

## 應用柔性演算法於吹塑成型件之製程與設計最佳化

洪宗仁 余志成\*  
國立臺灣科技大學 機械工程系

國科會計劃編號：NSC 90-2212-E-011-022

### 摘要

為了有效提高吹塑成型產品品質與降低生產成本，需調整製程參數以控制成品壁厚分佈，本文應用柔性演算法的最佳化策略用以規劃吹塑成形中塑胚擠出時模具的開量，使用倒傳遞類神經網路學習田口方法之直交表實驗的結果，模擬系統輸入輸出之間的關係，再使用基因演算法搜尋模擬表面上的最佳設計。另外，為避免網路預測離樣本點太遠時不可避免的誤差增加，使用模糊系統針對距離學習樣本點的遠近給予不同的信賴度，做為製程與設計的最佳化策略。本文使用有限元素模擬軟體 *BlowView* 模擬吹塑成型製程，以塑胚規劃做為製程控制的主要參數。在製程最佳化方面根據產品外形決定塑胚的厚度，以期得到製程最佳化的厚度均一要求，並與模擬軟體中的 *BlowOp* 最佳化模組及田口方法的結果做比較。另一方面對於有結構強度限制的成形品設計最佳化，本文以 ANSYS 估計成形件承受負荷時的應力分布。並藉由設計目標的定義，進行重量的極小化，並討論反覆最佳化的方式，結果比較顯示本文所提出的方法較單純田口方法的應用，更能找出較佳的設計參數組合，成品厚度與強度需求皆可獲得明顯的改善。

關鍵字：田口方法、類神經網路、基因演算法、模糊系統、吹塑成型

### 1. 前言

吹塑成型[1] (Blow molding)，是主要用來生產中空物件的塑膠成型方法，但吹塑成型並不是製造中空物件的唯一方法，不過由於其特有的加工特性及成熟技術，使得吹塑成型廣泛的應用在塑膠容器的製造上，不只單純用於製造瓶子之類，在其他領域上應用也日新月異，諸如工業用品，汽車零件，玩具，陳列品，家庭器具及建築器件等。

基本的吹塑成型過程通常是由四步驟組成：1、製成離形或塑胚；2、模具圍繞塑胚定位，並夾住塑胚；3、如果製品是容器，則進行製品的頭部成型或定徑；4、導入空氣或其他介質，將塑胚吹脹成模穴的形狀，同時，讓製品在模具內冷卻。在完成上述的基本操作以外，還有要從機頭上切斷塑胚，以及從模具內頂出成品等。

吹塑成型的相關研究多在於控制成品的壁厚分布，以降低材料成本與滿足結構強度需求，一般多採試誤法，若成品某部份太厚則降低塑胚在該部份的厚度，反之，則增加，但塑胚 (Parison) 從擠出到冷卻退出的過程複雜，使得輸出厚度不易控制。鄭[2]以「圖解法」對於塑胚的頸部、胚體與底部做各別的設計探討，對於軸對稱產品較適用。黃[3]則以高分子材料流變特性模擬塑胚吹塑過程，模擬出產品瓶身之厚度、拉伸比、剪切應力值供產品及塑胚設計之用，適用於碳酸瓶與低溫低壓的熱充填瓶。Lee[4]等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，進行成品體積最小化的搜尋，以減少材料浪費與成本。而 Diraddo 等[5]以塑胚的厚度、溫度分布以及吹塑比 (Blow-Up Ratio) 做為輸入參數，使用類神經網路來預測塑料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獲得最適厚度[6]。Hsu 等[7]使用模糊推論，訂定厚度、開量與模具幾何外形與尺寸之間的經驗法則，進而推論出下一次控制點所需要的開量變化，以期提昇搜尋速率。

### 2. 製程設計與模擬

製程控制的目地在於塑胚擠出時，須根據產品外形決定塑胚的厚度，以期得到產品厚度均一的目的。另外，若產品須承受某些負荷或環境相當惡劣時，厚度設計則需要滿足強度需求，並希望應力的分布能均一，以達到產品體積最小化目

\*聯絡作者：[jcyu@mail.ntust.edu.tw](mailto:jcyu@mail.ntust.edu.tw)

地，以節省材料支出成本。

Die Open 控制量是因為主軸上下作動的關係，使得模具與主軸的間隙會有變化（圖 1），我們稱為開口量，進而影響塑胚的厚度，若成品在此區域的直徑會較大，塑胚的厚度便需要增加。一般多將塑胚擠出時設定數個控制點，如圖 2 所示，以控制主軸與模具間的開口，來設計塑胚的厚度稱為塑胚規劃（Parison Programming），進而獲得特定成品的厚度分布。

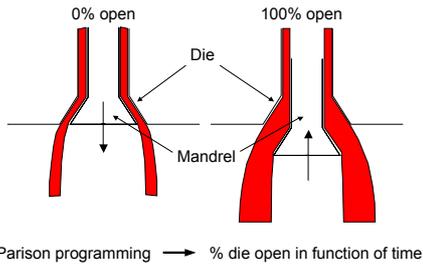


圖 1：塑胚規劃（Parison Programming）的動作

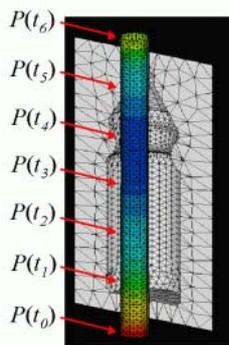


圖 2：吹塑成型塑胚規劃控制點的設定

本研究使用擠出 *BlowView* 吹塑成型模組，估計成型品的厚度分佈。*BlowView* 是一套以有限元素方法以分析各種吹塑成型製程的套裝軟體，*BlowView* 內含有一個批次執行功能模組（*BlowLoop*），可迭代執行模擬吹塑成型各步驟的模組，並且可選擇性執行某幾項功能模組。在讀入程式化塑胚定義檔之後，*Parmesh* 產生擠出後塑胚的尺寸檔交由 *BlowSim* 進行製程模擬。其模擬結果交由 *BlowOp* 最佳化模組判斷下一次的控制點設計參數反覆執行之。最後 *Flash* 模組計算應該移除的廢料以及使用 *Results* 計算統計資料即完成整個步驟。

本文將以柔性計算法控制製程參數中的塑胚模具開口量（Die Open），設計方式是固定模具外形，藉由開口量的調整達到兩種最佳化的目的：一是製程最佳化，期望成品能有均勻的厚度；二是設計最佳化，希望產品在負載之下能不

超過容許應力條件下，降低成品重量。

### 3. FUNTGA 最佳化策略

本文應用 FUNTGA（FUZZY Neural Taguchi with Genetic Algorithms）於吹塑成型產品製程與設計的最佳化，期望在較短的時間內，以少量的實驗計算成本，獲得最佳（較佳）的設計[8][9]。因此採用直交表為訓練樣本，藉以建構類神經網路，作為一個虛擬系統響應產生器（Virtual Response Generator），藉由類神經網路回想快速的效率，以基因演算法搜尋模擬曲面上的最佳值。而另一方面，為避免因學習樣本的減少，造成預測誤差影響最佳設計的搜尋，我們提出信賴距離，配合模糊系統推論網路預測值的信賴度，以控制 GA 的搜尋範圍，整個演算流程如圖 3 所示。

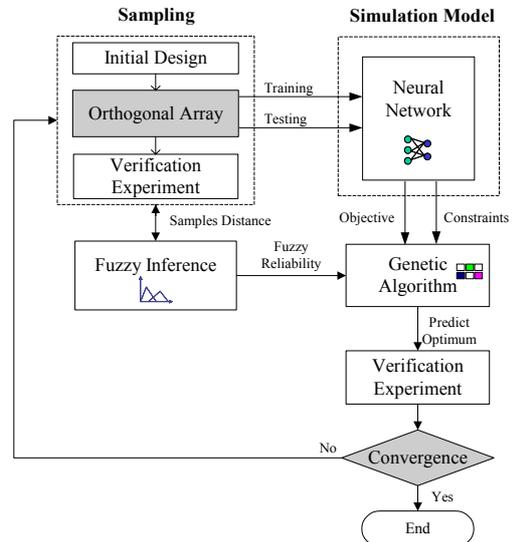


圖 3：FUNTGA 流程圖

#### 3.1. 田口類神經網路

訓練樣本的表现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。除降低實驗次數之外，直交表亦可處理有離散變數的設計類型。在類神經網路中並不限定範例的結構，所以 FUNTGA 使用直交表實驗作為倒傳遞類神經網路的學習與測試範例。雖然直交表學習範例對於實驗成本高的設計問題，可減少實驗次數但又不失其樣本代表性與均勻性的優點，但可能因為樣本數太少，造成網路學習不夠充分與完整，這樣不利於 GA 的最佳化搜尋出近似的全域最佳值，因此我們使用模糊

理論建立樣本信賴距離的信賴度，以限制 GA 搜尋類神經網路的區域。

### 3.2. 應用模糊推論提昇預測準度

雖然訓練樣本的「質」達到了，然而「量」可能會不夠，其預測誤差是無法避免的。因此對於每個 NN-GA 所預測出來的設計（染色體），若距離學習樣本越遠，其預測的準度應該比較受到質疑。所以 FUNTGA 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，若距離學習樣本越近，信賴度就越好；反之，信賴度便越差。

為了計算新設計與每個樣本的距離，必須先對輸出變數的座標位置進行正規化，如式(1)，在計算距離方面，本文使用平均歐氏（Euclid）距離，如式(2)來計算預測點與樣本點的距離，並以最短的距離作為評斷的標準，如(3)式，此最小樣本距離在本文稱為信賴距離（Reliability Distance, RD）。

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

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

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

在圖 4 中，設計  $D_2$ （外插）與樣本  $S_1$  距離為  $r_{21}$ ，與樣本  $S_2$  距離為  $r_{22}$ ，則信賴距離  $RD_2$  以最小值  $r_{21}$  代表。而設計  $D_1$  為內插，其信賴距離  $RD_1$  則為  $r_{15}$ 。

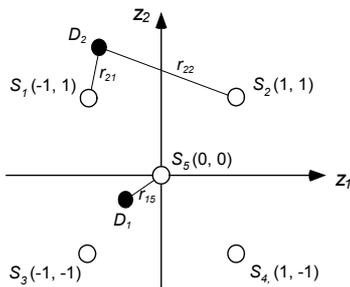


圖 4：設計與樣本之間的距離（內、外插）

由經驗可知信賴距離越短，類神經網路預測的準確度越高，而內插值的預測準確度又較外插設計為高。故我們以下列的推論規則，來表示上述的經驗法則，依信賴距離述詞給予不同等級的信賴度：

R1:If RD is [PB] then prediction reliability is [Bad]

R2:If RD is [PM] then prediction reliability is [Poor]

R3:If RD is [PS] then prediction reliability is [Fair]

R4:If RD is [ZE] then prediction reliability is [Excellent]

R5:If RD is [NS] then prediction reliability is [Good]

R6:If RD is [NM] then prediction reliability is [Fair]

R7:If RD is [NB] then prediction reliability is [Poor]

但由於距離多遠該給多少信賴度是屬於模糊性的概念，無法以二元邏輯來判定之，因此 FUNTGA 使用模糊系統來推論信賴度值。其歸屬函數使用三角形函數，設定值如圖 5 與圖 6 所示。

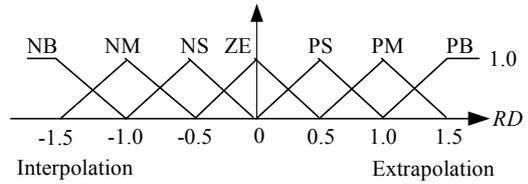


圖 5：信賴距離歸屬函數

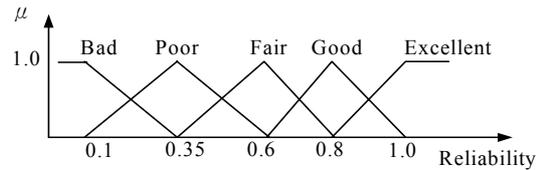


圖 6：信賴度歸屬函數

圖 7 是以二維設計空間為例，以上述模糊規則所推論的信賴度等高線分布圖，圖中五個實心點代表學習樣本點，樣本點附近具有較高的準確度，因此調整 GA 搜尋範圍，減少因網路引起的最佳化設計的推論錯誤。

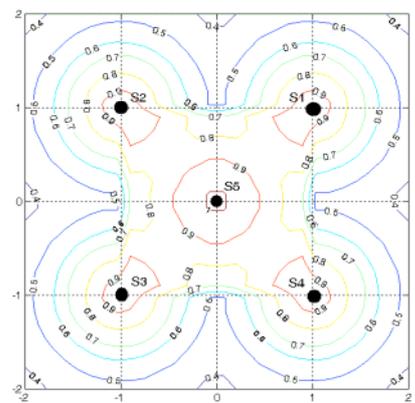


圖 7：樣本點距離之信賴度等高線

### 3.3. 基因演算法搜尋最佳值

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。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。FUNTGA 運用類神經網路學習直交表實驗結果，使用基因演算法搜尋模擬曲面上的最佳值。作為 GA 最佳化搜尋的適應函數。

因為田口類神經網路的學習樣本數目降低的緣故，其準確性僅限於樣本點的附近，因此 FUNTGA 以信賴度的調整網路所估計的訊噪比，避免 GA 搜尋範圍太大，受到網路誤差的影響而得到不正確的最佳設計。我們將類神經網路所預測的輸出依(4)式以信賴度調整訊噪比作為基因演算法中的適應度 (Fitness)，其中 FR 即代表模糊系統所推論出的信賴度， $Fitness_{net}$  則為網路之預測值。

$$Fitness_{GA} = \begin{cases} Fitness_{net} \times FR, & \text{if } Fitness_{net} > 0 \\ Fitness_{net} / FR, & \text{if } Fitness_{net} < 0 \end{cases} \quad (4)$$

### 3.4. FUNTGA 反覆最佳化

如果預測出的最佳設計結果與驗證實驗值間有較大的誤差，或是設計性能仍然不滿意時，則必須進行反覆最佳化的循環程序 (圖 8)。反覆最佳化的過程中，主要是增加實驗設計點。而模糊系統中的信賴度參數可依驗證結果做調整，若是預測誤差偏大，則可以設定較嚴格的信賴度，使預測的設計更接近樣本點；若預測準確度高，則可放寬信賴度的設定，使最佳值搜尋可以更遠離樣本點。

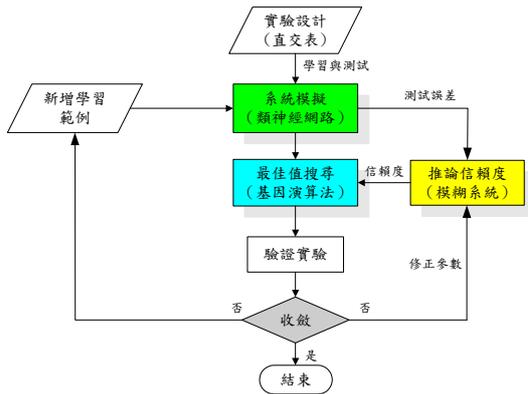


圖 8：反覆最佳化流程

除了類神經網路與模糊系統的參數設定會影響預測準確度之外，網路範例更是左右了整個最佳化流程的成敗關鍵。範例除了需具有代表性，還需要有充分性，所以範例數目越多，通常可以獲得較接近驗證值的預測輸出。新增實驗點數可依實驗成本與設計空間，本文採用下列兩種

方式：

- (1). 以所預測最佳設計的驗證實驗結果作為新增的學習範例：如果實驗成本昂貴，可在不改變設計範圍的情況下，直接以驗證實驗的結果作為新的網路範例。本文建議以上一次最佳設計的驗證實驗加入網路的學習樣本，重新調整網路參數，搜尋最佳設計反覆直至收斂為止
- (2). 新增直交表實驗：如果實驗成本允許，可以上一次所推論出的最佳點作為初始設計，訂定新的搜尋範圍與水準，重新再執行一遍直交表實驗。新增直交表實驗一併作為學習樣本，如此可變動搜尋空間，增加找的全域最佳解的機會。

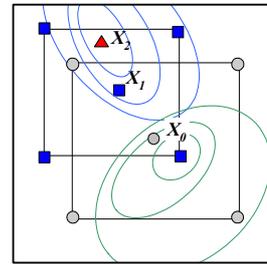


圖 9：以新的直交表實驗作為新增學習範例

## 4. 製程最佳化

### 4.1. 最佳化設計目標

製程最佳化 (Process Optimization) 的目地在於藉由塑胚規劃的方式，來決定開口量，以求得厚度均一的成品。本章所使用的例子外型如圖 10 所示的塑膠儲油槽 Gaztank，Gaztank 是德國 Kautex Textron 公司，使用吹塑成型所製造的汽車零件，主要用途是汽車的燃料儲存槽，材料為高密度聚乙稀 (High Density Polyethylene, HDPE)，其成品厚度要求為 5mm，並期望厚度變異愈小愈好。

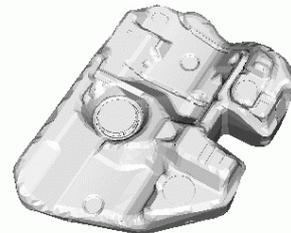


圖 10：Gaztank 的外形

我們以(5)式平均損失函數表示厚度均一的設計目標，其中  $t_i$  代表成品移除廢料後第  $i$  點的

厚度，一共有  $n$  點， $T$  為目標厚度。

$$\frac{\sum_{i=1}^n (t_i - T)^2}{n} = (\bar{t} - T)^2 + \frac{\sum_{i=1}^n (t_i - \bar{t})^2}{n} \approx (\bar{t} - T)^2 + s^2 \quad (5)$$

(5)式的推導可將平均損失函數分為兩部分：

1.  $(\bar{t} - T)^2$ ：成品厚度與目標厚度的差異
2.  $s^2$ ：成品各點厚度之間的變異量

因此選用損失函數做為目標的優點在於可同時減少成品平均厚度與目標值的差異及厚度分佈變異。

#### 4.2. BlowOp 序列最佳化

表 1 所示的塑胚規劃初始設計值，是由德國 Kautex Textron 公司所建議提供。本節以 BlowView 中的最佳化模組 BlowOp 搜尋最佳塑胚規劃。BlowOp 採用直覺式的調整法則，在計算出每個 Programming Point 所影響的權重節點厚度之後，若該點的厚度大於目標厚度，則減少該點的模具開口量；反之，若該點的厚度小於目標厚度，則增加該點的模具開口量，直到迭代結果收斂為止。表 1 顯示 BlowOp 的疊代結果，在第 8 次的迭代其損失函數最小(4.32)，為 BlowOp 所得到損失函數最小的最佳參數組合。

表 1：Gaztank 初始設計 BlowOp 預測最佳組合

	$P(t_1)$	$P(t_2)$	$P(t_3)$	$P(t_4)$	$P(t_5)$	$P(t_6)$	$P(t_7)$	$P(t_8)$	$P(t_9)$	$P(t_{10})$	$P(t_{11})$	$P(t_{12})$	$P(t_{13})$	Loss
Initial	5	5	10	10	40	40	40	40	40	40	40	40	40	11.48
BlowOp	5	5	10	4.96	22.62	19.91	22.94	24.5	25.35	24.16	24.19	23.41	20.82	4.32

#### 4.3. 田口方法應用

本節應用田口方法於塑胚規劃的最佳化，表 2 列出因子水準值的設定，因有十三個三水準的控制點，我們選用 L36 直交表，並設定第二水準為初始設計的開口量。在控制點 1、2、3、4、12 及 13 的位置為產品的頂端與尾端的水準設定範圍為  $\pm 10\%$ ，因為在夾鉗後有許多部分成為廢料，因此這些因子的開量與範圍設定較小，其他控制點為  $\pm 20\%$ 。範圍的訂定希望可以包含最佳設計組合在內。

田口方法使用加成法預測找出最佳值。圖 11 為 Gaztank 的因子效果折線圖，輸出為目標函數值。在不考慮交互作用的前題下，最佳組合為個別參數的最佳水準的參數組合。由折線圖可推算出最佳的參數組合為

$A_1B_3C_3D_2E_2F_1G_1H_1I_1J_1K_1L_1M_3$ ，但經 BlowView 模擬該參數組合的實際目標函數為 6.44。

表 2：控制因子水準設定

因子名稱	Ppt1	Ppt2	Ppt3	Ppt4	Ppt5	Ppt6	Ppt7	Ppt8	Ppt9	Ppt10	Ppt11	Ppt12	Ppt13
水準 1(%)	5	5	5	5	30	30	30	30	30	30	30	35	35
水準 2(%)	10	10	10	10	40	40	40	40	40	40	40	40	40
水準 3(%)	15	15	15	15	50	50	50	50	50	50	50	45	45

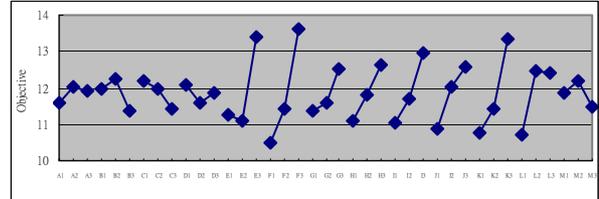


圖 11：Gaztank 因子效果分析圖

#### 4.4. 應用 FUNTGA 於塑胚規劃最佳化

田口方法的加成法模式只能預測各因子水準點上的實驗結果，並且當因子間存在交互作用的狀況下會使預測值產生誤差。我們將田口方法 L36 的實驗結果做適當分割，作為類神經網路的學習與測試範例，網路主要參數設定如下。

表 3：類神經網路主要參數設定

網路模式	第一隱藏層	學習率	學習循環數
倒傳遞網路	15個神經元	1	15

為了能夠在類神經網路上尋找到最佳設計，本文使用二進位編碼的基因演算法作為最佳值搜尋的策略，主要參數如表 4 所示。我們在損失函數前面加負號，並加上模糊預測信賴度作為適應度函數如式(6)。使用 FUNTGA 第一次迭代所獲得設計的損失函數為 12.60。

$$Fitness_{GA} = -Avg\_Loss / FR \quad (6)$$

表 4：基因演算法主要設定參數

族群數	選擇池	交配率	突變率	最大世代數
36	母代+子代	0.75	0.1	100

我們可以發現 FUNTGA 的結果並沒有預期的比任何一組直交表實驗好，因此採用所建議的第一種反覆最佳化方式，在不改變設計範圍的情況下，直接以驗證實驗的結果作為新的學習範例，以改善網路的學習準確性，重新執行 FUNTGA 最佳化策略，反覆學習出最佳設計值為止。圖 12 為 FUNTGA 反覆 7 次之後的結果，在第 6 次有一組 FUNTGA 的設計組合平均損失為

3.42 (表 5)。

表 6 為 FUNTGA 與各設計經 BlowSim 模組所計算出的厚度平均值、標準差與平均損失。我們可以發現 FUNTGA 在平均損失的結果優於其他方法。

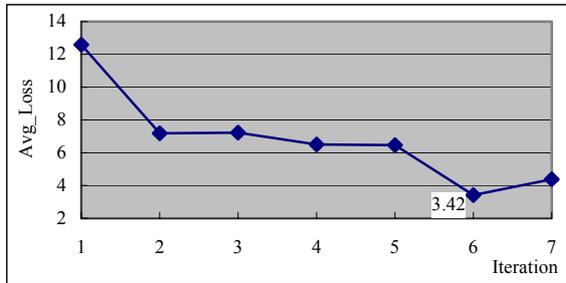


圖 12：FUNTGA 最佳化迭代情形

表 5：FUNTGA 反覆第 6 次的最佳設計

	$P(t_1)$	$P(t_2)$	$P(t_3)$	$P(t_4)$	$P(t_5)$	$P(t_6)$	$P(t_7)$	$P(t_8)$	$P(t_9)$	$P(t_{10})$	$P(t_{11})$	$P(t_{12})$	$P(t_{13})$	Loss
Optimum	18.78	15.62	1.09	0.79	21.2	26.26	44.93	20.79	20.42	34.07	25.92	28.69	47.63	<b>3.42</b>

表 6：FUNTGA 與各種最佳化結果比較

Iteration	Initial Design	Taguchi's	BlowOp	FUNTGA
Mean	7.4	6.17	5.12	5.63
Standard Deviation	2.39	2.25	2.07	1.74
<b>Average Loss</b>	<b>11.48</b>	<b>6.44</b>	<b>4.32</b>	<b>3.42</b>

## 5. 設計最佳化

因為吹塑成型產品主要是為中空件，大多數都得容納大重量或高壓的流體，盛裝這些流體時，產品本身的機械強度就很重要了，單純以厚度均一為目標，並不是最適合吹塑成型產品的設計方式。在運輸與搬運過程中，產品本身除了承受內壓力之外，還要受到產品運送時疊放的重力，如何在產品受負載時不破壞的情形之下，同時達到節省材料降低成本的目的，使成為成品厚度分布的重點。

本節使用中空 HDPE (High Density Polyethylene) 塑膠瓶為例，依廠商美國 Lear 公司的設計要求，瓶子需承受 0.75 MPa 的內壓力，並在瓶子的頂部施加 5 mm 的位移變形量，用以模擬瓶子可能的負載狀況。最大容許應力以材料的最大張應力 (Ultimate tensile strength) 而定，為 33 MPa，材料的楊氏係數為 879 MPa，假設收縮率為 3%。本節以 FUNTGA 最佳化策略，搜尋

最佳開口量設計組合，使用 BlowView 模擬吹塑成型製程，並輸出網格模型以利 ANSYS 應力分析，經目標函數計算收斂與否，在反覆最佳化方面，則選擇重新設計直交實驗以增加學習範例，整體流程如圖 13 所示。

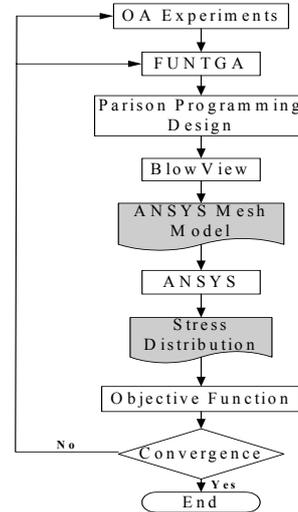


圖 13：應力分析流程

原始的最佳化問題的敘述如下：

Minimize : Part\_Weight $[P(t_j)]$

Design Variable :  $P(t_j)$

Constraints :  $s_i[P(t_j), P, T] \leq \sigma_a$

其中  $s_i$  為物件有限元素模型在各網格節點 (mesh nodes) 之應力， $P(t_j)$  為塑胚在控制點  $t_j$  開口量， $P$  為瓶內的壓力， $T$  為瓶子頂部的變形量， $\sigma_a$  為材料的容許應力。本節將藉由目標函數的定義，將上述有限制條件最佳化問題轉換為無限制條件的最佳化問題，以簡化最佳設計的搜尋。

應力分布變異越小，應力的平均值能越接近容許應力，所以厚度可以愈薄，產品重量也會愈輕。但如果產品有些部份太薄而無法承受負荷而超過容許應力時，將會造成產品的破壞。我們可以使用懲罰函數法，將原始的有限制條件最佳化問題，轉變為無限制條件的最佳化問題，

修正後的目標函數 (MOBJ)，如式(7)，含有兩個部份：前半部為應力分布變異所造成的平均品質損失 (Quality Loss)，後半部為違反容許應力的懲罰損失 (Penalty Loss)。

$$MOBJ = \frac{\sum_{i=1}^n (s_i - \sigma_a)^2}{n} + \sum_{i=1}^n \langle s_i - \sigma_a \rangle^2 \quad (7)$$

$s_i$  代表的是每個節點  $i$  的應力值， $\sigma_a$  是材料的容許應力而  $n$  為整個有限元素模型的節點數。

在平均品質損失方面如前節所示，包括成品平均應力與材料容許應力的差異，以及各節點應力分佈的變異數。而目標函數的第二部份是懲罰損失，如式(8)，在這裡我們使用二階奇異函數做為懲罰量，對於每個節點都會計算懲罰量，如果節點  $s_i$  的應力小於容許應力值  $\sigma_a$ ，那麼懲罰量為零；如果節點  $s_i$  的應力大於容許應力，那麼懲罰量會是差的平方。

$$\langle s_i - \sigma_a \rangle^2 = \begin{cases} 0, & \text{if } s_i \leq \sigma_a \\ (s_i - \sigma_a)^2, & \text{if } s_i > \sigma_a \end{cases} \quad (8)$$

由圖 14 中可以看出，在此目標函數的定義下，在超過容許應力時，目標函數會增加的相當快，以迫使設計往合理區移動。

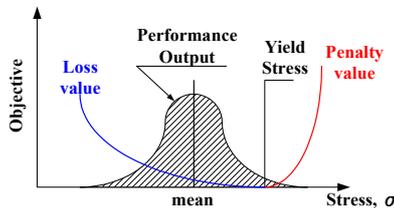


圖 14：性能最佳化目標函數示意圖

### 5.1. 田口方法應用

表 7 列出因子水準值的設定，第二水準為初始設計，因為類神經網路在估計外插值的誤差較大，所以我們將設計空間設為  $\pm 20\%$ ，希望將最佳設計包含在水準範圍之內。

表 7：控制因子水準設定

因子名稱	Ppt_0	Ppt_1	Ppt_2	Ppt_3	Ppt_4	Ppt_5	Ppt_6
水準1 (%)	55	55	55	55	55	55	55
水準2 (%)	75	75	75	75	75	75	75
水準3 (%)	95	95	95	95	95	95	95

經由田口的平均數分析，可找出各因子對輸出特性的影響，選擇有最大訊噪比的組合，並加以成法預測找出的最佳參數組合為  $A_1B_3C_1D_1E_1F_1G_3$ ，經驗證 *BlowView* 模擬該參數組合的目標函數值為 555.6。

### 5.2. FUNTGA 應用

本節將田口方法的實驗計畫作為類神經網路的學習範例，本例我們將所有的直交實驗以及初始設計都做為學習範例，以學習誤差底限  $10^{-5}$  及最多學習循環數 200 次，來避免過度學習的問題，表 8 為網路主要參數設定。

表 8：類神經網路主要參數設定

網路模式	第一隱藏層	學習率	學習循環數
倒傳遞網路	9 個神經元	1	200

訓練後的類神經網路做為基因演算法的適應函數產生器，對於每個染色體（設計組合）計算適應函數，同樣為了使適應度函數最大化，我們將適應度函數等於目標函數，並使用相同的模糊設定來調整 GA 的預測準度與搜尋效率。表 9 為 GA 主要的參數設定，我們將原本 19 組學習範例作為初始族群，最後使用 FUNTGA 所獲得設計的損失函數為 514.34，而為各式最佳化方法的比較。

表 9：基因演算法主要參數

族群數	選擇池	交配率	突變率	最大世代數
19	母代+子代	0.75	0.2	200

表 10：各式最佳化方法的結果比較（未反覆）

	Mean Stress	Std.Dev. Stress	Quality Loss	Penalty Loss	Objective Function
Initial	15.9	6.4	335.1	33.7	368.8
Taguchi's	16.6	7.3	322.4	233.2	555.6
FUNTGA's	16.3	7.1	327.5	186.8	514.4

FUNTGA 的第一次最佳化過程中，結果並不是最佳設計。在本應用例中，初始設計恰好已經是相當好的設計，在模擬成本允許的條件下，本節使用反覆最佳化的第二種方法，依上一次所推論出的最佳值作為初始設計，訂定新的搜尋範圍與水準，重新再執行一遍直交表實驗，將新的直交表實驗與原為學習樣本的次直交表，作為神經網路的學習樣本，其他作為測試樣本，希望在學習樣本增多的情況下，建立更具代表性的類神經模型。

表 10 可知道第一次實驗中的初始設計是目前的最佳值，因此再以此點當做反覆直交表的初始設計，並將範圍降低一半為  $\pm 10\%$ ，訂定新的水準範圍（表 11）。

模糊規則與 GA 參數的設定與原先設定相同，唯有 GA 初始族群設為 37 個（所有訓練範例與初始設計），而類神經網路的參數因為學習樣本增多，主要參數及訓練結果則有不同，如表 12 所示，在範例的選擇處理上，我們使用反覆最佳化的第二種範例處理方式。反覆使用 FUNTGA 所獲得設計的損失函數為 340.5（表 13）。

表 11：反覆直交表實驗的水準範圍

因子名稱	Ppt 0	Ppt 1	Ppt 2	Ppt 3	Ppt 4	Ppt 5	Ppt 6
水準1 (%)	65	65	65	65	65	65	65
水準2 (%)	75	75	75	75	75	75	75
水準3 (%)	85	85	85	85	85	85	85

表 12：類神經網路主要參數（反覆）

網路模式	第一隱藏層	學習率	學習循環數
倒傳遞網路	11個神經元	1	200

表 13：反覆 FUNTGA 的最佳設計組合

Iterative	$P(t_0)$	$P(t_1)$	$P(t_2)$	$P(t_3)$	$P(t_4)$	$P(t_5)$	$P(t_6)$	Objective Function	S/N ratio (dB)
FUNTGA's Optimum	68.32	84.59	88.52	85.24	78.51	70.58	71.66	340.5	-25.32

比較反覆最佳化之後 FUNTGA 與各設計經應力分析之後所得到的平均應力與損失函數。我們可以發現 FUNTGA 因為反覆而增加類神經網路模型學習樣本之後，可以使網路模型更具代表性，所找到的結果也就越好，其應力分佈也較為平均，（圖 15）

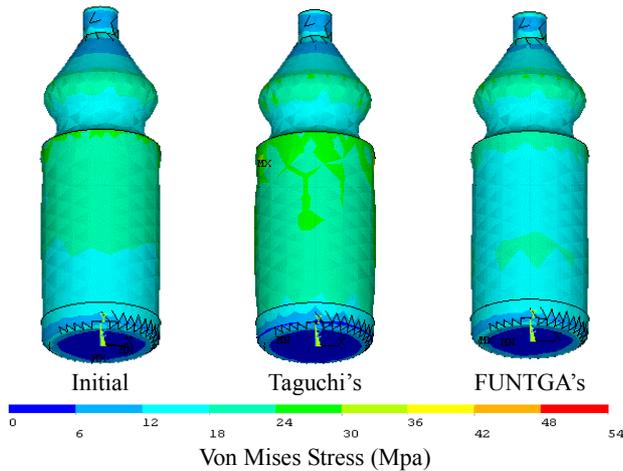


圖 15：性能最佳化結果比較

## 6. 結論

製程最佳化問題，必須調整成品壁厚等於公稱值，同時又要降低厚度的變異。本文使用有限元素分析軟體（BlowView）模擬製程，並以平均損失作為輸出目標，透過先前所提出的最佳化策略，並將樣本距離量化以建構模糊系統，修正類神經網路的預測信賴度。經模擬驗證，成品壁厚分布獲得明顯的改善。另一方面在設計最佳化問題中，本文使用 ANSYS 分析塑膠瓶於負載下的應力分布情況，以懲罰函數的觀念將設計限制條

件轉換到至損失函數的定義中，並使用相同於製程最佳化中的 FUNTGA 最佳化策略，達到體積最小化的目的。

誌謝

本研究承蒙國科會支持，計劃編號 NSC 90-2212-E-011-022，特誌謝意。

參考文獻

- [1]. 陳正鋒，塑料吹塑成型，大孚，(1984)。
- [2]. 鄭基鋒、邱顯俊，”PET 瓶胚設計參數之探討”，國立中興大學機械工程學系碩士論文，(1997)。
- [3]. 黃志昌、邱顯俊，”吹瓶與瓶胚設計理論之探討”，國立中興大學機械工程學系碩士論文，(1998)。
- [4]. D. K. LEE and S. K. SOH, "Prediction of Optimal Preform Thickness Distribution in Blow Molding", *Polymer engineering and science*, 36, 11 (1996).
- [5]. 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, 33, 11, 653-664, (1993).
- [6]. 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*, 17, 8, 751-764, (1993).
- [7]. Y. L. Hsu, T. C. Liu And M. S. Hsu, "A Fuzzy Optimization Algorithm for Blow Moulding Process", *Proceedings of The Sixth International Conference on Computer Supported Cooperative Work in Design*, July 12-15, 2001, London, Ontario, Canada.
- [8]. J. Yu, X. Chen, and T.R. Hung (2001) "Optimization of Extrusion Blow Molding Using Soft Computing and Taguchi Method", *Proceedings of the Sixth International Conference on Computer Supported Cooperative Work in Design*, July 12-15, 2001, London, Ontario, Canada.
- [9]. 陳相弦、洪宗仁、余志成 (2001) “應用柔性演算法於吹塑成型製程最佳化”，第十二屆全國自動化科技研討會，雲林虎尾技術學院，民國九十年五月