

第二章 文獻探討

近年來，具有自我相關的製程資料之管制越來越受到工業界之重視，中外文獻陸續提出一些新的分析方法，或是改良傳統的管制分析工具以有效監控具自我相關特性的製程。但這些文獻之重點大多是放在管制單品質特性的製程上，對於具自我相關之多變量製程的研究則非常少見，結合 EPC 程序的自我相關多變量製程之研究則未見任何文獻提出。以下是與本研究有關的一些文獻之介紹。

2.1 自我相關製程的統計製程管制

針對具有自我相關特性之資料施行統計製程監控的時候，若使用傳統的管制工具，則會大幅提高假警報的機率（即型 I 誤差），使得在管制狀態下的製程其平均連串長度(Average Run Length; ARL)大為縮短，嚴重影響到判斷製程是否穩定的正確性。即使資料間之自我相關性不強，亦會造成相當程度的影響。所以當製程具有一定程度的自我相關性時，便應該使用其他可信賴的管制程序以避免傳統製程管制所帶來的錯誤訊息。

2.1.1 自我相關製程之統計製程管制的方法

探討監控自我相關製程之產品平均值的文獻相當多。Bagshaw 與 Johnson [5] 探討具自我相關性的製程對於累積和管制圖(Cumulative-Sum Control Chart, CUSUM)的影響。Vasilopoulos 與 Stamboulis [15]藉由修正傳統的蕭瓦特管制圖之管制界限來處理具自我相關性的製程所引起的假警報頻率提升的問題。Alwan 與 Roberts [4]針對具自我相關性的製程，建立合適的時間序列模型後，再對其殘差做管制圖。尤其在製程為差分移動平均(Integrated Moving Average, IMA)(1,1)模式下，此方法可有效的監控制程。Zhang [17]提出了指數加權移動平均穩態(Exponentially Weighted Moving-Average Stationary, EWMAST)管制圖，監控穩態(stationary)的製程均值做。Jiang et al. [10]則是針對具自我相關的製程工業資料，提出了自我迴歸移動平均(Autoregressive Moving Average, ARMA)管制圖。ARMA

管制圖利用時間序列中的 ARMA 統計量作為此管制圖所監控的統計量，並推導出適當的管制界限。Alwan 和 Roberts 或是 Zhang 所發展的管制圖，都可證明是 ARMA 管制圖的特例。Loreedo et al. [8]則是針對化學製程建立一個複迴歸模型，然後利用此模型來預測下一時點之資料，再利用觀測值與預測值所得之殘差來建立管制圖。上述文獻之研究，均只針對單變量製程來進行自我相關性資料的管制程序。

綜觀過去文獻，可區分為兩大類，其一是仍採用傳統管制圖手法，估計製程參數，再根據所估得的參數修正管制界限，以排除製程自我相關性對型 I 誤差的影響，此種作法大多應用在製程相關性不高的情況；其二則是使用殘差的手法，先由製程觀測值建立一個合適的時間序列模型，再求得其預測誤差或是殘差，如此即可利用其近似相互獨立且來自相同分配的特性，進而針對預測誤差或殘差來建構傳統的管制圖來監控制程。

2.1.2 類神經網路在自我相關製程管制上的應用

在實際的工業製程中，製程狀態是隨著時間不斷變化，雖然線性製程管制的計算簡單且易於分析，但無法有效解決一些非線性製程問題。而在這方面類神經網路預測模式可以提供一個很好的學習效果。

在處理具有自我相關性的製程數據資料時，許多研究也嘗試透過類神經網路來進行製程控制。本研究採用的倒傳遞神經網路是類神經網路中的一種，可用輸入向量和其所對應的目標向量來訓練網路，直到網路能夠逼近於一個函數，或是能夠用指定的輸出來聯想輸入向量。倒傳遞網路具有偏權值，隱藏層具有雙彎曲轉移函數，輸出層具有線性轉移函數，如此使得網路能夠逼近於有限個不連續點的任何函數。其網路架構如圖2.1所示，為兩層的網路；假設輸入維度是 p ，隱藏層類神經元的數目是 J ，則網路的輸出可以式2.1表之：

$$F(\bar{x}) = \sum_{j=1}^J w_j \varphi_j(\bar{x}) + b_j \quad (2.1)$$

其中 $\bar{x} = (x_1, \dots, x_p)^T$ 代表輸入向量， w_j 代表第 j 個隱藏層類神經元到輸出類神經元的鍵結值， b_j 代表第 j 個隱藏層類神經元到輸出類神經元的偏權值， $\varphi_j(\bar{x})$ 代表第 j 個隱藏層類神經元的輸出值，以及 $F(\bar{x})$ 代表網路的輸出函數。

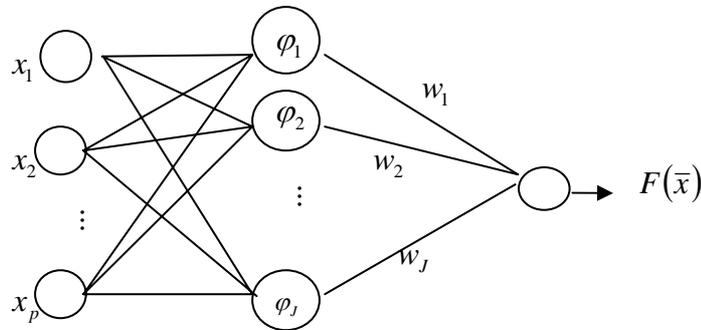


圖 2.1 倒傳遞網路架構

2.1.3 類神經網路在相關型製程管制上的相關文獻

Cook 與 Cuiu [7] 建立一個以類神經網路為基礎之管制方法，主要用來偵測製程平均值偏移之變化。他們研究的對象是具有自我相關性之製程資料。研究結果顯示，當製程產生了具有自我相關性的數據時，類神經網路可以比傳統 SPC 管制法更有效地偵測出製程的移動量。

萬維君 [3] 發展出一個以類神經網路為基礎之偵測系統並建構訓練樣本。然後利用所訓練的網路來偵測製程平均值是否偏移及估計平均值之偏移量，以與傳統 CUSUM 管制圖比較。結果顯示在偵測製程平均值是否產生偏移及估計平均值偏移量上，類神經網路之效益都比 CUSUM 管制圖來的好。

李柎梓 [1] 發展兩個類神經網路來進行單變量 SPC。第一個類神經網路 (NN-1) 是用來建立具有自我相關性之結構，以去除製程中相關性之干擾。接著以第二個類神經網路 (NN-2) 來做為監控制製程之工具。NN-2 包含一個輸出運算元，網路之輸出運算元表示製程平均值是否改變。李柎梓利用蒙地卡羅模擬法模擬出各種不同製程偏移量之數據，來作為類神經網路之訓練樣本。

2.2 多變量管制

隨著科技的進步，產品的功能越來越多，製程的複雜度也日漸提升，而且這些製程或品質變數彼此間並不完全獨立，因此，如果把這些變數視為獨立且分別繪製管制圖予以監控，則會增加誤判的機率，所以探討及發展多變量管制（multivariate statistical process control）的方法有其必要性。

2.2.1 多變量管制圖簡介

一個產品的品質特性變數間常具有一定程度的相關性，而傳統管制圖的最大可議之處為其將品質變數均當成彼此獨立的變數，如此將會失去很多品質特性間相關性的訊息。假設兩變數(Y_1, Y_2)彼此具有顯著相關性(例如：相關係數 $\cong 0.8$)，圖 2.2 中顯示兩個變數的蕭瓦特管制圖，且當兩個變數具有相關性時，其二元變數的信賴區間應為橢圓分佈之圖形。由圖 2.1 可以看到兩者的觀測值均在管制界限之內，如只用單變量管制圖來偵測，其結論為製程正常，但若用多變量管制圖，則可看出某一點落在信賴區間之外，所以此點應屬異常點，但在單變數管制圖中卻無法偵測出此異常點，因此由這個例子可以很清楚的瞭解到變數之間具有相關性時，單獨使用單變數管制圖可能會發生誤判的情形。

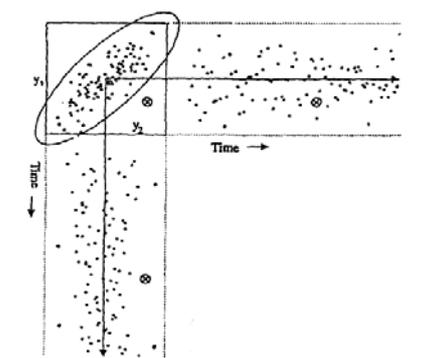


圖 2.2 兩相關變數之二元信賴區間及個別 Shewhart 管制圖[13]

對目前高科技產業而言，只分別偵測產品之單品質特性是不夠的，因為在製程中可能存在有多個彼此具相關的品質特性造成製程異常；再者，隨著生產設備

的自動化，收集數據已不是什麼太大的問題，因此如果我們想將品質做進一步推升，考慮更多的製程變數及最終產品的品質特性就顯得相當重要了。多變量品質管制法就是為了因應這樣的想法所衍生出來，其做法為同時監控多個品質特性，並將數個變數之間的相關性納入考慮，此種品質管制方法即稱為多變量統計製程管制。

在多變量管制圖中，當觀測點超出管制界限時，則表此製程失控，由於多變量製程包含了兩個以上的品質特性，因此造成失控的原因可能來自於許多個不同的品質特性。

2.2.2 Hotelling's T^2 管制圖

Hotelling [9]所建立之多變量管制圖主要的想法是利用新觀測值與歷史資料平均值之間的距離來監控多變量製程是否失控。

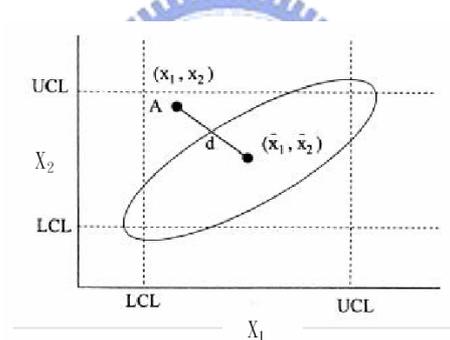


圖 2.3 二元管制區

假設變數 X_1 及 X_2 表製程的兩個品質特性，其個別之 \bar{X} 管制圖之上、下管制界限如圖 2.2 所示，其中中心點 (\bar{x}_1, \bar{x}_2) 為資料的平均值，從點 $A(x_1, x_2)$ 到平均值的直線距離為： $D = \sqrt{(x_1 - \bar{x}_1)^2 + (x_2 - \bar{x}_2)^2}$ 。當 D 值大到一定程度時，即認為 A 點顯著地偏離 (\bar{x}_1, \bar{x}_2) ，也就是極有可能發生異常；然而，這樣的方式忽略了變數 X_1 、 X_2 間的相關性，因此利用變數 X_1 、 X_2 自身的變異數 σ^2_1 和 σ^2_2 及共變異數 σ^2_{12} 做矯正。根據二元常態分配密度函數(Binary Normal distribution density function)，我們可以得到一個卡方統計量(Chi-Square Statistics)：

$$\chi_0^2 = \frac{1}{\sigma_1^2 \sigma_2^2 - \sigma_{12}^2} [\sigma_2^2 (x_1 - \mu_1)^2 + \sigma_1^2 (x_2 - \mu_2)^2 - 2\sigma_{12}^2 (x_1 - \mu_1)(x_2 - \mu_2)] \quad (2.2)$$

此統計量服從自由度為 2 的卡方分配。上式可說是多變量管制圖的基礎，其物理意義即方程式所代表二維平面上橢圓形的軌跡，如圖 2.2 所示。利用樣本點是否在橢圓形內即可判斷出製程正常與否，故稱之為橢圓管制圖。

瞭解橢圓管制圖的觀念後，可以將二變數之管制圖擴展成 p 個變數的 Hotelling's T^2 管制圖。在實際應用上，因為母體的平均數與變異數通常無法事先得知，所以需利用歷史資料來估計期望值和標準差。假設對 P 個品質特性，分別選出管制界限內 m 組大小為 1 的樣本，則第 j 個品質特性的第 i 個觀測值可表示為 x_{ij} ($i=1,2,\dots,m$ 、 $j=1,2,\dots,p$)，所有之 x_{ij} 可用矩陣表示如下：

$$X = \begin{bmatrix} x_{11} & x_{12} & \dots & x_{1p} \\ x_{21} & x_{22} & \dots & x_{2p} \\ \cdot & \cdot & \dots & \cdot \\ x_{m1} & x_{m2} & \dots & x_{mp} \end{bmatrix} \quad (2.3)$$

利用 X 可計算出樣本平均值 $\bar{x} = [\bar{x}_1 \ \bar{x}_2 \ \bar{x}_3 \ \dots \ \bar{x}_p]$ 。接著便可得到樣本的共變

異數矩陣如下：

$$S = \begin{bmatrix} S_{11} & S_{12} & S_{13} & \dots & S_{1p} \\ & S_{22} & S_{23} & \dots & S_{2p} \\ & & S_{33} & \dots & S_{3p} \\ & & & \cdot & \cdot \\ & & & & S_{pp} \end{bmatrix} \quad (2.4)$$

若有一新觀察值 $x'_0 = [x_{01} \ x_{02} \ x_{03} \ \dots \ x_{0p}]$ ，則可利用下式計算 T^2 統計量：

$$T^2 = (x_0 - \bar{x})' S^{-1} (x_0 - \bar{x}) \quad (2.5)$$

當所計算之 T^2 統計量大於 $\frac{p(m+1)(m-1)}{m^2 - mp} F_{\alpha, p, m-p}$ 時，其中 $F_{\alpha, p, m-p}$ 表自由度為 p 及

$m-p$ 且具右尾端機率為 α 的 F 統計量時，則判定此觀察值出現異常。

2.2.3 T^2 統計量之診斷

由 T^2 統計量偵測得知觀察值出現異常時，則需知道到底是哪一個品質特性發生變異而導致 T^2 統計量發生失控的情形。Mason et al. [11]利用迴歸分析的方法將 T^2 統計量分解成各個不同的獨立部分，藉此找出造成多變量製程失控的品質特性到底是哪一個。此一方法根據Mason等人名字的第一個字母命名為「MYT分解法」。MYT分解法是將 T^2 統計量分解如下：

$$T^2 = T_{p-1}^2 + T_{p,1,2,\dots,p-1}^2 \quad (2.6)$$

其中 T_{p-1}^2 就是利用前 $p-1$ 個變數所求出的 T^2 統計量，而 $T_{p,1,2,\dots,p-1}^2$ 為利用前 $p-1$ 個變數針對第 p 個變數矯正後所得的 T^2 值。 $T_{p,1,2,\dots,p-1}^2$ 的計算方式如下：

$$T_{p,1,2,\dots,p-1}^2 = \frac{x_p - \hat{x}_{p,1,2,\dots,p-1}}{s_p \sqrt{(1 - R_{p,1,2,\dots,p-1}^2)}} = \frac{r_{p,1,2,\dots,p-1}}{s_p \sqrt{(1 - R_{p,1,2,\dots,p-1}^2)}} \quad (2.7)$$

其中 s_p 是第 p 個變數的標準差， $r_{p,1,2,\dots,p-1}$ 為迴歸的殘差項， $R_{p,1,2,\dots,p-1}^2$ 為判定係數(Coefficient of Determination)。由上式我們可以發現造成 $T_{p,1,2,\dots,p-1}^2$ 顯著的原因除了判定係數 $R_{p,1,2,\dots,p-1}^2$ 很接近1時，可能會造成其顯著外，當分子 $r_{p,1,2,\dots,p-1}$ 值很大時也會造成 $T_{p,1,2,\dots,p-1}^2$ 顯著，因此表示第 p 個變數很有可能發生問題，因為其與過去歷史資料所建立之迴歸模式所預測之應有結果有相當大的出入。之後繼續拓展 T^2 統計量的一般形式如下：

$$T^2 = T_1^2 + T_{2,1}^2 + T_{3,1,2}^2 + \dots + T_{p,1,2,\dots,p-1}^2 = T_1^2 + \sum_{j=1}^{p-1} T_{j,1,2,\dots,j-1}^2 \quad (2.8)$$

T_1^2 是第一個變數的 T^2 統計量，也是第一個變數的 T_1^2 統計量， T_1^2 可表示如下：

$$T_1^2 = \frac{(x_1 - \bar{x}_1)^2}{s_1^2} \sim \left(\frac{m+1}{m}\right) F_{\alpha,1,m-1} \quad (2.9)$$

利用上式的分解，我們可進一步探討一些與其相關的特質，首先在這裡必須澄清的是第(2.13)式的寫法並非唯一，總共應該有 $p!$ 不同的分解方式，我們可以在這

p 個變數中任選一個開始，再利用剩餘的 p-1 個變數針對第一個選出的變數作迴歸分析，接下來再從這 p-1 個變數中挑出一個變數，再利用剩餘的變數對此被挑出的變數作迴歸分析，如此反覆執行即可得到 p! 不同的分解方式。

2.3 工程製程管制

工程製程管制(engineering process control, EPC)提供一種消除製程輸出值與目標值之間差距的方法。Box 與 Kramer [6]首先提出 EPC 的概念，他們認為 EPC 是一種自動回饋控制的過程，主要是為了調整製程中所存在的干擾。Montgomery [13]認為 EPC 通常假設製程的輸入與輸出之間具有一定的函數關係，EPC 的精神即是藉由參數估計的方式，經由控制變數來對製程偏移進行調節控制，使製程輸出值能夠接近目標值。EPC 的基本觀念是認為在連續性產業中，通常會透過自動化設備，經由控制系統所具備之回饋或適應機制，對製程偏移做適當的調節，使製程的輸出值能接近預設之目標值。EPC 管制法便是在每個時間點上，比較觀測值與目標值，透過資訊回饋機制，來告知工程人員或自動化機器持續性地調整控制變數，用以縮短輸出值與目標值之間的差距。

2.3.1 工程製程管制的推導

假定一製程中， Y_t 為時間點t之製程輸出值，目標值為T，此製程中存在一個可控制變數為 X_t ，則管制目的是要調整可控制變數以使得下一時間點之輸出值(Y_{t+1})接近目標值。首先將輸出值以數學模式寫為：

$$Y_{t+1} = T + gX_t \quad (2.10)$$

其中g為一常數值，稱之為製程增益值(process gain)。此增益值就像是一個迴歸係數，可使控制變數放大或縮小倍數，製程輸出值也會跟著放大或縮小倍數。假如對於製程沒有進行調整的活動，製程在正常的狀況下會受到雜訊干擾之影響，而使製程產生跳動以致偏離目標值，即數學模式可寫為

$$Y_{t+1} - T = N_{t+1} \quad (2.11)$$

其中 N_{t+1} 為時間點t+1的雜訊值，此雜訊值的模式通常可以時間序列來表示。因

為 N_{t+1} 通常未知，故對 N_{t+1} 進行預測。Montgomery[13]假設 N_{t+1} 是為ARIMA(0,1,1)干擾過程，又稱為IMA(1,1)，也稱為EWMA，即 $N_{t+1} = N_t + e_{t+1} - \theta e_t$ ， θ 為MA(1)模式之相關參數， $e_{t+1}=0$ 且 $e_t = N_t - \hat{N}_t$ ，為t時間點的預測誤差，可得雜訊預測模式為：

$$\hat{N}_{t+1} = N_t - \theta(N_t - \hat{N}_t) = N_t - \theta N_t + \theta \hat{N}_t = \theta \hat{N}_t + (1 - \theta)N_t \quad (2.12)$$

令 $\theta = 1 - \lambda$ ， λ 為EWMA參數值，其範圍為 $0 < \lambda \leq 1$ 。故(2.12)式可表為(2.13)式：

$$\hat{N}_{t+1} = (1 - \lambda)\hat{N}_t + \lambda N_t = \hat{N}_t + \lambda e_t \quad (2.13)$$

如果欲對發生變動之製程其所產生的偏移，主動地進行調整，則製程應該包含在時間點t+1的雜訊項以及在時間點t的可控制變數，此兩項因素造成製程輸出值偏移目標值，因此製程數學模式可寫為下式：

$$Y_{t+1} - T = N_{t+1} + gX_t \quad (2.14)$$

由於雜訊干擾 N_{t+1} 未知，因此先對 N_{t+1} 進行預測動作，在此令殘差值表示如下：

$$e_{t+1} = N_{t+1} - \hat{N}_{t+1} \quad (2.15)$$

則調整時的製程模式可表示如下：

$$Y_{t+1} - T = e_{t+1} + \hat{N}_{t+1} + gX_t \quad (2.16)$$

為了要消除影響製程的雜訊干擾，其調整策略便是令 $\hat{N}_{t+1} = -gX_t$ ，也就是令

$X_t = -(1/g)\hat{N}_{t+1}$ 。因此若對製程進行EPC管制則調整過後所得到的製程數學模式可表示如下：

$$Y_{t+1} - T = e_{t+1} \quad (2.17)$$

製程輸出值就變為白噪音過程(white noise process)，在預設目標值之水準上下跳動。實際調整時，在時間點t的製程可控制變數如下式：

$$X_t - X_{t-1} = -(1/g)(\hat{N}_{t+1} - \hat{N}_t) = -(1/g)(\lambda e_t) \quad (2.18)$$

故實際上在時間點 t 的可控制變數 X_t ，為所有調整的總和，可表示如下：

$$X_t = \sum_{j=1}^t (X_j - X_{j-1}) = -\frac{\lambda}{g} \sum_{j=1}^t e_j \quad (2.19)$$

這種對製程的調整方法，在工程學上即稱為積分控制(integral control)。

2.3.2 工程製程管制的相關文獻

Montgomery et al.[12]比較使用 EPC 程序下與使用結合 SPC 和 EPC 程序下其回饋控制之效率。結果證明在使用 SPC 結合 EPC 程序下，當管制圖偵測出製程發生失控的情形時進行回饋控制之結果確實比只使用 EPC 程序來的更有效率，避免由於白噪音的影響而進行無謂的回饋控制。除了使用傳統的蕭瓦特管制圖進行 SPC 結合 EPC 之程序外，Shao [14]針對當製程產生小偏移時，提出以 CuSum 管制圖為基礎來進行改良的 Cuscore 管制圖，此管制圖是整合 SPC 與 EPC 的重要媒介，一方面修正製程輸出偏離目標值之差額，一方面利用 Cuscore 管制圖針對製程產生小偏移進行監控管制，將可消除製程之自我相關性並降低製程變異。

在實際進行 EPC 程序時，其製程增益值並非為固定常數，造成進行回饋控制時不能以傳統 EPC 的線性模式來進行，所以後來文獻便對此做了修正。徐偉晉 [2] 分別針對反應曲面技術之有限度回饋控制模式與輻射基底函數網路找出最適當的製程參數調整量，來進行切割作業改善之比較。經由實驗與評估指標最小均方誤差以及調整率的衡量，證實使用有限度回饋控制與輻射基底函數網路，均能得到比現行作業更佳的回饋控制效果，其中又以輻射基底函數網路所得之改善效果較為明顯。

陳詩銓[4]發展出以經濟考量為依據的單變量製程控制器。在進行 EPC 程序時，傳統大多採用最小均方差 PI 控制器和 Integral 控制器，但是當考慮到經濟的要素時，它們就不是最適當的控制器。故其主要的目的就是針對兩種過程：(1). 非穩定的整合移動平均 (IMA(1, 1)) 過程 (2). 穩定的自迴歸 (AR(p)) 過程，發展出以經濟考量為依據的新控制器。

Stokes et al. [18] 提出了倒傳遞網路控制器，利用製程輸出值與目標值間的誤差，透過運算式的推導，即可得到製程參數修正量如下：

$$\Delta x_{t+1} = \prod_n \left(\sum_f f'(net_j^n) * w_y \right) * e_t \quad (2.20)$$

其中 Δx_{t+1} 為第 t+1 期的參數修正量； $f'(net_j^n)$ 為第 n 層第 j 個處理單元之加權輸入值經轉換函數微分後之值， e_t 則為第 t 期製程輸出值與目標值間的誤差。本研究便是根據輸出值與目標值間的誤差，利用此控制器之運算式來計算各個輸入變數所對應的參數調整量，藉由各變數的調整量來作為選擇控制變數之開端。

2.3.3 整合 SPC 與 EPC 的相關文獻

盧淑蘭[5]主要比較在不同的自我相關性與偏移程度下，使用 Shewart 管制圖、CUSUM 管制圖及 EWMA 管制圖來進行 EPC 整合 SPC 對自我相關性資料的處理能力。當自我相關程度低時，EPC 與 SPC 整合及時間序列模式法的處理結果是很相似的。然而當資料具有高度自我相關時，EPC 整合 SPC 會優於時間序列模式法。CUSUM 與 EWMA 管制圖的偵測能力在以下幾種情形下明顯比 Shewart 管制圖好：(1)在階梯式干擾下，自我相關程度低且偏離程度介於 0.5~1 倍標準差；(2)在階梯式干擾下，自我相關程度高且偏離程度介於 1~3 倍標準差；(3)線性干擾時，偏移斜率介於 0.05~0.1 之情形下。因此使用此二種管制圖來作製程的監控會是很不錯的選擇。