

## 類神經網路於 MIMO 半導體製程控制的應用

呂明山 張仁達

雲林科技大學工業工程與管理研究所

雲林縣斗六市大學路三段 123 號

### 摘要

在製程上常存在許多干擾，這些干擾會造成製程輸出飄移或是偏移，本研究提出利用倒傳遞類神經網路針對多重輸入及多重輸出製程，建構製程的預測及控制模式來補償干擾造成的誤差。首先，倒傳遞類神經網路預測器經由學習製程的輸出模式，預測製程的干擾輸出，接著，倒傳遞類神經網路控制器經由學習製程的調控模式，依據目標值與干擾輸出的誤差計算製程的參數調整量，來補償干擾所產生的誤差。為了驗證倒傳遞類神經網路預測器的預測績效，預測結果將與 Box-Jenkins 預測模式作比較。最後，利用半導體化學機械研磨製程為模擬驗證的對象，驗證倒傳遞類神經網路預測及控制器之可行性。研究結果顯示倒傳遞類神經網路預測及控制器能有效控制干擾輸出，降低製程干擾所產生的變動。

**關鍵詞：**類神經網路，預測，干擾，製程控制

## Neural-Network-Based Process Control for the MIMO Semiconductor Manufacturing Process

MING-SHAN LU and LEN-TA CHANG

*Department of Industrial Engineering and Management, National Yunlin University of Science & Technology  
123, University Rd., Sec. 3, Douliou, Yunlin 64002, Taiwan, R.O.C.*

### ABSTRACT

In the manufacturing process many disturbances exist which usually cause the process output to draft or shift from the design output. In this research an on-line process prediction and control for multiple-input and multiple-output (MIMO) systems, based on back-propagation neural networks, is developed. A neural network predictor is designed to estimate the disturbed process outputs, and a neural network controller is used to adjust the input parameters to reduce errors between the design outputs and the estimated outputs. Moreover, a comparison of estimated performance between the proposed neural network predictor and a Box-Jenkins predictor is also given. A simulation study based on the chemical mechanical polishing process is used to verify the proposed controller. The simulation results show that the proposed neural network controller can effectively reduce the variance of output.

**Key Words:** neural network, prediction, disturbance, process control

## 一、前言

隨著自動化生產機器設備日益複雜及製程的多變性，產品的生產過程中，可能會受到一些變異或干擾的影響，例如機器設備老化、工具的磨損或原料的差異等因素，而造成製程的輸出值偏離期望的目標值，使得製程的品質受到了影響。這樣的結果導致良品率的降低，增加成本的損失。為了能夠保持製程的穩定性及生產出合乎品質要求的產品，使得製程輸出值能不偏離目標值，實為一個值得研究的課題。

一般的干擾可造成製程的漂移(drift)或是偏移(shift)，為了對製程所存在的干擾進行補償，可結合統計製程管制(statistical process control, SPC)與工程製程管制(engineering process control, EPC)的技術來進行製程的調整以穩定系統的輸出。Montgomery [12] 認為工程製程管制假設製程的輸出隨著輸入動態變化時，利用預測下一時間點的觀測值及找出輸出及輸入的函數關係，藉由推估輸入參數的調整量來進行參數的調整，可使得輸出符合目標值。Box 與 Kramer [5] 利用工程製程管制的觀念，應用於連續性製程的產業中，透過自動化的機械設備，經由製程控制系統來做回饋或適應機制，對於製程發生變異的現象做適當地調整與修正，達成製程的輸出能接近預設之目標值。

統計製程管制與工程製程管制亦可應用於以一個製程批次或 Lot 為基礎的離散生產系統。當製程受到變異干擾時，以一個製程批次為基礎，量測當期的輸出質品特性，並預估下一期輸出質品特性，來修正製程的輸入參數，進而補償或降低干擾所造成的影響，此種技術又稱為 Run-to-Run 的製程控制技術，並且廣泛地應用於半導體的製程。Sachs [13] 結合 SPC 及 EPC 來設計 Run-to-Run 的控制器，控制器包括 Rapid mode、Gradual mode 及 General mode 等三種元件所組成。Rapid mode 可用來補償製程突然發生的快速偏移，Gradual mode 可用來調整製程緩慢的漂移，General SPC 是利用管製圖來決定兩個模式間的選擇。同時，利用指數加權移動平均(exponentially weighted moving average, EWMA)來遞迴估計輸出值及計算控制輸入值。為了補償因半導體線路開極蝕刻機器老化作用所產生的製程漂移，Butler 與 Stefani [6] 提出了兩個 EWMA 控制器，稱為預測修正控制器(predictor correct control, PCC)，利用 EWMA 同時來遞迴估計製程的漂移及快速偏移，並且計算所需補償的輸入值。Guo 等學者 [10] 修正 PCC 的方法，提出 Double-EWMA，將製程偏移及漂移的 EWMA 遞迴估計中

加入製程的漂移項，同時利用穩態的變動值(steady-state deviation, SSD)找出最佳的輸入參數。

另外一種 Run-to-Run 的製程控制方法為 Self-tuning。Self-tuning 控制器主要將估計及控制分開來，利用遞迴估計演算法線上估計製程中連續變化或初始值為未知的參數，接著將估計的參數值作為控制器估算控制參數的依據。有關 Self-tuning 的控制理論請參考文獻 [3]。Del castillo [8] 提出利用 Self-tuning 的架構於多變量的製程控制，補償製程偏移及漂移的現象，並利用一次線性的模式作為系統的控制模擬。Del castillo 及 Yeh [9] 將 Self-tuning 的方法延伸到多變量的非線性二次製程模式的控制，利用多變量遞迴最小平方的演算法來預估製程的輸出，在最小的輸出品質及輸入參數的成本要求，與考慮輸出及輸入的限制下，利用 Mixed pennaty-barrier 來找出最佳的輸入參數值。Yeh 及 Huang [17] 及江行全等學者 [1] 考慮相同的製程模式下，分別利用基因演算法及 Trust region 取代 Mixed pennaty-barrier 來找出最佳的輸入參數值。

類神經網路因具有高度的學習能力，因此廣範圍應用於多變量線性及非線性製程模式的辨識、預測及控制上的應用。類神經網路在預測應用方面，Tang [16] 針對航空旅客人數、美國國外汽車銷售量、美國國內汽車銷售量三組時間數列資料，利用單因子型態來探討 Box-Jenkins 模式與類神經網路預測能力的優劣，結果指出在短記憶性的預測，類神經網路之預測能力較好。Shao 及 Chiu [14] 更進一步利用倒傳遞類神經網路，辨識製程輸出之階段性干擾(step-change disturbance)與線性干擾(linear disturbance)，並提出利用倒傳遞類神經網路具有高度預測效果，建立製程干擾預測以提高控制器效能。Cho [7] 將類神經網路用於建立陶瓷殼模鑄造(ceramic slip casting)、彈性流體研磨拋光(abrasive flow machining)及化學氧化(chemical oxidation)等製程的預測模式。

類神經網路在控制器的設計應用方面，依據 Cho [7] 文獻中，類神經網路在製程控制的設計可分為四種：結合類神經網路辨識器的適應控制器、當作增益調整的類神經網路控制器、結合傳統回饋控制的類神經網路前饋控制器及結合類神經網路辨識器的類神經網路控制器。Azouzi 及 Guillot [4] 兩位學者以兩個類神經網路分別建立切削製程的品質的預估模式及製程模式，類神經網路製程模式以品質預估模式的輸出及製程輸入參數建立製程輸出及輸入的關係，接著以製程

模式為基礎，在最佳化的品質要求下調整輸入的參數。Lim 及 Cho [11] 結合類神經網路前饋控制器及回饋 PID 控制器用於電弧焊接焊池 (weld pool) 大小的控制，在控制器中也引用類神經網路的焊池預估器來預估焊池大小，作為 PID 控制器調整誤差的依據，此類神經網路控制器可有效補償干擾造成的誤差。在半導體製程的應用方面，Stoke 及 May [15] 發展半導體反應性離子蝕刻製程的類神經網路品質調控系統，類神經網路控制器包括類神經網路品質估計器及逆向類神經網路控制器。

由於類神經網路具有的學習能力，可經由學習偵測多變量製程動態的變異及建立控制行為的模式，因此，本研究提出利用倒傳遞類神經網路針對多重輸入及多重輸出 (multiple input and multiple output, MIMO) 製程，建構製程的預測及控制模式來補償干擾造成的誤差。首先，倒傳遞類神經網路預測器經由學習製程的輸出模式，預測製程的干擾輸出，接著，倒傳遞類神經網路控制器經由學習製程的調控模式，依據目標值與干擾輸出的誤差計算製程的參數調整量，來降低干擾產生的誤差。同時，為了驗證倒傳遞類神經網路預測器的預測績效，預測結果將與 Box-Jenkins 預測模式作比較。最後，利用半導體化學機械研磨 (chemical mechanical polishing, CMP) 製程為模擬驗證之對象，驗證倒傳遞類神經網路預測及控制器的可行性。

## 二、倒傳遞類神經網路

類神經網路 (artificial neural network) 之原理是模仿生物神經網路的資訊處理系統。以處理單元 (processing elements) 或稱神經元 (neurons) 組成「層」(layer)，再由各層組合為「網路」，不同層之神經元間以路徑相連來傳遞訊號及資訊，稱為「連結」(connections)。

倒傳遞網路 (back-propagation neural network, BPNN) 屬於監督式 (supervised learning) 學習網路，監督式學習網路的訓練樣本中，一組輸入值必定存在至少一對應之目標輸出值，由目標值與實際輸出值間的誤差調整連結之權重，可經由重複訓練減少誤差而產生輸入值與輸出值間的對應模式。然而在學習的過程中，倒傳遞的監督式學習是希望降低網路輸出單元目標值與推論輸出值之差異，一般都以能量函數 (誤差函數) 來表式學習品質：

$$E = \frac{1}{2} \sum_j (T_j - A_j)^2 \quad (1)$$

其中  $T_j$  為輸出層之目標輸出值

$A_j$  為輸出層推論輸出值

為了使能量函數在學習中達到收斂最小化，通常以最陡坡降法來訓練，每訓練一個範例即小幅調整權重值，其調整的公式如下：

$$\Delta W_{ij} = -\eta \cdot \frac{\partial E}{\partial W_{ij}} \quad (2)$$

$W_{ij}$  介於第  $n-1$  層的第  $i$  個處理單元與第  $n$  層的第  $j$  個處理單元間的連接值， $\eta$  為學習率，控制每次最陡坡降的步幅。利用連鎖率可推導出

$$\frac{\partial E}{\partial W_{ij}} = \left( \frac{\partial E}{\partial net_j^n} \right) \left( \frac{\partial net_j^n}{\partial W_{ij}} \right) \quad (3)$$

$$\frac{\partial E}{\partial W_{ij}} = \left( \frac{\partial E}{\partial A_j^n} \right) \left( \frac{\partial A_j^n}{\partial net_j^n} \right) \left( \frac{\partial net_j^n}{\partial W_{ij}} \right) \quad (4)$$

其中， $A_j^n$  為第  $n$  層第  $j$  個單元的推論輸出， $net_j^n$  為集成函數。根據類神經網路結構，輸入層將所收到的資料傳給隱藏層，隱藏層中的神經元先計算輸入資料加權後的總和，作為該神經元之輸入值，其關係式可寫成：

$$net_j^n = \sum W_{ij} A_j^{n-1} - \theta_j \quad (5)$$

其中， $A_j^n$  表第  $n$  層類神經元  $j$  之激發值， $W_{ij}$  表類神經元  $j$  至神經元  $i$  之間連結的權重， $\theta_j$  表類神經元  $i$  之修正誤差。將 (5) 式分別代入 (4) 式中

$$\frac{\partial net_j^n}{\partial W_{ij}} = \frac{\partial}{\partial W_{ij}} \left( \sum_k W_{kj} A_k^{n-1} - \theta_j \right) = A_i^{n-1} \quad (6)$$

$$\frac{\partial A_j^n}{\partial net_j^n} = \frac{\partial}{\partial net_j^n} f(net_j^n) = f'(net_j^n) \quad (7)$$

$\frac{\partial E}{\partial A_j^n}$  可分成兩種情況：

1. 如果第  $n$  層為網路的最後一層。

$$\frac{\partial E}{\partial A_j^n} = \frac{\partial}{\partial A_j^n} \left[ \frac{1}{2} \sum_k (T_k - A_k^n)^2 \right] = -(T_j - A_j^n) \quad (8)$$

2. 第  $n$  層不是網路的最後一層只是隱藏層之一。

$$\frac{\partial E}{\partial A_j^n} = \sum_k \left( \frac{\partial E}{\partial net_k^{n+1}} \right) \left( \frac{\partial net_k^{n+1}}{\partial A_j^n} \right) \quad (9)$$

其中，

$$\frac{\partial net_k^{n+1}}{\partial A_j^n} = \frac{\partial}{\partial A_j^n} \left( \sum_i W_{ik} A_i^{n-1} - \theta_k \right) = W_{jk} \quad (10)$$

定義

$$\frac{\partial E}{\partial net_h^n} = -\delta_h^n \quad (11)$$

可得到

$$\frac{\partial E}{\partial A_j^n} = -\sum_k \delta_k^{n+1} \cdot W_{jk} \quad (12)$$

從 (6)、(11) 代入 (3) 中可得到

$$\frac{\partial E}{\partial W_{ij}} = -\delta_j^n \cdot A_i^{n-1} \quad (13)$$

根據 (13) 代入 (2) 式可得

$$\Delta W_{ij} = \eta \cdot \delta_j^n \cdot A_i^{n-1} \quad (14)$$

其中， $\delta_j^n = W_{ij}$  所連接之較上層的處理單元之差距量。所以

$$\delta_j^n = \begin{cases} \text{如果 } W_{ij} \text{ 所連接之較上層的處理單元為輸出層} \\ \text{則 } \delta_j^n = (T_j - Y_j) \cdot f'(net_j^n) \\ \text{否則 } \delta_j^n = \left[ \sum_k \delta_k^{n+1} \cdot W_{jk} \right] \cdot f'(net_j^n) \end{cases} \quad (15)$$

其中  $Y_j$  為隱藏層處理單元之輸出值。從 (15) 式  $\delta_j^n$  的關係式得知，目標輸出值  $T_j$  與隱藏層單元處理輸出值  $Y_j$  其誤差如果收斂為零，則依據 (14) 中  $\Delta W_{ij}$  之權重調整也將收斂為

零，故將一組參數值當作網路之輸入，會得到一組期望之輸出值。

### 三、類神經網路預測及控制器的架構

製程控制主要利用參數調整方法，使得製程的輸出與目標值一致，同時，製程若受到干擾的影響而偏離目標時，亦能加以消除，本研究提出利用倒傳遞類神經網路建立干擾輸出的預測及控制模式，類神經網路預測及控制的架構如圖 1 所示。當製程輸出值  $Y$  受到一干擾訊號  $d$  的影響，而成為干擾輸出  $Yd$ 。收集干擾輸出，透過類神經預測器 (BPNN1) 預測下一期的干擾輸出  $\hat{Yd}$ ，類神經網路控制器 (BPNN2) 將  $\hat{Yd}$  與目標值  $T$  比較所產生的誤差  $e$  計算出調整參數量  $\Delta X$ ，並修正調整參數  $X$ ，使得輸出值與目標值一致。同時，為了建立製程模式，以提供設計及評估預測與控制器的效益，本研究利用田口實驗收集的製程輸入及輸出的資料來訓練類神經網路，建立製程的類神經網路模式 (BPNN0)。以下就干擾訊號的產生，類神經網路的預測及控制的方法加以說明。

#### (一) 干擾訊號

一般製程干擾訊號可分成兩類：一為非隨機的變異，例如如機器設備老化或工具的磨損、原料的差異等因素等造成的製程的偏移或漂移等現象，可用步階 (step) 或線性 (linear) 函數表示；另一種為隨機的變異，屬於不可歸屬原因的自然變異。干擾訊號  $d$  可由下式表示：

$$d = \delta + at + N \quad (16)$$

(16) 式中  $\delta$  為步階干擾、 $at$  為線性干擾及  $N$  為隨機干擾。製程輸出值  $Y$  受到干擾訊號  $d$  影響產生干擾輸出  $Yd$ 。  $Yd$ 、 $Y$  與  $d$  的關係式如下：

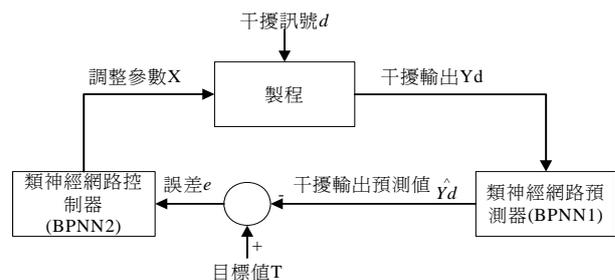


圖 1. 類神經網路預測及控制的架構

$$Yd = Y + d \tag{17}$$

將 (16) 式代入 (17) 式中，可得製程干擾輸出如下：

$$Yd = Y + \delta + kt + N \tag{18}$$

假設隨機干擾  $N$  為 ARIMA 時間序列模式 ARMA  $(p, q)$ ，ARMA  $(p, q)$  是考慮以自我回歸與移動平均的時間序列模式。若以 ARMA  $(1, 1)$  之時間序列模式為穩定隨機干擾，則干擾可寫成爲

$$N_{t+1} = \phi N_t + \varepsilon_{t+1} - \theta \varepsilon_t \tag{19}$$

其中  $\varepsilon_t \sim^{iid} N(0, \sigma^2)$  爲白噪音 (white noise)， $\phi$  爲 AR  $(1)$  (自我回歸模式) 的模式參數，其參數值介於  $-1$  到  $1$  之間。 $\theta$  爲 MA  $(1)$  (移動平均模式) 模式的參數，其值定義在爲  $-1 < \theta < 1$ 。在 ARMA  $(1, 1)$  模式中  $N_t$  與  $N_{t+1}$  存在自我相關程度  $\rho_0$ ，其關係式可以寫成

$$\rho_0 = \phi\psi = (1 - \phi\theta)(\phi - \theta) / (1 + \theta^2 - 2\phi\theta) \tag{20}$$

其中  $\psi$  爲製程輸出總變異，是由雜訊所引起的。

**(二) 預測模式之建構**

爲了使控制器能預知干擾輸出的變化，調整參數以消除干擾，在系統中建立預測模式來預測干擾輸出。本研究主要針對受到製程干擾所造成的輸出做預測，應用類神經網路與 Box-Jenkins (簡稱 B-J) 等人研究之預測模式來預測干擾輸出。比較兩種預測模式在預測製程的干擾輸出之績效，進而用於干擾輸出的預測。

**1. B-J 預測模式**

B-J 時間序列預測模式是一線性函數關係，利用線性關係來描述發生的時間序列干擾，根據 ARMA  $(p, q)$  模式，以及  $\varepsilon_t = N_t - \hat{N}_t$  可推得 B-J 之預測模式， $\hat{N}_{t+1}$  爲

$$\begin{aligned} \hat{N}_{t+1} = & N_t\phi_1 + \dots + N_{t-p+1}\phi_p + \theta_1(\hat{N}_t - N_t) + \dots \\ & + \theta_q(\hat{N}_{t-q+1} - N_{t-q+1}) \end{aligned} \tag{21}$$

其中， $N_t$ ：爲第  $t$  期的數列值。

$\hat{N}_t$ ：爲第  $t$  期的預測值。

$p$ ：爲自我相關之階層。

$q$ ：爲移動平均之階層。

**2. 類神經網路預測模式**

利用類神經網路預測干擾的輸出  $Yd$ ，首先進行預測模式(BPNN1)的線外訓練，每次收集前  $r$  期干擾輸出  $(Yd_t, Yd_{t-1}, Yd_{t-2}, \dots, Yd_{t-r+1})$  當作網路的輸入，網路的輸出則是下一期的干擾輸出  $\hat{Yd}_{t+1}$  建立類神經網路初期預測模式。利用初期預測模式，持續收集線上的干擾輸出來訓練類神經網路，以偵測製程的變異並預測干擾輸出。圖 2 爲類神經網路預測模式的架構圖。BPNN1 線上預測流程如圖 3 所示。

**(三) 類神經網路控制器**

針對製程干擾因素所造成的誤差，利用類神經網路建構控制器 (BPNN2) 來調整製程參數，消除誤差所造成製程的不穩定情況。首先，進行建立初步的 BPNN2 線外訓練。收集多筆製程輸入及輸出的資料，計算  $\Delta Y_t = Y_t - Y_{t-1}$  當作網路之訓練輸入，參數調整量  $\Delta X_t = X_t - X_{t-1}$  爲網路之輸出，線外訓練建立初步的 BPNN2 控制器調整模式。接著爲了針對製程的干擾輸出做有效的控制，BPNN2 必須持續收集輸出與目標值的誤差及輸入參數調整量，來訓練 BPNN2 類神經網路，以適應及學習製程的調整控制模式。圖 4 爲類神經網路控制器輸入參數調整的架構。其中控制器調整模式訓練網路的輸入爲

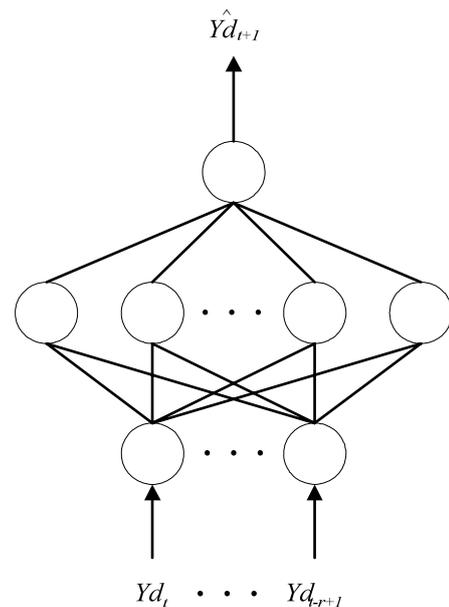


圖 2. 類神經網路預測模式架構圖

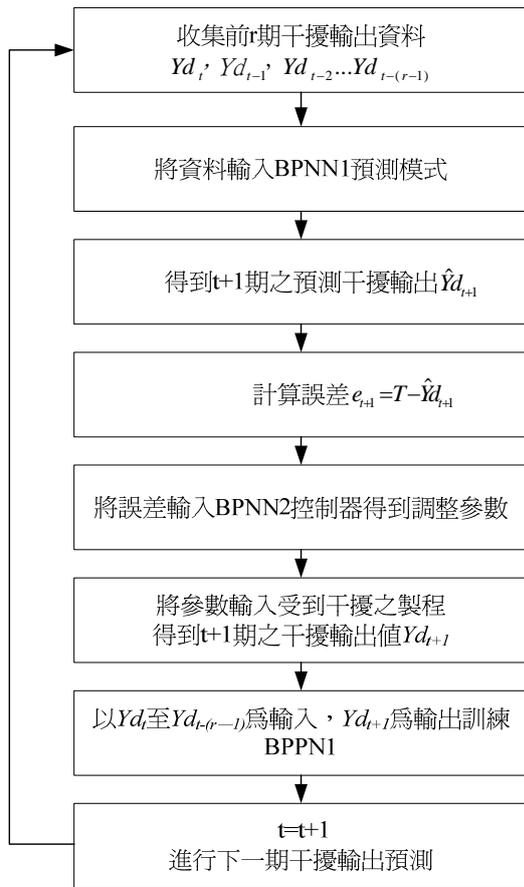


圖 3. BPNN1 網路線上預測流程

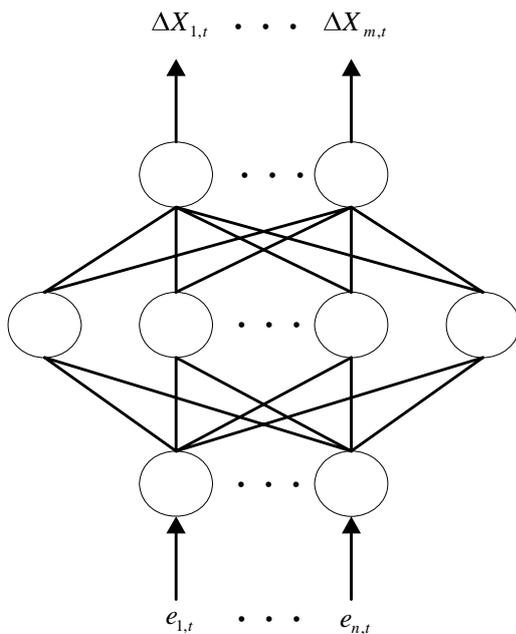


圖 4. 類神經網路控制器線上調整架構

$$e_t = T - \hat{Y}_d \tag{22}$$

$e_t$  表示在第  $t$  期目標值與預測輸出值的誤差值；訓練網路的輸出為  $\Delta X_t = X_t - X_{t-1}$ ，表示參數在第  $t$  期之參數調整量； $m$  及  $n$  分別表示輸入及輸出參數的個數。

為了符合實際製程的控制過程，由控制器調整參數來消除誤差時，控制器只能在製程設定的參數調整範圍內作控制調整，即  $Min(X_i) \leq X_i \leq Max(X_i)$ ； $Min(X_i)$  表示  $X_i$  可調參數的最小值， $Max(X_i)$  表示  $X_i$  可調參數的最大值。當  $X_i > Max(X_i)$  或  $X_i < Min(X_i)$  時， $X_i$  不作調整，即  $X_{i,t+1} = X_{i,t}$ 。BPNN1 預測下一筆的干擾輸出值，將此預測的干擾輸出與製程的目標值作比較所得的誤差，利用 BPNN2 產生參數的調整量，來調整製程輸入參數，進而減少干擾對製程的影響。圖 5 為 BPNN2 用於干擾輸出控制的整體流程圖。

#### 四、CMP 製程的模擬驗證

本研究以 CMP 製程為例，來驗證類神經網路的預測及控制器的效益。CMP 就是把晶片表面的介電層或金屬層加以平坦化的製程，透過研磨墊的機械運動及加入微細拋光粉粒之化學研磨液，來進行化學研磨及機械拋光而達到研磨的目的，CMP 的設備機構如圖 6 所示。化學機械研磨屬於 MIMO 製程，包含五個製程輸入設定參數：研磨液重量百分比 (X1)、下壓力 (X2)、背壓 (X3)、研磨平台轉速 (X4)、研磨時間 (X5) 等，與兩個輸出產品品質特性：平均移除率 (Y1)、研磨表面不均勻度 (Y2)。

為了建構製程模式，以供控制器的設計及模擬評估用，本研究 CMP 製程的模擬參考資料主要來自於周孟賢 [2] 所進行的 CMP 田口實驗的 25 筆研磨數據，利用類神經網路建構 CMP 的製程模式 BPNN0。網路輸入神經元定義為五個製程設定參數，而輸出神經元定義為兩個品質特性值，25 筆原始數據分為 20 筆訓練樣本及 5 筆測試樣本。類神經網路之網路結構中各路徑之初始權重及各神經元之初始誤差為隨機產生，迭代次數設定為 20000 次。經過測試後，BPNN0 內部的參數設定第一隱藏層 9 個類神經元，第二隱藏層 2 個類神經元，學習率訂為 0.4，慣性因子為 0.8，訓練函數為最陡坡降法，第一層之轉移函數為正切雙彎曲轉移函數，第二層採用線性轉移函數。網路的收斂程度，以誤差均方根計算，其誤差均方根公式如下：

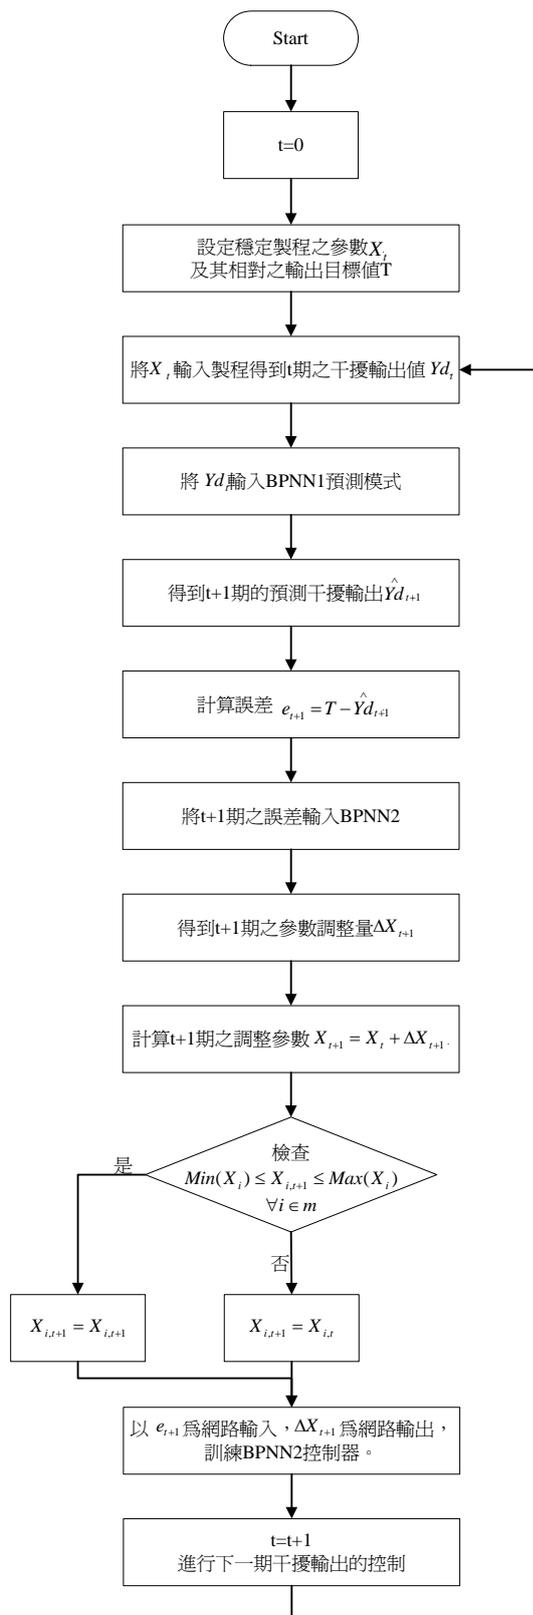


圖 5. BPNN2 用於干擾輸出控制的流程

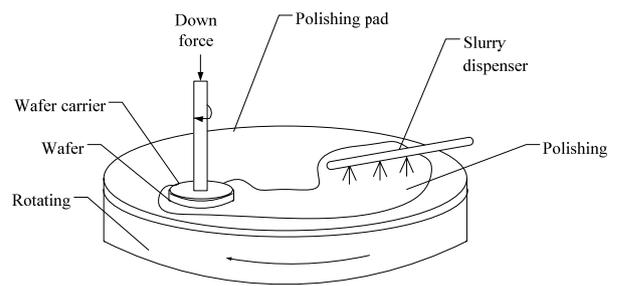


圖 6. 化學機械研磨的設備機構圖

$$\text{誤差均方根} = \text{MSE} = \sqrt{\frac{\sum_{p=1}^a \sum_{j=1}^b (T_j^p - Y_j^p)^2}{ab}} \quad (23)$$

其中

$T_j^p$  = 第  $p$  個範例的第  $j$  個輸出單元之目標輸出值

$Y_j^p$  = 第  $p$  個範例的第  $j$  個輸出單元之推論輸出值

$a$  = 範例數目

$b$  = 輸出層單元數目

利用 (23) 式我們求得類神經網路製程之 MSE，如表 1 所示。由表 1 得知，其收斂效果良好。表示所建立之 BPNN0 可以代表 CMP 製程輸入與輸出的關係。利用 BPNN0 作為 CMP 製程模式，並作為預測及控制器測試模擬之用。

#### (一) 預測模式分析比較

利用類神經網路及 B-J 的預測模式，對於製程受到時間序列的干擾做預測效益評估，並將較優的預測模式用來建構干擾輸出的預測。根據 (19) 式，假設干擾只有穩定隨機干擾模式 ARMA (1,1)，白噪音之變異數設為初始值之 2.5% 變量，製程參數設定值為周孟賢 [2] 研究中的最佳參數組合（如表 2 所示）， $Y_1$  及  $Y_2$  的白噪音分別設為  $\varepsilon_1 \sim N(0, 0.82^2)$  及  $\varepsilon_2 \sim N(0, 1.23^2)$ ，模擬 100 筆實際干擾輸出值。BPNN1 預測模式設定  $r=15$ ，利用前 15 期的輸出預測下一期的輸出。利用 BPNN1 模式及 B-J 模式預測干擾輸出，兩者的預測輸出與實際輸出作比較，結果得到如圖 7 到圖 10 所示。

表 1. 製程之 MSE

	BPNN0
訓練範例之 MSE	$2.77 \times 10^{-4}$
測試範例之 MSE	$3.84 \times 10^{-4}$

表 2. 預測模式的製程參數設定

	輸入參數					輸出值	
	X1	X2	X3	X4	X5	Y1	Y2
數值	0.1	7	3	50	40	32.437	49.11

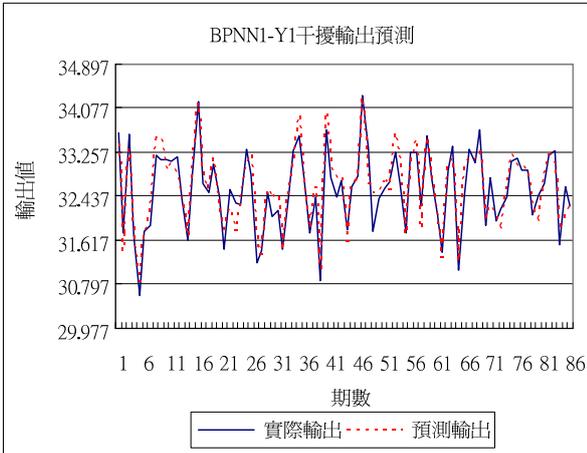


圖 7. BPNN1 預測 Y1 干擾輸出

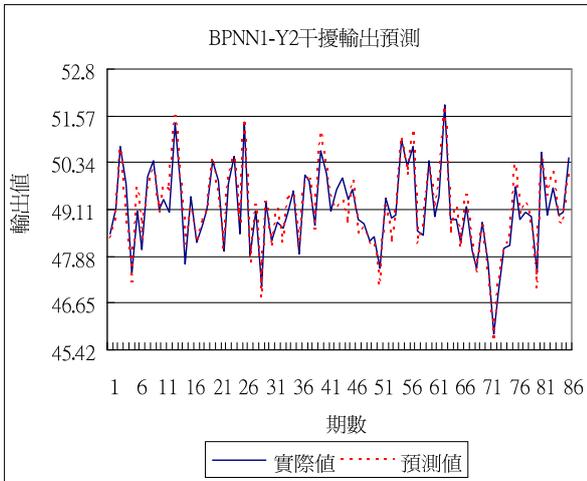


圖 8. BPNN1 預測 Y2 干擾輸出

計算 BPNN1 預測模式及 BJ 預測模式之 MSE，比較結果如表 3 所示。由表 3 得知，類神經網路之預測模式優於 B-J 之預測模式。

(二) 控制器效益評估

為了評估類神經預測及控制的效益，首先，在無干擾情況下，測試控制器對不同設定目標值下，調整參數以達目標值的能力，接著，評估在不同干擾情況下，控制器調整參數降低干擾造成製程變異的能力。

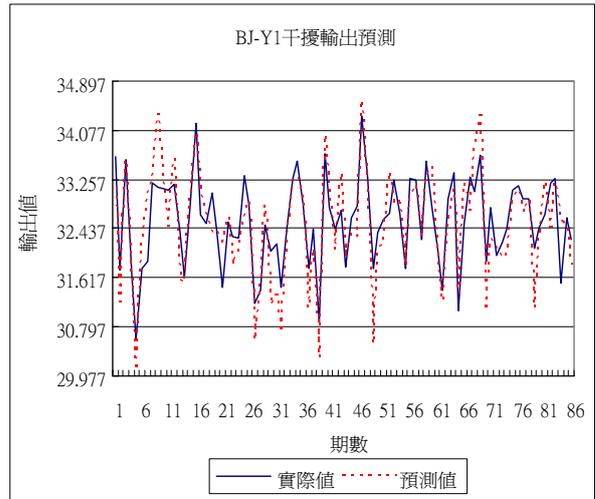


圖 9. B-J 預測 Y1 干擾輸出

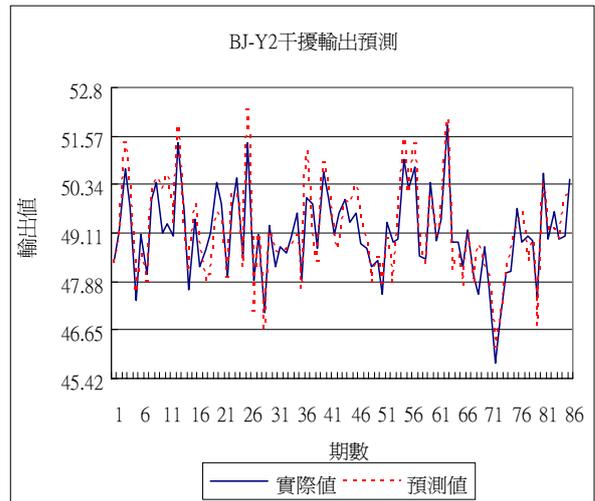


圖 10. B-J 預測 Y2 干擾輸出

表 3. 預測模式之 MSE 比較表

	BPNN1 預測模式	BJ 預測模式
Y1 干擾輸出	0.0718	0.2403
Y2 干擾輸出	0.1009	0.2791

1. 無干擾下控制器的效益評估

為了驗證控制器是否能依據設定目標值調整參數降低輸出與目標值誤差的能力，首先針對沒有干擾的輸出值做調整控制測試。參數的調整只考慮三個顯著影響的可調控參數 X2、X3 及 X4，參數 X1 及 X5 則固定不變。設定初始的輸入參數如表 4 所示；目標值 T 的設定值為三組，如表 5 所示。每組模擬 50 筆的資料，Y1 及 Y2 輸出結果如圖 11 及 12 所示，圖 13 至 15 分別為 X2、X3 及 X4 參數調整的情況。

表 4. 初始輸入參數

輸入參數	X1	X2	X3	X4	X5
參數初始值	0.1	6	1.75	40	40

表 5. 不同目標值的設定

期數	目標設定值	
	T1	T2
1	30	95
51	28	75
101	26	85

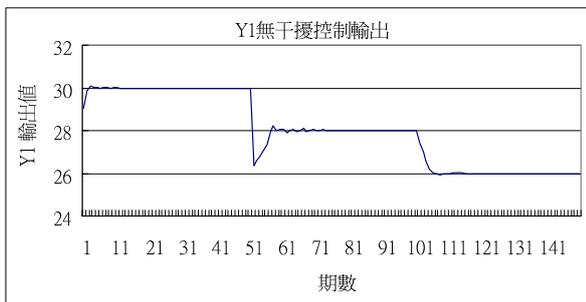


圖 11. Y1 無干擾時的控制輸出

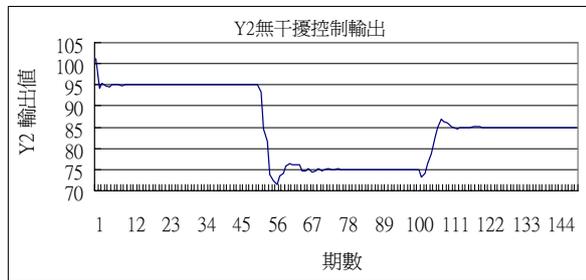


圖 12. Y2 無干擾無干擾時的控制輸出

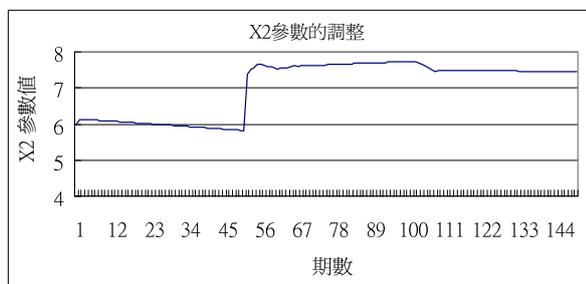


圖 13. X2 參數的調整



圖 14. X3 參數的調整

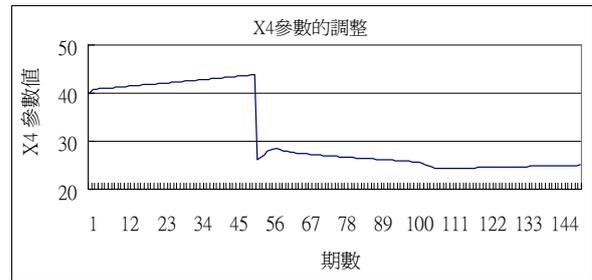


圖 15. X4 參數的調整

2. 有擾下控制器的效益評估

接著評估類神經預測及控制器對干擾所造成變異的補償效益，假設穩定隨機干擾模式為 ARMA (1,1)，白噪音之變異數為目標值之 2.5% 變量，以及干擾模式中步階之變化是由目標值標準差  $\sigma$  之  $k$  倍進行變動，考慮  $k=0,1,2,3$  四種步階干擾，受到步階干擾順序為  $k=0,2,1,3$ ，比較無預測控制與有預測控制的效益。初始參數值及目標值之設定如表 6 所示；其中輸出的初始值與目標值一樣，表示系統由穩定狀態下受到步階變動的干擾而偏離初始值（目標值）。圖 16 及圖 17 實線部份為  $k=0,2,1,3$  在無預測控制下，受到四種步階干擾下，輸出偏離目標值的情形。

在預測控制方面，只調整三個顯著影響的可控參數 X2、X3 及 X4，其餘參數 X1 及 X5 皆固定不變。圖 16 到圖 17 虛線部份為預測及控制器調整 Y1 及 Y2 受到  $k=0,2,1,3$  步階干擾輸出值的情形。由圖 16 及圖 17，可以發現 BPNN1 預測 Y1 及 Y2 之干擾輸出，BPNN2 進行參數的調整，有效

表 6. 初始參數及目標值

X1	X2	X3	X4	X5
0.1000	77.7725	3.4595	59.6300	40.0000
Y1	Y2	T1	T2	
33.9640	40.4670	33.9640	40.4670	

由圖 11 至 15 得知，在不同的設定目標值下，透過控制器的參數調整，均能調整輸出到達目標值上，結果證明類神經控制器具有調整製程參數以達目標值的能力。

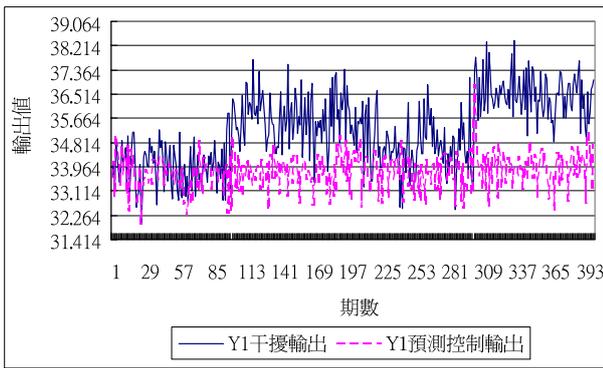


圖 16. Y1 有無預測控制的輸出

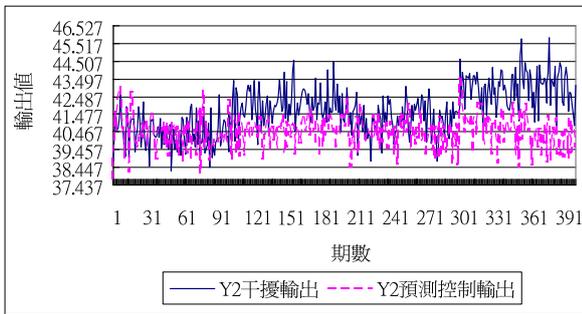


圖 17. Y2 有無預測控制的輸出

的降低步階干擾造成的製程偏移。為了比較預測控制與無預測控制之製程輸出，利用統計假設檢定來檢定控制之效益，檢定母體為輸出 Y 與目標值 T 的誤差， $e_{pr}$  及  $\sigma_{pr}$  表示預測控制誤差的平均數及變異數， $e_{po}$  及  $\sigma_{po}$  表示無預測控制誤差的平均數及變異數。檢定之樣本數各為 100 筆。採用母體平均數檢定及母體變異數檢定兩種，判別製程輸出的穩定程度。母體平均數檢定之假設檢定為  $H_0: e_{no} - e_{pr} \leq 0$ ，表示預測控制器其誤差大於無預測控制器。  $H_1: e_{no} - e_{pr} > 0$ ，表示預測控制器其誤差小於無預測控制器。母體變異數檢定為  $H_0: \sigma_{no}^2 \leq \sigma_{pr}^2$ ，有預測控制器比無預測控制器其輸出變異數較大。  $H_1: \sigma_{no}^2 > \sigma_{pr}^2$ ，有預測控制器比無預測控制

器其輸出變異數較小。檢定結果如表 7 所示。由表 7 檢定結果得知，預測控制器在存在干擾的情況下，能有效提升控制誤差能力，預測模式幫助控制器預測干擾輸出，使控制器能進行製程參數的調整並降低干擾造成的變異。

### 五、結論

本研究提出以倒傳遞類神經網路建構 MIMO 製程預測及控制模式。兩個類神經網路分別建立製程的輸出預測模式及製程調整模式，同時以倒傳遞類神經網路建立 CMP 製程輸入及輸出的關係模型，作為驗證類神經網路的預測及控制器的效益的評估對象。以下為本研究歸納的結論：

1. 比較類神經網路預測模式以及 B-J 預測模式，類神經網路預測模式之預測干擾輸出的能力，優於 B-J 預測模式。主要是因為類神經網路具有建構非線性預測模式的能力，優於 B-J 的線性化預測模式。
2. 利用線外訓練建立的初期類神經網路預測模式，接著，線上收集干擾輸出來訓練類神經網路，以可達到線上偵測製程的變異，完成預測干擾輸出的工作。
3. 利用線外訓練建立的初期類神經網路的控制模式，接著，線上收集干擾輸出與目標值的誤差及輸入參數的調整量來訓練類神經網路控制模式，透過適應及學習製程的模式，完成線上製程參數的調整，並降低干擾造成的變異。

本研究只考慮步階干擾及穩定隨機干擾，製程還有存在不同型態之干擾因素，未來之研究可針對不同干擾變異做更深入的探討。另外，製程的控制會產生成本的支出，成本的產生可能因為控制參數值的不同有所差異，未來之研究，可考慮控制成本上的因素，來進行製程控制的最佳化。

### 參考文獻

1. 江行全、范書愷、任志宏、王建智(民 90)，多變量自適應控制應用於半導體 R2R 製程，中國工業工程學會

表 7. 檢定結果比較

		k=0	k=1	k=2	k=3
Y1 有無預測控制模式之效益檢定	母體平均數檢定	否定 Ho	否定 Ho	否定 Ho	否定 Ho
	母體變異數檢定	否定 Ho	否定 Ho	否定 Ho	否定 Ho
Y2 有無預測控制模式之效益檢定	母體平均數檢定	否定 Ho	否定 Ho	否定 Ho	否定 Ho
	母體變異數檢定	否定 Ho	否定 Ho	否定 Ho	否定 Ho

- 九十年年度年會暨學術研討會，高雄。
2. 周孟賢 (民 89)，化學機械研磨時控制製程參數最佳化技術，國立中興大學機械工程學系碩士論文。
  3. Astrom, K. J., U. Borisson, L. Ljung and B. Wittenmark (1977) Theory and application of self-tuning regulations. *Automatica*, 13, 457-476.
  4. Azouzi, R. and M. Guillot (1996) Control and optimization of the turning process using a neural network. *Japan/USA Symposium on Flexible Automation ASME*, 2, 1437-1444.
  5. Box, G. E. P. and T. Kramer (1992) Statistical process monitoring and feedback adjustment-a discussion. *Technometrics*, 34, 251-267.
  6. Butler, S. W. and J. A. Stefani (1994) Supervisor run-to-run control of polysilicon gate etch using in situ ellipsometry. *IEEE Transactions on Semiconductor Manufacturing*, 7(2), 193-201.
  7. Cho, H. S. (2001) Neural network applications to manufacturing processes: Monitoring and control. In: *Computational Intelligence in Manufacturing Handbook*. J. Wang and A. Kusiak Eds. CRC Press.
  8. Del Castillo, E. (1996) A Multivariate self-tuning controller for run-to-run process control under shift and trend disturbances. *IIE Transaction*, 28(12), 1011-1021.
  9. Del Castillo, E. and J. Yeh (1998) An adaptive run-to-run process optimizing control for linear and nonlinear semiconductor process. *IEEE Transactions on Semiconductor Manufacturing*, 11(2), 285-259.
  10. Guo, R. S., A. Chen and J. J. Chen (2000) Run-to-run control schemes for CMP process subject to deterministic drifts. *Semiconductor Manufacturing Technology Workshop*, Hsinchu, R.O.C.
  11. Lim, T. G. and H. S. Cho (1995) A study on the estimation and control of weld pool sizes in GMA welding processes using multilayer perceptrons. *Journal of Intelligent Manufacturing*, 6, 389-400.
  12. Montgomery, D. C. (2001) *Introduction to Statistical Quality Control*, 4th Ed., John Wiley & Sons, New York.
  13. Sachs, E., A. Hu and A. Ingolfsson (1995) Run by run process control: Combining SPC and feedback control. *IEEE Transactions on Semiconductor Manufacturing*, 8(1), 26-43.
  14. Shao, Y. E. and C. C. Chiu (1999) Developing identification techniques with the integrated use of SPC/EPC and neural networks. *Quality and Reliability Engineering International*, 15, 287-294.
  15. Stokes, D. and G. May (1996) Real time control of reactive ion etching using neural network. *Proceeding American Control Conference*, Albuquerque, NM.
  16. Tang, Z. (1991) Time series forecasting using neural network vs. box-jenkins methodology. *Simulation*, 57, 303-331.
  17. Yeh, J. and B. Huang (2003) Genetic algorithm based semiconductor manufacturing process controller for chemical mechanical planarization. *Journal of the Chinese Institute of Industrial Engineers*, 20(6), 625-635.

收件：96.01.10 修正：96.04.17 接受：96.06.25