

應用柔性演算法於吹塑成型製程最佳化

陳相弦 洪宗仁 余志成*
國立台灣科技大學，機械工程研究所
106 台北市大安區基隆路四段四十三號
國科會補助編號：NSC89-2212-E155-019

摘要

由於吹塑成型從塑胚擠出到冷卻退出的過程具有高度的非線性，使得輸出/輸入系統模型不易求得。另外爲了有效提高品質與降低材料成本，最佳化製程參數時，目標函數必須調整成品壁厚等於公稱值同時又要降低厚度的變異。本文目的在於製程參數設計最佳化，使用有限元素分析軟體模擬擠出吹塑成型製程，透過田口式品質法減少實驗次數，並利用直交表實驗結果訓練一組類神經網路模型來預測系統響應以降低模擬所需的時間。爲了使少量樣本即可獲得較佳的預測值，文中採用模糊集合建構最佳化知識與工程經驗，輸出神經網路預測信賴度，以作爲基因演算法過程中用來判斷最佳值的依據。

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、吹塑成型

1. 研究背景

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。

目前面對複雜系統，設計者往往需藉助實驗分析或有限元素法來獲得系統資訊。但這些方式卻往往需要大量的時間與成本。因此，如何降低實驗次數並有效地模擬系統行爲，便成爲目前學者關切的焦點。

田口玄一[21]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。對於製造過程複雜或理論模組無法求得時，田口方法可有效率的以較少實驗，來獲得設計改善。Tribus 等[19]使用響應曲面法（Response Surface Method, RSM）來取代田口方法的變異數分析（ANOVA），使用二階的多項式來模擬系統響應。由於RSM必須在模擬之前設定系統的數學型態，如二階多項式，對於複雜的系統較不具彈性。Nakajima 等[8]建議以直交表實驗結果爲樣本，使用倒傳遞類神經網路來取代RSM；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[9]提出類神經田口法，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以取代外直交表。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[2]，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[6]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。

吹塑成型是一種成本較低的塑膠成型製程技術，其特色在於可製造具有複雜外形的中空元件。目前的研究多在於控制成品壁厚分布均勻，以降低材料成本與提高強度。但從塑胚擠出到冷卻退出的過程複雜，使得輸出厚度不易控制。Diraddo 等[16]以塑胚的厚度、溫度分布以及吹塑比(Blow-up ratio)做爲輸入參數，使用類神經網路來預測樹脂在模具中分布的情形。之後使用Newton-Raphson方法藉由塑胚幾何控制來求得最適厚度[17]。Lee 等[12]使用近似薄膜的有限元素模型

模擬製程，並配合 Feasible direction Method 在成品厚度所構成的限制條件下，進行塑胚體積最小化的搜尋。

本文將評估上述柔性計算的特性，發展出一套系統模擬與最佳化方法，應用於吹出成形參數的最佳化，以有效提高吹出成形成品品質與降低材料成本。同時使用有限元素分析軟體(BlowView)模擬擠出吹塑成型製程，透過直交表實驗訓練類神經網路模型，並配合模糊推論法則與遺傳基因演算法，進行製程參數之最佳化。

2. 柔性演算法

柔性演算法(Soft Computing, SC)主要包含類神經網路 (Neural Networks, NN)、模糊集合理論 (Fuzzy Set Theorem) 與基因演算法 (Genetic Algorithm, GA)。其共同的特色是可處理不確定性的計算，這是傳統數學不易克服的難題。SC 也可同時用統計理論來補強其不足。

2.1 類神經網路

類神經網路原始於對生物神經網路內部傳遞的觀察，所衍生出的計算觀念。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，使類神經網路廣泛地應用在控制工程、資訊處理、最佳化方法等，並且都有明顯的改善效果。

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 1 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。




圖 1、倒傳遞網路的基本結構

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 1 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。

2.2 基因演算法

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。

對於二進位編碼的 GA 演算流程可以圖 2 來代表。藉由隨機方式產出初始的族群，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。

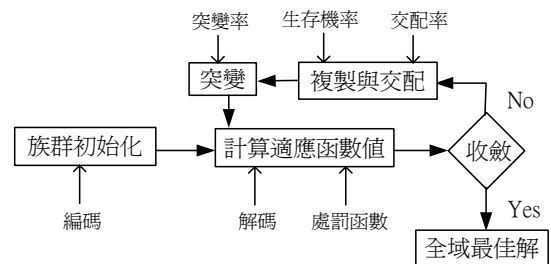


圖 2、基因演算法基本參數與流程

2.3 模糊集合

模糊集合理論使用了歸屬函數的概念來取代傳統明確集合(Crisp Sets)的二元邏輯。模糊化的好處是可以提供更佳的推廣性、錯誤容忍性、處理不確定性、以及更適合應用在真實世界中的非線性系統。

常見的模糊系統如圖 3 所示。假設有一組規則設定為：“IF A Then B”。若輸入 A'，經過模糊化(Fuzzifier)介面之後，產生一組 A 與 A'的模糊關係(Relation)，進而觸發此項規則。將此關係與規則經過合成(Composition)運算之後，即可獲得 B'，由於 B'是模糊集合，可經由解模糊化(Defuzzifier)獲得明確集合的輸出。一般的歸屬函數與規則可以專家知識來建立，有時也會使用類神經網路或基因演算法來調整。




圖 3、一般常見的模糊系統流程

3. 最佳化策略

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，同時減少實驗成本，本文採用田口方法直交表實驗，作為採樣方式。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。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值。而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，但實驗成本卻過於昂貴。因此本文導入類神經網路模組，以直交表實驗與加乘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，即可獲得一組新的預測最佳設計。

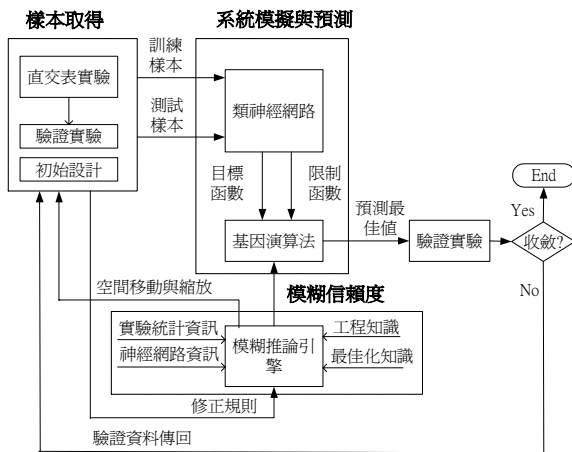


圖 4、最佳化策略示意圖

雖然訓練樣本的“質”達到了，然而“量”還是不夠，因此預測誤差是無法避免的；另一方面，類神經網路無法紀錄工程知識與經驗，並且學習出來的權重矩陣不但無法粹取任何知識，也不能以人工作進一步的調整。因此本系統導入模糊集合與推論的觀念，儲存了工程經驗與實驗統計的知識，建立一套模糊推論引擎來監視類神經網路所預測出來的參數組合與響應，應用基因演算法中處罰函數的觀念，對每一組預測值推論出一信賴度，若符合規則越高，信賴度就越好；反之，若規則違反量越多，信賴度便越差。最佳化策略的流程如圖 4 所示，如果加入的規則與參數能有效地建立，則修正後的預測曲面將有更準確地輸出。

4. 吹塑成型

吹塑成型是一種成本較低的塑膠成型製程技術，其特色在於可製造具有複雜外形的中空元件。以擠出吹塑成型(Extrusion Blow Molding)為例，在圖 5 中，將高分子材料融化並以擠出機經由心軸(mandrel 圖 6)擠出塑胚(parison)，再將模具由兩旁向塑胚夾鉗。在完全夾鉗之後，填入氣壓使塑胚膨脹至模具壁貼合，待冷卻後再把廢料移除(Flash)。




圖 5、吹塑成型示意圖

本文以塑膠瓶壁厚控制作為應用範例，期望瓶壁達到均一的目標厚度。壁厚分布均勻的目的在於使應力分佈較均勻，以及節省材料成本[16]。其中實驗的部份將使用有限元素分析軟體(BlowView)[4]模擬擠出吹塑成型製程，以驗證最佳化策略的可行性。

吹塑成型製程參數主要在於控制塑胚的長度與厚度，包括塑胚擠出的控制點位置與點數、控制點心軸的開合量(Open %)、體積流率(mm^3/sec)、加壓壓力、工作溫度與高分子材料的選擇，其中材料使用高密度聚乙烯(HDPE)。如圖 6 所示，心軸的高低控制擠出的壁厚，0% Open 時有最小的壁厚；相對地，100% Open 有最厚的流出量。在本次實驗中設立了 7 個等間隔固定位置的控制點(圖 7)，調整各點的開合量來調整塑胚的厚度，而控制點間的開合量呈現線性變化，目的在使吹出的塑膠瓶具有均一的厚度。




圖 6、擠出吹塑成型以心軸控制塑胚壁厚

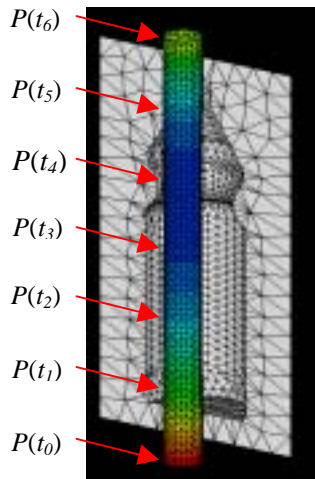


圖 7、控制點在塑胚與模具中的位置

5. 吹塑成型製程參數最佳化

5.1 田口實驗

首先我們先採用田口方法進行參數設計。以塑胚擠出時的心軸開合量作為控制因子，分別是控制點 0 到 6。由於系統會有非線性的表現，因此水準數設為 3 水準，如表 1 所示，實驗配置選用 L18 直交表。

在 Blow View 模擬塑胚擠出過程中，體積流率為定值。但每一個控制點的位置與塑胚長度也會在固定流率下隨開量的增減而移動，若不將控制點座標調整回原先設定的位置，將會大幅增加實驗誤差。因塑胚厚度分布只受到控制點位置與開量大小而改變，故在每一組實驗中將調整流量，使每次實驗擠出之塑胚長度保持定值。

表 1、L18 直交表控制因子水準設定

| | | | | | | | |
|----------|-----|-----|-----|-----|-----|-----|-----|
| 初始設計 | 35 | 75 | 75 | 75 | 75 | 75 | 35 |
| 因子名稱 | Op0 | Op1 | Op2 | Op3 | Op4 | Op5 | Op6 |
| 水準 1 (%) | 65 | 95 | 95 | 95 | 95 | 95 | 65 |
| 水準 2 (%) | 35 | 75 | 75 | 75 | 75 | 75 | 35 |
| 水準 3 (%) | 5 | 45 | 45 | 45 | 45 | 45 | 5 |

為了使輸出平均值符合要求的同時又能降低厚度變異，目標函數使用田口方法中平均損失函數的觀念，來量化參數設定對性能輸出的影響。在(1)式中 t_i 為成形瓶中第 i 個節點(Node)的厚度，共有 n 個節點； T 則為理想厚度 $2mm$ 。損失函數愈小有越好的輸出。

$$Avg_loss = \frac{\sum_{i=1}^n (t_i - T)^2}{n} \quad (1)$$

直交表實驗結果列在表 2 中，第 3 組實驗有最低的損失函數。但田口方法可使用加成法預測找出最佳值，圖 8 為因子效果折線圖，其標號字母的順序依照控制點的順序而排列，輸出為平均損失函數值。由折線圖可推算出最佳的參數組合為 A1B3C1D2E3F3G3，預測值與驗證值如所表 9 示。結果在損失函數值雖有降低，但預測結果並不如預期，其原因可能是因子間有強烈的交互作用與非線性關係等因素。

表 2、直交表實驗結果

| | | | | | | | | | |
|-------|------|------|------|------|------|------|------|------|------|
| Trial | 1 | 2 | 3 | 4 | 5 | 6 | 7 | 8 | 9 |
| Loss | 1.64 | 1.06 | 0.68 | 1.09 | 1.94 | 2.22 | 1.39 | 1.45 | 1.59 |
| Trial | 10 | 11 | 12 | 13 | 14 | 15 | 16 | 17 | 18 |
| Loss | 1.94 | 1.26 | 1.85 | 1.46 | 2.26 | 1.26 | 1.80 | 1.33 | 1.40 |




圖 8、因子效果折線圖

5.2 柔性演算法

5.2.1 類神經網路學習

為提高網路學習能力，本文使用多層函數連結網路(Multilayer Function Link Network)來作為模擬的網路架構。其特色是在倒傳遞網路中的輸出入層加入對數化單元，可對變數的低值較敏感；加入指數化單元，可對變數的高值區域提高敏感度，因此多層函數連結網路常能有較高的精度。

表 3、訓練範例中的因子水準設定

| | | | | | | | |
|----------|-----|-----|-----|-----|-----|-----|-----|
| 初始設計 | 20 | 75 | 75 | 75 | 75 | 25 | 20 |
| 因子名稱 | Op1 | Op2 | Op3 | Op4 | Op5 | Op6 | Op7 |
| 水準 1 (%) | 50 | 90 | 90 | 90 | 90 | 90 | 50 |
| 水準 2 (%) | 20 | 60 | 60 | 60 | 60 | 60 | 20 |

在訓練樣本的取得上，為了降低實驗次數，表 3 中的因子水準設定為上下兩個水準，選用 L8 直交表配合原先二水準設定之中間值作為初始設計。而為了使學習資訊完整，輸出變數將成品厚度輸出依控制點間隔分為 6 段，而不採用單一平均損失函數。其主因在於每個控制點的開量只會影響附近區域的厚度，若

使用單一輸出變數將無法充分表現出變數間的關聯性與敏感度。實驗紀錄如表 4 所示。

表 4、L8 直交表實驗結果

| 編號 | 區段 1 | 區段 2 | 區段 3 | 區段 4 | 區段 5 | 區段 6 |
|------|------|------|------|------|------|------|
| 1 | 2.58 | 1.85 | 1.80 | 1.96 | 2.11 | 4.62 |
| 2 | 3.25 | 1.35 | 1.12 | 1.28 | 1.60 | 3.52 |
| 3 | 1.59 | 1.24 | 1.23 | 2.81 | 2.79 | 3.50 |
| 4 | 2.14 | 1.48 | 1.31 | 1.37 | 1.65 | 4.72 |
| 5 | 2.25 | 1.21 | 1.89 | 2.11 | 1.63 | 4.38 |
| 6 | 2.28 | 1.21 | 1.27 | 1.74 | 2.48 | 3.85 |
| 7 | 1.89 | 3.17 | 1.60 | 1.14 | 1.45 | 3.65 |
| 8 | 2.04 | 1.94 | 1.09 | 1.54 | 2.33 | 4.60 |
| 初始設計 | 2.42 | 1.59 | 1.53 | 1.72 | 1.90 | 4.06 |
| 加成預測 | 1.29 | 1.32 | 2.43 | 2.90 | 2.20 | 3.62 |

學習範例使用直交表實驗結果、初始設計、與驗證實驗共 10 個樣本，8 個作為學習範例、2 個作為測試範例。主要的網路參數為 11 個隱藏層單元、初始學習率=0.8、初始慣性項=0.5。範例處理的部分，為了將輸出入變數映射到合理的區間，輸入變數採用機率對應法、輸出變數採用區間對應法[3]。經過 8000 次學習循環，測試誤差 RMS 縮減至 0.23，調整後的網路架構即可提供資訊給 GA 進行搜尋。

5.2.2 模糊推論設定

雖然直交表提供一組良好的範例供類神經網路使用，但由於數量有限，內插的結果勢必有一定的誤差，導致實際的結果不如預期，尤其是距離樣本越遠的預測點。因此可使用模糊推論，對於距離遠的預測點給予較低的信賴度，如式(2)所示，而詳細的推論可靠度規則則列於表 5。

If (取樣方式=內插) And (樣本距離=很遠)
Then (信賴度=很不可靠) (2)

表 5、樣本距離列表

| 樣本距離 | 很遠 | 遠 | 普通 | 近 | 很近 |
|------|------|------|-----|-----|-----|
| 內插 | 很不可靠 | 算可靠 | 可靠 | 很可靠 | 很可靠 |
| 外插 | 很不可靠 | 很不可靠 | 不可靠 | 算可靠 | 可靠 |

關於樣本距離的歸屬函數設定部分，”很遠”的支點是在所有的學習樣本中，以每一個控制因子的最大間距平方的總合再開根號所得。至於信賴的的設定則採樂觀的做法：以誤差最小的測試樣本作為基準，

反推求得信賴度與樣本距離對映的設定值。其主要理由在於模擬輸出值與實際值的差距不見得都是模擬的比較差，也會發生實際值比預測值好的情況，而且若處罰的太嚴格也容易否定原本表現好的輸出。




圖 9、樣本距離歸屬函數




圖 10、信賴度歸屬函數

樣本距離推論只能消極地對距離遙遠的預測值降低信賴度，如此只會使預測的損失函數提高而無法協助獲得更好的設計。因此，若能導入工程經驗來判斷設計參數組合的優劣，來補償實驗數據的不足，將可有效提昇最佳化結果。

當某區段的平均厚度過大或過小時，成品壁厚的損失函數一定不佳，所以依此觀念可定出推論規則。其步驟主要是以某一組實驗數據作為基準，此一基準數據會有 7 個控制點並將輸出壁厚等份成 6 塊區段。每個控制點對於各個區段的影響強弱程度不同，可由座標的差距來決定影響的程度，由於影響程度是非線性地，不見得每個區段只受兩個控制點的影響，因此可使用模糊歸屬函數來代表。

所有的規則如表 6 所示，其中一條規則如式(3)。只要控制點與該區段的差距小，而基準範例中的某一區段的平均厚度比理想厚度厚很多，並且此控制點的開量又比基準範例大很多。可想而知，這組參數組合一定不是一組好的設計。

If (高度差距=小) And (厚度差距=厚很多)
And (開量比較=大很多)
Then (信賴度=很不可靠) (3)

至於歸屬函數的定義方式，則是在學習範例中，選擇每一區段厚度與理想厚度差距最大的數值取平均作為”厚很多”的支點，其他則以等間距對稱地推導而出，再以人工方式微調。由於模糊推論用意是在於粗調神經網路沒有學習到的參數關係，細微部分是由類神經網路學習訓練樣本而得，只要信賴度的變化範圍不大，就不需要對歸屬函數的部分做太細微的調整。

表 6、厚度與開量關係表示

| | | | | | |
|-----|------|------|-----|------|------|
| | 厚很多 | 厚一點 | 差不多 | 薄一點 | 薄很多 |
| 大很多 | 很不可靠 | 很不可靠 | 不可靠 | 算可靠 | 很可靠 |
| 大一點 | 不可靠 | 算可靠 | 很可靠 | 很可靠 | 可靠 |
| 沒變化 | 很不可靠 | 算可靠 | 可靠 | 算可靠 | 很不可靠 |
| 小一點 | 可靠 | 很可靠 | 可靠 | 算可靠 | 不可靠 |
| 小很多 | 很可靠 | 算可靠 | 不可靠 | 很不可靠 | 很不可靠 |




圖 11、厚度與開量輸入變數歸屬函數

5.2.3 基因演算法

為了能夠在神經網路上尋找到最佳設計，在本文中導入基因演算法搜尋策略。本次 GA 搜尋採用二進位編碼，在各水準的上下限之間進行搜尋。其中母代與子代可一起被選擇與交配，交配率為 0.75、突變率為 0.03。為了使適應度函數最大化，因此適應度函數等於損失函數前面加負號。

在搜尋空間設定方面，雖然類神經網路對於外插的準確度並不理想，但可使用模糊信賴度來做修正，所以可以嘗試放大搜尋空間，其上下限列於表 7 中。

表 7、GA 搜尋空間設定

| | | | | | | | |
|------|-------|-------|-------|-------|-------|-------|-------|
| 初始設計 | 20 | 75 | 75 | 75 | 75 | 25 | 20 |
| 因子名稱 | Op1 | Op2 | Op3 | Op4 | Op5 | Op6 | Op7 |
| 上限 | 50+15 | 90+5 | 90+5 | 90+5 | 90+5 | 90+5 | 50+15 |
| 下限 | 20-15 | 60-15 | 60-15 | 60-15 | 60-15 | 60-15 | 20-15 |

5.3 實驗結果

使用基因演算法在類神經網路模型上進行搜尋，並使用模糊推論引擎加以修正，經過 300 次疊代之後收斂，其預測的參數組合如表 8 中 F-NNGA 所示，雖然外插的組合會遭受到模糊推論的不信任，但因為

Open0 與 Open6 向下調整將可大幅縮減損失，因此其設計組合有最高的目標函數，預測值為 0.82。

田口方法與柔性演算法的預測與驗證結果列於表 8，其結果可發現使用柔性演算法的預測誤差遠小於田口方法，並且有較佳的驗證值。

表 8、各種預測的參數組合

| | | | | | | | |
|--------|------|------|------|-----|------|------|------|
| 控制因子 | Op0 | Op1 | Op2 | Op3 | Op4 | Op5 | Op6 |
| 加成預測 | 65 | 45 | 95 | 75 | 45 | 45 | 5 |
| F-NNGA | 13.5 | 63.5 | 84.9 | 70 | 89.3 | 69.2 | 14.8 |

表 9、驗證實驗結果

| | | | |
|--------|-------|-------|------|
| | 預測值 | 驗證值 | 誤差 |
| 田口方法 | 0.527 | 0.824 | 56% |
| F-NNGA | 0.82 | 0.776 | 5.3% |

6. 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最佳化知識與吹塑成型製程經驗，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。

誌謝

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

參考文獻

- [1]. R. Raviwongse, V. Allada and T. Sandidge, "Plastic manufacturing process selection methodology using self-organizing map (SOM)/fuzzy analysis", The international journal of advanced manufacturing technology, 16, 155-161, (2000).
- [2]. 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學系博士論文, (2000).
- [3]. 葉怡成, "類神經網路模式應用與實作", 儒林, (2000).
- [4]. BlowView, 6.0, (C) Copyright Industrial Materials Institute, National Research Council Canada 1999.

- [5]. D. C. Ko, D. H. Kim and B. M. Kim, "Application of artificial neural network and Taguchi method to perform design in metal forming considering workability", *International Journal of Machine Tools & Manufacture*, 39, 771-785, (1999).
- [6]. 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).
- [7]. T. C. Chang and J. C. Chen, "Fuzzy nets based on-line cutting power recognition in milling operations", *The international journal of advanced manufacturing technology*, 15, 231-237, (1999).
- [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]. 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).
- [10]. 何文中、余志成, "參數變異模態應用於穩健最佳化設計", *中國機械工程學會第十五屆全國學術研討會, 固力與設計組論文集*, pp.953-961, (1998).
- [11]. A. Lotfi and M. Howarth, "Experimental design with fuzzy levels", *Journal of intelligent manufacturing*, Vol. 8, 525-532, (1997).
- [12]. D. K. LEE and S. K. SOH, "Prediction of Optimal Preform Thickness Distribution in Blow Molding", *Polymer engineering and science*, Vol. 36, No.11 (1996).
- [13]. 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).
- [14]. 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)
- [15]. J. C. Yu and K. Ishii, "Robust Design by Matching the Design with Manufacturing Variation Patterns." *Advances in Design Automation, DE-Vol. 69-2, ASME*, pp. 7-14, (1994).
- [16]. R. W. Diraddo and A. Garcia-Rejon, "On-Line Prediction of Final Part Dimensions in Blow Molding: A Neural Network Computing Approach", *Polymer Engineering and Science*, MID-JUNE, Vol.33, No.11, 653-664, (1993).
- [17]. R. W. Diraddo and A. Garcia-Rejon, "Profile Optimization for The Prediction of Initial Parison Dimensions From Final Blow Moulded Part Specifications", *Computers chem. Engng*, Vol. 17, No. 8, pp. 751-764, 1993
- [18]. 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.
- [19]. Tribus, M. and Szonyi, G., An alternative view of Taguchi approach, *Quality Progress*, 46-52, (1989, May).
- [20]. D. Rosato and D. Rosato, "Blow Molding Handbook", Hanser Publisher, Munich, (1989).
- [21]. G. Taguchi, "Performance Analysis Design." *International Journal of Production Research*, 16, pp.521-530. (1978)