不均勻現象發生。有學者利用高週波感應加熱線圈快速升溫之特性[3]，應用於導光板射出成型模仁表面的加熱，其特色為(1)能快速加熱模仁表面；(2)使用感應加熱法相較於一般傳統加熱法的成型週期較短；(3)可局部加熱；(4)不需在模仁及模壁上進行加工，亦不需於模具中置入其他加熱器材，可節省設備成本。

導光板微結構的塑膠射出成型從熔融塑料之充填、保壓、冷卻至固化頂出的加工程序是為複雜之

製程，為獲得最佳的品質特性，除了要有良好設備技術外，尚需提供適當的製程參數。Lin 等[4]應用感應加熱技術快速提高模具表面溫度，並配合田口實驗找出最佳參數組合，提高微結構轉寫高度。田口實驗計劃法[5]是藉由直交表的實驗設計，用以減少實驗次數，再以統計分析預測最佳參數組合。但若此系統問題上存有著複雜的非線性現象，或是參數間交互作用，則可能造成預測的品質特性的誤差。且田口方法僅能在所選定的控制參數因子水準點上尋求最佳組合，並無法在其水準區間內作全域性地搜尋，因此在這區間內可能存在的最佳品質特性數據則將被忽略。

當實驗計畫預測結果不盡理想時，業界常在初步最佳化結果，以最陡梯度或反覆應用實驗計畫的方式，但在如本研究的微特徵射出成形，並無法利用模流分析進行轉寫性的模擬，而需藉由實驗。在搜尋最佳化的過程中，所產生新的設定參數的輸出，都將是每筆成本的支出，因此搜尋效率就變得非常重要。

為突破上述田口實驗法之限制並有效降低實驗之成本，因此有研究提出以現有田口法之實驗資料結合類神經網路 (Artificial Neural Network) 建構出近似模型以作為預測評估，然後再藉由基因演算法 (Genetic Algorithm) 搜尋其全域最佳值，以獲得最佳參數組合。Lin 等[6]及 Fan 等[7]則建議以田口品質工程的訊噪比 (Signal to Noise, S/N) 作為類神經網路模型輸出的績效評估，並結合類神經網路與基因演算法找出製程中最佳輸入參數組合。

而為使類神經網路所建構的近似模型其全域預測準確度高，因此必須提供大量的樣本數據以供學習，然而當成本與資源受限時，無法提供足夠或分佈均勻之樣本點，則將可能降低全域的預測可靠度。Yu 等[8]因此提出信賴半徑 (Reliable Radius) 與樣本包圍空間 (Sampling Enclosure Space, SES) 針對於由稀少樣本學習後的類神經網路模型較不準確，為此建構出一局部類神經模型，並以模糊邏輯調整其信賴半徑，藉以提高預測模型之準確度及可靠度。

2. 感應加熱輔助射出成型

非印刷式導光板一般採用射出成型之方法，但是具有微 V 溝特徵之導光板，由於薄形化的趨勢，其特徵尺寸可能在微米等級，常造成塑料射入模穴後因接觸到模壁冷卻後，影響到熔膠的冷卻速度使其流動性變差，進而造成充填不全及末端成型不良等缺陷。所以模具溫度越高將會使模溫與融膠溫度之間的溫度梯度變小、熱傳導效果變慢，因此融膠在模穴內也會變得較好充填。為了提高模溫，本實驗採用感應加熱方法，此方法是利用電磁感應 (Electromagnetic induction) 原理，使工件在磁場中產生感應電流，利用感應電流通過工件所產生的熱效應，使工件表面、內孔、局部或整體加熱，感應加熱線圈設計如圖 1 所示。

圖 2 為射出成型模具與感應加熱系統圖，其操作機制為：(1) 模溫機加熱模具至一定溫度；(2) 感應加熱器於模仁上局部快速加熱後退出；(3) 射出成型機進行合模、射出、冷卻及開模。本實驗所使用之模具為 SKD61 模具鋼，其模仁為表面鍍鎳之 STAVAX 模具鋼，水冷卻迴路為 2 進 2 出。

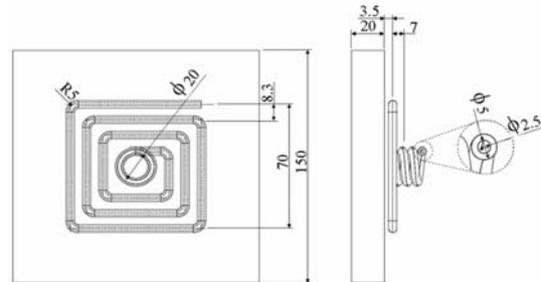


圖 1. 感應加熱線圈尺寸示意圖

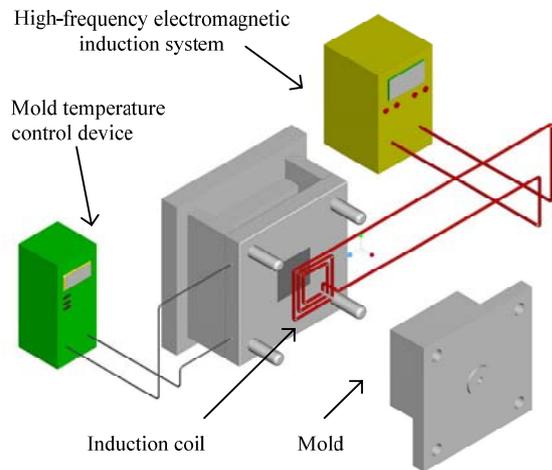


圖 2. 感應加熱系統與成形模具配置圖

3. 感應加熱輔助射出成型參數設計

本文選擇射出速率 (mm/sec)、保壓壓力 (kgf/cm²)、保壓時間 (sec)、模溫 (°C)、冷卻時間 (sec) 及感應加熱模面溫度等六個控制因子，作為降低微結構轉寫高度誤差的製程參數。這些控制因子對於射出成型過程中的流動、充填及成型皆有相當之影響。

本研究以 2 吋導光板作為應用載具，導光板長 40 mm，寬 30 mm、厚度為 0.68 mm 如圖 7 所示。其 V 溝特徵間距為 15 μm、寬 10 μm、深度 5 μm。為評估射出成形轉寫性，共採樣五個樣本，實驗樣本量測九點轉寫高度誤差 (圖 3)，並應用田口方法的望小特性 (smaller-the-better) 訊噪比 (S/N) 作為其品質特性 (quality characteristics) 如式(1)作為目標函數如式。

$$SN = -10 \cdot \log_{10} \left(\frac{1}{m} \sum_{i=1}^m \left(\frac{1}{n} \sum_{j=1}^n y_{ij}^2 \right) \right) \quad (1)$$

y_{ij} 為每一組參數設計中第 $i=1\sim m$ 樣本中第 $j=1\sim n$ 個位置所量測的轉寫高度誤差，每組射出成形參數取五個樣本，每個樣本量測九個位置如圖 3。

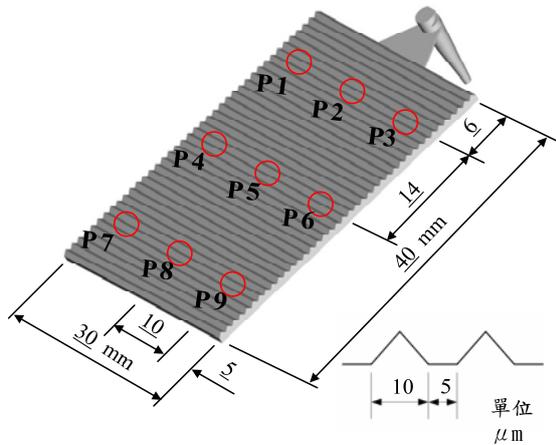


圖 3. 導光板尺寸圖

表 1. 控制因子水準設定

因子	A	B	C	D	E	F
水準	射出速率	保壓壓力	保壓時間	模溫	冷卻時間	模面溫度
1	190	700	8	80	40	150
2	180	600	6	70	35	130
3	200	500	4	60	30	110

表 2. 實驗計畫統計資料

實驗編號	A	B	C	D	E	F	SN
1	1	1	1	1	1	1	6.45
2	1	2	2	2	2	2	4.87
3	1	3	3	3	3	3	-7.89
4	2	1	1	2	2	3	3.00
5	2	2	2	3	3	1	4.71
6	2	3	3	1	1	2	6.18
7	3	1	2	1	3	2	5.89
8	3	2	3	2	1	3	-6.79
9	3	3	1	3	2	1	5.50
10	1	1	3	3	2	2	2.97
11	1	2	1	1	3	3	-2.70
12	1	3	2	2	1	1	5.28
13	2	1	2	3	1	3	-1.49
14	2	2	3	1	2	1	6.08
15	2	3	1	2	3	2	5.90
16	3	1	3	2	3	1	4.90
17	3	2	1	3	1	2	-3.33
18	3	3	2	1	2	3	-9.40

首先以田口方法進行參數設計，控制因子取3水準化，其各水準之參數值如表 1，而本實驗因具有6個3水準之控制因子因此選擇 L_{18} ($2^1 \times 3^7$) 直交表的參數配置，並在每一組實驗組合參數下進行射出，各參數水準值配置設定與量測數據結果，如表 2所列。

依田口直交表的數據分析計算出轉寫高度誤差各水準的 SN 比，並繪製出其因子回應如圖 4。藉由各因子的反應值，因此田口方法的所決定出最佳因子水準組合為 $A_2B_1C_1D_2E_2F_1$ ，經確認實驗後其訊噪比為 6.57(db)。

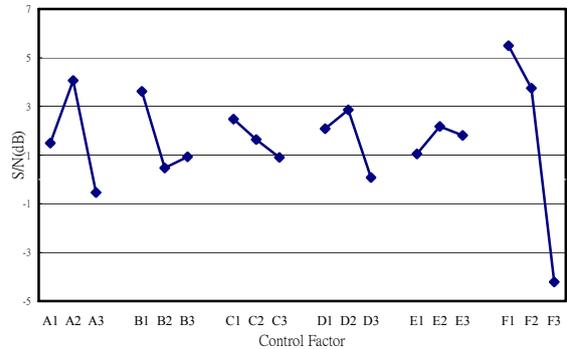


圖 4. 各因子影響訊噪比之折線圖

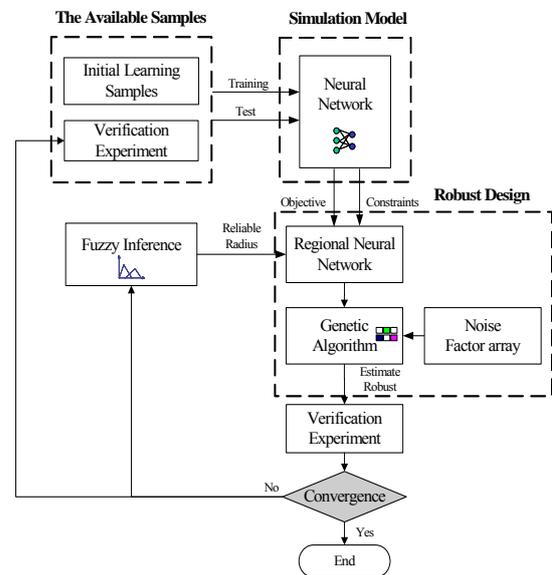


圖 5. 演化型局部類神經網路結合基因演算法

4. 演化型局部類神經網路

田口方法所得結果雖具有不錯的結果，但若持續進行最佳化，必須以所得設計重新定義搜尋範圍與實驗計畫，即可能再進行一次 L_{18} 實驗，所需要的成本過高，且參數結果侷限於水準點上，無法連續搜尋最佳解。本文應用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) 於導光板成形參數的最佳化，可適用於當類神經網路的訓練學習樣本稀少時，平衡類神經網路預測的準確度與搜尋範圍，再以遞迴方式漸進式的向外找尋，以提升搜尋結果之可靠度與效率。圖 5 為 ERNGA 演算法之流程圖，其運作機制如下各節所述。

4.1 類神經網路

倒傳遞類神經網路 (Back-propagation Neural Networks, BPNs) 屬於監督式學習網路 (supervised learning network) 之一，是目前類神經網路中最具代表性且應用最普遍之模式。其基本原理是利用最陡坡降法 (gradient steepest descent method) 的觀念，透過學習過程中輸出值與期望輸出值的偏差量，並向後傳遞至隱藏層與輸入層來調整權重值修正量及閾值修正量，使輸出值與期望值之間的誤差予以最小化，進而利用輸入與輸出所組成的資料，經由反覆的訓練，建立一個系統模型，可用來描述輸入與輸出間的關係，因此有了這樣的系統模型便可用於推估、預測、決策及診斷。

類神經網路的學習是藉由實際數據資料中輸出和輸入間的關係，以模擬出近似的系統模型，所以通常需要相當大量且包含於各不同操作區域的資料以供學習，因此越是複雜的系統所需要的訓練資料就越多。訓練資料太少或是沒有足夠的多元性，若是當參數資料是落在高度非線性且十分敏感的操作區域，將會降低由模擬系統所預測輸出資料的準確度，也因此其所建立的近似模型通常將具有一定程度的不確定性，而且在某些訓練資料缺乏使得系統資訊不足的區域情形可能特別嚴重。本文採用田口直交表作為初始採樣之規劃，其特色為可藉由統計之方法可大幅降低實驗次數，並能提供均勻分佈之採樣樣本，但需考量因實驗樣本減少可能造成預測模型的普遍性 (Generality) 不足。

4.2 模擬系統的可信賴空間

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，造成最佳化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，預測點在內插設計之準確度往往優於外插設計 [10]。因此本文以學習樣本為中心定義信賴半徑，並依照內外插設計準則分別定義信賴內插半徑 (Reliable Interpolation Radius, *RIR*) 與信賴外插半徑 (Reliable Extrapolation Radius, *REER*)，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。

4.2.1 樣本包覆空間

在建立類神經網路模型之前，應先將各參數正規化，參數正規化主要目的在於因輸入的參數單位不一致，為考量各變數間的尺度問題 (Scaling Problem)，因此使其輸入參數對映至 $[-1, 1]$ 的區間，以避免輸出計算結果受少數數值較大的參數所影響，如 (2) 式。

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

z_{kl} 表示第 k 變數中的第 l 個樣本設計範例

由於類神經網路的訓練需要大量的實驗資料，才能提高預測模型的準確度。然而在成本及資源的限制下，由稀少樣本學習後的類神經網路模型，其全域的預測準確度偏差較大，但愈接近學習樣本點之預測數據則誤差較小，且內插設計之準確度優於外插設計 [9]。為區分多維問題中內插與外插預測，本文定義將能夠包覆所有輸入參數的最小凸殼 (Convex Hull) 定義為樣本包覆空間 (Sampling Enclosure Space, SES) [10]，藉由此包覆空間來判斷內插或外插設計。在二維的例子中，其 SES 將為一凸多邊形，如圖 6 的虛線所示。

4.2.2 信賴半徑

為判斷多維輸入參數間相對應之距離，本研究採用平均歐式距離 (Mean Euclidean Distance) 如式 (3)，作為多維變數空間中的距離指標。

$$r_{ij} = \left[\frac{1}{n} \sum_{k=1}^n (D_{ik} - S_{jk})^2 \right]^{0.5} \quad (3)$$

n 表示維度， P_i 為預測點 i 個， S_j 為樣本點 j 個

信賴半徑則以學習樣本為中心點，依照內外插之設計分別定義信賴內插半徑與信賴外插半徑。再配合上述多維參數之平均歐式距離，設定內外插半徑之初始值，藉由此信賴半徑建構出類神經網路模型之局部信賴空間 (圖 6)，作為後續最佳化搜尋的空間。

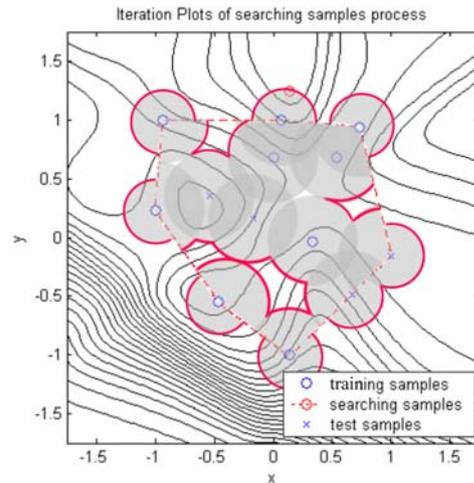


圖 6. 類神經網路模擬之響應曲面與局部信賴空間 ($RIR = 0.3, REER = 0.2$)

4.3 基因演算法

基因演算法是根據達爾文進化論 (Darwinian Paradigm) 中「適者生存，不適者淘汰」為基礎，是借鑑生物界演化和自然遺傳機制所建立的程式模式。一般而言，傳統的演算法由一個點開始，然後慢慢逼近最佳解，而基因演算法其主要特色在於它採用群體搜尋策略即從很多點出發，使得它可以同時搜索解空間內的多個區域亦即可局部搜尋 (local search) 及全域搜尋 (global search)，可用於傳統搜尋方法難以處理的複雜和非線性問題。

本研究採用實數編碼遺傳演算法 (Real-parameter Genetic Algorithm, RGA)[11] 搜尋信賴空間內之極值，實數編碼適合處理工程上實數最佳化的問題[9]，其主要運算為複製、交配、突變及淘汰；首先初始族群依目標特性設定適應函數，其適應值較高的染色體 (chromosome) 則挑選至交配池，然後將交配池內的染色體藉由交配與突變過程產生子代，最後再經由淘汰擇優選擇較佳之染色體，此一循環完成即產生新一代之族群，如此重覆演化以得到最佳之品質特性。

4.4 模糊邏輯調整信賴半徑

為評估類神經網路的可靠度，本文提出模型誤差指標 (Modeling Error Index, MEI) 如式(4)來做評估近似模型內局部信賴空間的預測準確性，當 MEI 值越小則表示搜尋在局部信賴空間內的預測值準確度較佳，反之則準確度較劣。

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

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

為改善最佳化搜尋在局部信賴空間內的預測值能夠維持在一定的誤差範圍內，因此必須調整其信賴半徑。本研究採模糊邏輯動態地調整其信賴半徑，依內外插不同與誤差的大小，設定6條模糊規則如表 3。

表 3. 信賴半徑調整模糊規則

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

根據上述規則本研究將 MEI 值轉換成三角形及梯形的歸屬函數，依其誤差的大小可分為三種語意即 L (Large)、M (Medium) 及 S (Small)，並將其歸屬函數對應至 [0,1] 區間如圖 7 所示，再依歸屬函數之值進行解模糊化，以對應到調整參數 (Adjust Factor, AF) 修正信賴內外插半徑之值如圖 8 所示。

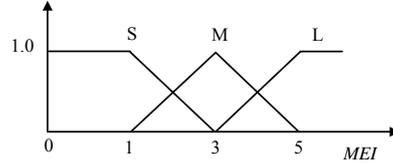


圖 7. 模型誤差指標之歸屬函數

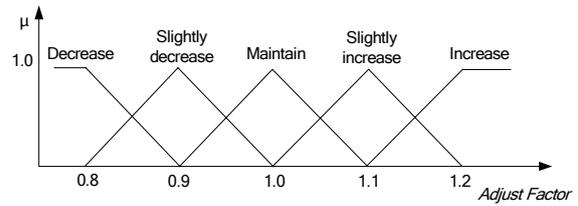


圖 8. 調整信賴半徑之歸屬函數

再經由模糊推論與解模糊化後，在下一迭代所使用調整的內插與外插信賴半徑分別為式(5)及式(6)

$$RIR_{i+1} = AF_i \times RIR_i \quad (5)$$

$$RER_{i+1} = AF_e \times RER_i \quad (6)$$

此動態的調整信賴半徑，當搜尋過程的最佳預測值與實驗值誤差越小時，表示該近似模型具有較高的準確度，因此在下一代的搜尋過程中則增加其信賴半徑，意即其信賴空間較大。反之，而當獲得預測準確度誤差大則應縮小其搜尋的信賴空間。因此整個搜尋過程不至於封閉於固定區域內，且將逐漸地朝向最佳值區域接近。

4.5 ERNGA 最佳化

圖 9 為 ERNGA 於導光板微結構的塑膠射出製程之訊噪比迭代關係圖，而其初始設計暫以實驗計畫中的第 2 組作為設計改善比較，因其參數組合除了 A 以外都在中間水準。目前經過 12 次的迭代已看到預測的最佳設計與驗證結果有收斂的趨勢，同時最佳化預測輸出與實際值間的誤差也收斂，所得訊噪比值為 7.83 (db)，其平均轉寫誤差為 0.4 (μm)，高度轉寫率為 92%。由從迭代關係圖中發現，在演化初期時因學習樣本數較少，因此在外插預測時太過樂觀，因而造成第二次最佳化結果預測訊噪比較大的誤差，但於下次迭代時將此實驗數據加入學習範本後，其局部類神經網路預測之系統模型即能自動修正擬合此區域趨勢，並找到真正最佳參數設計可能的區域，驗證了本方法的穩健性。

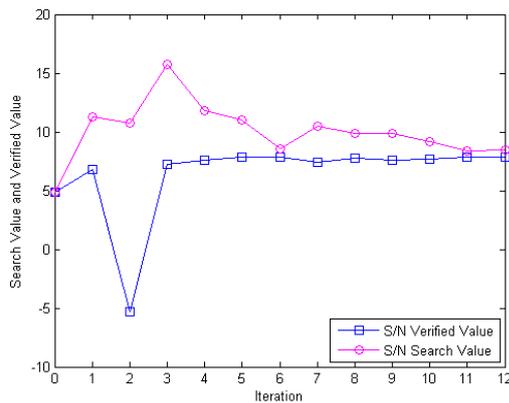


圖 9. ERNGA 於導光板微結構的塑膠射出製程之訊噪比迭代關係圖

5. 結果與比較

表 4 為田口方法與 ERNGA 之最佳化之參數組合比較，ERNGA 在第 11 次迭代並經確認實驗，最佳設計驗證實驗之輸出平均訊噪比由初始設計的 4.87 提升至 7.83，平均轉寫高度為 4.6 (μm)，標準差為 0.07 (μm)，相對的平均高度轉寫率為 92%。而田口方法所得結果為 6.57 (db)，其相對的平均高度轉寫率為 91%，但其轉寫高度標準差為 0.13 (μm)，驗證 ERNGA 具有非常好的最佳化搜尋效率。

表 4. 最佳化參數比較

	製程參數						轉寫高度 誤差	
	A	B	C	D	E	F	S/N (db)	平 均 (μm)
Initial	190	600	6	70	35	130	4.87	0.53
Taguchi	180	700	8	70	35	150	6.57	0.45
ERNGA	197	686	7.4	80	33	150	7.83	0.40

6. 結論

田口直交表透過了統計學的方式大幅減少了實驗次數，然而田口方法僅能在所選定的控制參數因子水準點上尋求最佳組合，並無法在其水準區間內作全域性地搜尋。另外，參數因子設定的水準點數目將會決定實驗範圍內參數因子與觀測值之函數關係，因此當水準數目太少，將難以得到期望的品質特性，且其推論亦受到系統非線性與參數間交互作用的影響。本文藉由演化型最佳化，可以全域搜尋，持續改善收斂至注意最佳解，由感應加熱技術應用於導光板的塑膠射出製程的應用，藉由 L_{18} 的實驗計畫，以及少數的遞迴搜尋驗證樣本，可進一步找到穩健最佳化的設計，得到優異的高度轉寫與

均齊性，而不需藉由反覆的田口實驗計畫來進行最佳化搜尋，驗證了本研究提出之方的效率與優點。

7. 參考文獻

- [1] 曹彰明，LCD 用導光板的成型技術，塑膠世界，pp. 45-49，2002。
- [2] 沈永康、張宏榮、沈煜勝、林柏村，微射出壓縮成型於背光模組導光板微結構之研究，中國機械工程學會第二十一屆全國學術研討會，中山大學，pp. 5177，2004。
- [3] M.-S. Huang and N.-S. Tai, "Experimental rapid surface heating by induction for micro-injection molding of light-guided plates," *Journal of Applied Polymer Science*, Vol. 113, No. 2, pp. 1345-1354, 2009.
- [4] 林穎志，應用感應加熱技術改善具 V 溝微結構導光板成型轉寫性之研究，國立高雄第一科技大學碩士論文，2009，高雄。
- [5] G. Taguchi, "Performance Analysis Design" *International Journal of Production Research*, vol.16, pp. 521-530, 1978.
- [6] 林啟濂，一般常用最佳化方法在塑膠射出成型之應用，國立台灣科技大學機械工程系碩士論文，2005，台北。
- [7] 范揚志、陳文欽，應用類神經網路與基因演算法於射出成型製程參數最佳化之研究，中華大學科技管理研究所，2005，新竹。
- [8] J. Yu, X. Chen, T.R. Hung "Optimization of Extrusion Blow Molding Processes Using Soft Computing and Taguchi Method", *Journal of Intelligent Manufacturing*, 15, pp. 625-634, 2004.
- [9] 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。
- [10] 余志成、曾譽龍 "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"，第十一屆人工智慧與應用研討會，2006/12/15-16，國立高雄應用科技大學，高雄。
- [11] J. Ronkkonen, S. Kukkonen, and K. V. Price, "Real-Parameter Optimization with Differential Evolution," *IEEE Congress on Evolutionary Computation*, vol. 1, pp. 506-513, 2005.