

## 以類神經網路改善累積和管制法偵測成效之研究

鄭盛樹

育達商業技術學院企業管理系  
苗栗縣造橋鄉談文村學府路 168 號

### 摘要

累積和管制法在偵測製程平均值的微量偏移時，優於蕭華特管制圖的偵測能力。但由於累積和管制法是以簡單對立假設為基礎的逐次機率比檢定法所衍生而得，因此操作累積和管制法時，必須先固定此管制法中的參考值。而參考值的設定方法與製程為管制外時之狀態有關，以實務而言，參考值應隨時變動以反應製程之改變。但在學理上，目前參考值的設定方法，均以事先設定之固定參考值大小於管制圖的操作中。為改善此一缺點，本研究提出以類神經網路為基礎之參考值設定方法，利用製程之現有數據以類神經網路提供及時之參考值大小，再由累積和管制法判斷製程是否異常。此方法之目的在於改善固定參考值的缺點，以擴大累積和管制法的有效偵測範圍。研究結果顯示，本文所提之改善方案將比使用固定參考值之傳統累積和管制法更具偵測效益。

**關鍵詞：**累積和管制法，類神經網路，平均連串長度，統計製程管制

## A Study of the Improvement in the Detection Capability of CUSUM Control Charts Based on a Neural Network

SHENG-SU CHENG

*Department of Business Administration, Yu-Da College of Business  
168, Hsueh-fu Rd, Tanwen Village, Chaochiao, Miaoli, Taiwan*

### ABSTRACT

Cumulative sum (CUSUM) charts are known to be very sensitive in detecting small shifts in the process mean, the magnitude of which should be known before using such a chart. However, in the real world, the mean shifts may be changing dynamically in a running process; therefore, it is difficult to obtain an exact value in practical operation. Moreover, the superiority of a CUSUM chart will be lost if improper reference values are chosen. Usually a constant reference value for a CUSUM control chart is selected on the basis of what one is interested in detecting quickly. In this study, a neural network was employed as an alternative approach to the estimation of the reference parameters of a CUSUM. This network provided the reference value for a CUSUM chart on the basis of current process data, but the discriminating criterion was still constructed by a general CUSUM. Average run lengths (ARLs) using simulation were used to evaluate the performance of this procedure. The results show that this charting procedure, based on the hybrid of a statistical method and a neural

network, extended not only the utility of the CUSUM chart but also the alternative SPC (statistical process control) solution.

**Key Words:** CUSUM charts, neural network, average run length, SPC (statistical process control)

## 一、前言

在管制圖的使用上，一般皆使用蕭華特管制圖 (Shewhart control chart) [9] 做為即時品管的工具。雖然蕭華特管制圖簡單易用，且對於大幅度的製程平均值偏離具有相當好的偵測能力。但其缺點為僅使用最後一組樣本資料做為判斷製程狀態的依據，因此導致蕭華特管制圖對於微量的製程變動並不靈敏。直到 Page [8] 提出累積和管制法 (cumulative sum control chart, CUSUM) 後，管制圖在微量製程變動的偵測能力上才有明顯的提升，但對於大量的製程變動其偵測成效則不如蕭華特管制圖。就使用製程資訊之觀點而言，CUSUM 管制法最大的特點為利用樣本統計量與樣本出現順序的訊息來判定目前的製程狀態。

學理上，其行為則相當於逆向的逐次機率比檢定 (sequential probability ratio test)。由於製造業中循序生產的特性，因此累積和管制法相當適用於生產線上品質管制這一類的問題。但基於逐次機率比檢定本身為適用在簡單假設對抗 (versus) 簡單假設的情況下，在操作上，累積和管制法在使用前必須先設定一些參數，而且這些參數將決定累積和管制法的最佳偵測範圍。為克服此一侷限性，本研究將以類神經網路來選擇合適的參數，以彌補累積和管制法無法同時兼顧微量與大量製程變動的缺點。研究的目標即為：在指定的管制內平均連串長度下，以類神經網路法提供適當之參考值以改善累積和管制法之管制外平均連串長度，進而提升管制圖的整體偵測能力。

## 二、文獻探討

### (一) 累積和管制法

假設製程在管制內服從  $N(\mu_0, \sigma)$ ，管制外服從  $N(\mu_1, \sigma)$  之常態分配 (其中  $\mu_0, \mu_1, \sigma$  為已知) 時，則累積和管制法的操作方式為，記錄樣本大小為  $n$  之第  $i$  組樣本統計量  $S_H(i)$ ， $S_L(i)$ 。

$$\begin{aligned} S_H(i) &= \max\{0.0, z - k + S_H(i-1)\} \\ S_L(i) &= \max\{0.0, -z - k + S_L(i-1)\} \\ S_H(0) &= S_L(0) = 0.0 \end{aligned} \quad (1)$$

其中  $z = \sqrt{n}(\bar{x} - \mu_0)/\sigma$ ，亦即標準化後之數據值。而參數  $k$  稱為參考值 (reference value)， $h$  稱為決策區間值 (decision interval)。當  $\max(S_H, S_L) > h$  時，則判定製程為管制外。

理論上，累積和管制法可用來偵測各種不同程度之製程變化。但一組特定之參數 ( $h, k$ ) 將決定累積和管制法之最佳偵測範圍，而無法兼顧不同程度之變化。在累積和管制法中， $k$  值將決定管制法最有益之偵測範圍，當製程平均值  $\mu_1$  為不可接受之狀態時，取參考值  $k=(\mu_0+\mu_1)/2$  將可獲得最佳偵測效益。亦即，採用較小之  $k$  值可使累積和管制法在偵測製程微量變化上較為靈敏，但對於大量的製程變化的反應則比蕭華特管制法遲鈍。累積和管制法之整體偵測能力是由參數  $h$  和  $k$  決定，此兩項參數必須在使用前先決定。由於製程之變化量無法預知，因此選擇不合適製程狀態之  $k$  值，將會影響累積和管制法之效益。

在傳統蕭華特管制法中，由於對於偵測製程微量變動的能力較差，因此有些學者建議以輔助法則的方式來改善此一缺失。輔助法則的目的在於偵測樣本數據所產生的非隨機性藉以判別製程是否為異常，雖然輔助法則可以有有效的改善管制法的偵測能力，但相對的過多的輔助法則將導致型 I 誤差迅速的增加。在 Davis [5] 的研究中可發現經過適當的分數選擇，區間管制法將可有效的代替輔助法則。然而根據 Champ [1] 的研究，其效果無論是加諸於蕭華特管制法或 Run Sum 管制法均不如單獨使用累積和管制法，由此可見累積和管制法的優越性。

### (二) 累積和管制法偵測成效之改善

基於傳統累積和管制法的缺失，過去已有諸多學者提出改善偵測能力的方法，在這些方法中吾人將其分類為統計方法與類神經網路法，並介紹如下。

#### 1. 由統計方法改善

從 Lucas [6] 的研究成果，吾人可以發現，合併使用蕭華特管制法與累積和管制法將可彌補單一累和管制法之不足。雖然這種組合方式相當直觀，但卻可改善製程大量變動的偵測成效。學理上，若將蕭華特管制法視為累積和管制法的一個特例，則合併蕭華特累積和管制法也只是雙重累積和管制法 (同時使用兩組參數的累積和管制法) 的特例。因此

使用者可根據過去製程的偏移狀況，選擇合適的兩組累積和管制法進行製程管制，以增加管制效益，至於雙重累積和管制法的最佳整體偵測效益則可依據 Waldmann [11] 之建議進行參數選擇。

## 2. 由類神經網路方法改善

除了統計方法方面的改善外，Smith [10] 應用類神經網路來偵測製程平均值和變異數之改變，但與 Cheng 和 Tzeng [4] 不同的是其管制對象為樣本組數據。Smith [10] 所採用之製程特徵值，包含一樣本組內之原始數據及樣本平均值、全距、標準差。他並經由數據模式的判別，概略預測未來的製程數據。

Cheng [2, 3] 以製程最近的 16 組樣本做為類神經網路之輸入訊號，並以倒傳遞網路來偵測製程平均值之變化。Cheng 所提出之類神經網路與合併蕭華特累積和管制法具有相似之偵測效益，但在平均值微量變化之偵測成效上，Cheng 之類神經網路管制法則較合併蕭華特累積和管制法約快了 20%。之所以會有這種結果，除了學習策略的貢獻外，與 Smith [10] 之研究方法的重大不同點為，在 Cheng 的類神經網路中同時監視數組樣本組於輸入層，但過去的研究方法一次只監視一組樣本。採用這種輸入方式將可避免類神經網路管制法於樣本大小與訓練時不同所衍生的適用問題。

整體而言，雖然 Cheng [2, 3] 所提之研究架構可改善 Smith [10] 方法於樣本大小不同時之困擾，可增加實務上的應用性，但也面臨一些問題。這些問題分別為，首先，在類神經網路訓練階段，僅以特定參考值下之累積和管制法參數做為訓練樣本之基礎。當參考值改變時網路必須重新學習，使用上較為不便；其次，透過分析視窗的移動來監控最新製程之變化，雖合理可行，但於製程一開始就異常或矯正作業失敗時，網路必須等待分析視窗被填滿後方可進行分析。在此種狀況下，將使類神經網路管制法無法立即反應製程變化。

## 三、問題及模式說明

針對這些缺點，本文之改善方法為整合使用類神經網路與累積和管制法，首先藉由訓練樣本之學習，使類神經網路得以提供目前製程狀態之合適參考值。並藉由此參考值與使用者所希望之管制內平均連串長度來決定決策區間值。接下來，則由傳統之累積和管制法進行製

程監控。由此方式來建構管制方法其優點為：

1. 訓練樣本內已包含各種參考值下之製程狀態，累積和管制法中的參考值可由訓練後之網路來決定，使用者無需設定參考值大小。亦即，網路不需要重新訓練，使用上較為便利。
2. 當製程一開始為異常或矯正作業失敗時，雖然類神經網路無法立即反應，但仍可藉由設定參考值（如  $k=0.25$  或  $k=0.5$ ）的方式，來暫時監控製程。待分析視窗成立時，再由網路提供合適之  $k$  值進行後續監控。

其邏輯概念則如圖 1 與圖 2 所示。

### (一) 類神經網路大小之決定

如圖 2 所示，本文使用之網路大小為  $33 \times 50 \times 2$ ，其中輸入層之處理單元為 32 個原始數據與最後 5 組數據之平均值（共計有  $32+1=33$  個輸入層處理單元）；隱藏層為 50 個處理單元；輸出層則分別為參考值與其相對之平均連串長度。其中隱藏層處理單元數部份係由二分法搜尋後所得之較佳結果，所謂的二分法是以先選定固定之隱藏層處理單元數（本研究選取 10 個處理單元），然後在相同的學習法則與學習參數下，經學習後找出誤差均方和 (root mean square error, RMSE)，接著再增加處理單元數至 20 個，然後比較 RMSE

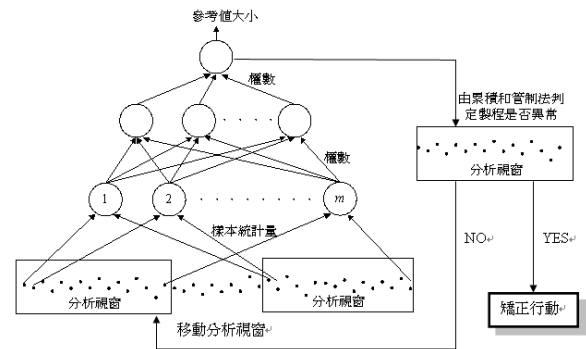


圖 1. 研究方法示意圖




圖 2. 類神經網路架構圖

之結果，若 RMSE (20) 比 RMSE (10) 小 (括號內數字表示隱藏層處理單元數)，則再試著增加隱藏層處理單元數。反之，則減少處理單元數為上次與本次之平均數。直到 RMSE 並無太大變化時則為最終之隱藏層處理單元數。

(二) 建立偵測平均值變化之類神經網路

1. 訓練樣本

由於訓練樣本需要包含不同參考值之數據，因此，本研究乃採用蒙地卡羅 (Monte Carlo) 模擬法來模擬出各種不同平均值偏移量之數據，並以偏移量之一半以作為類神經網路之訓練樣本。在本研究中是以連續 32 組數據及最末連續 5 組數據之平均值作為輸入訊號，而此 33 個輸入訊號構成一個分析視窗。

2. 數據之規格化

在網路訓練過程中，如果某一運算元為一相當大的數值，即使連接權數值相當小，也會造成該網路運算元之誤差調整項接近於零，而致使網路將不再具有學習效果，這種現象稱之為運算元之飽和 (saturation)，因此，為避免此效應之產生，本研究將原始輸入數據加以規格化 (scaling)，並利用線性轉換方式，將各變數之數值轉換至某一固定範圍之內，如此可避免過大之輸入值所造成運算元飽和的問題。

3. 類神經網路之架構

本研究之目的主要為利用類神經網路以決定合適之參考值大小，並進一步估計累積和管制法之靈敏性。本研究採之網路架構為倒傳遞網路，其學習參數設定則如圖 3 所示。

在學習速率的設定方面，我們考慮臨界值以及學習率的影響，僅設學習次數為 600000 次，而將起始學習速率參數

固定為 0.3，並隨學習次數之增加而降低。詳細之設定為起始之學習速率為 0.3，轉動慣量 (momentum) 為 0.4，此皆為軟體之預測值。至於速率調整其方式為第 1-10000 次使用起始速率，10001-30000 次使用上次速率之一半 30001-70000 次時為起始速率的 1/4，以此類推。

4. 訓練樣本之產生

本研究之主要目的為發展一個以類神經網路為輔之累積和管制法，以使累積和管制法更能適應目前製程狀態。在不損失一般性之原則下，我們假設數據服從標準常態分配，即  $N(0,1)$ 。本研究考慮的平均值偏移範圍為平均值向上及向下偏移各 4 倍標準差。為了呈現不同程度之參考值，此訓練樣本集共計 7272 筆資料，包含各種參考值大小 ( $|k| \leq 2$ )。亦即，訓練樣本會依偏移量而有不同之偏移前及偏移後之數據個數。假設分析視窗之大小為  $m$ ，其中有  $s$  組為平均值偏移後之數據，另外  $(m-s)$  為未偏移之數據組數。參數  $s$  之大小是根據我們所選定之最佳累積和管制法偵測到某平均值偏移量所需之平均樣本組數，此稱為平均連串長度 (average run length, ARL)。表 1 為管制內 ARL=465 時訓練樣本內的所有參數組合。

5. 輸出層的使用方式

根據類神經網路之輸出值，在參考值的估計中，本研究

表 1. 管制內 ARL=465 時，累積和管制法之可能參數組合

$k$	$h$	$k$	$h$	$k$	$h$
---	---	1.05	2.500	2.05	1.034
0.10	14.479	1.10	2.382	2.10	0.981
0.15	11.650	1.15	2.272	2.15	0.929
0.20	9.778	1.20	2.171	2.20	0.877
0.25	8.442	1.25	2.077	2.25	0.825
0.30	7.431	1.30	1.989	2.30	0.774
0.35	6.634	1.35	1.906	2.35	0.723
0.40	5.987	1.40	1.828	2.40	0.672
0.45	5.451	1.45	1.754	2.45	0.621
0.50	4.999	1.50	1.683	2.50	0.570
0.55	4.612	1.55	1.615	2.55	0.520
0.60	4.276	1.60	1.550	2.60	0.470
0.65	3.982	1.65	1.487	2.65	0.419
0.70	3.722	1.70	1.426	2.70	0.369
0.75	3.490	1.75	1.367	2.75	0.319
0.80	3.282	1.80	1.309	2.80	0.269
0.85	3.095	1.85	1.252	2.85	0.219
0.90	2.925	1.90	1.197	2.90	0.169
0.95	2.770	1.95	1.142	2.95	0.119
1.00	2.629	2.00	1.088	3.00	0.069

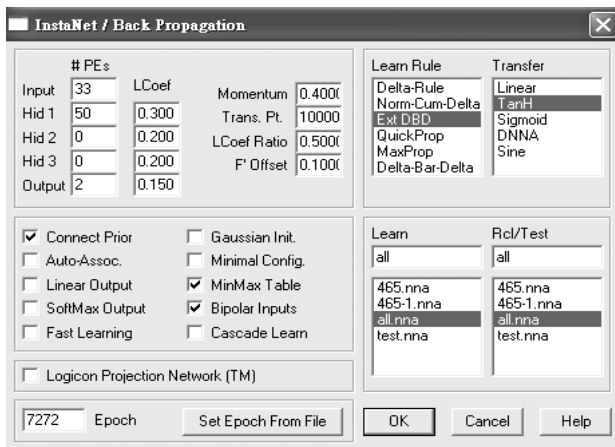


圖 3. 類神經網路之學習參數設定

提供兩種選擇方式如下：方式 1：以類神經網路之估計結果為主，使用每次分析視窗所得之輸出值。方式 2：使用前次分析視窗所得之估計值與本次視窗所得之估計值之平均。

其中使用方式 1 來設定參考值實為本研究之基礎思考方式，但鑑於前次分析視窗所得之估計結果對於目前製程狀態之資訊亦有其參考價值，因此吾人將考慮分別以方式 1 與方式 2 來設定累積和管制法之參考值，並討論其在偵測成效上之差異。

#### 四、管制效益評估

##### (一) 評估方法

為了符合實際之製程情況，本研究在評估類神經網路之偵測效益時，假設一開始有  $m$  組（此  $m$  值等於視窗之大小）正常之數據，隨後再將異常之數據逐點納入分析。對於類神經網路偵測製程平均值偏移之效益，本研究是利用平均連串長度 (ARL) 來做為評估的指標。對於平均值偏移量之估計，指標定義如下：

$$\rho = \frac{ARL_{NC}}{ARL_C} \quad (2)$$

其中， $ARL_{NC}$  為本研究方法之平均連串長度，而  $ARL_C$  則為傳統累積和管制法之平均連串長度，當  $\rho$  愈小時則表示本研究方法愈佳。

##### (二) 測效益之評估結果

當數據服從常態分配時，傳統管制圖對於平均值向上及向下偏移，具有相同之偵測能力。本研究所發展之類神經網路也具有相同之特性。因此，在以下之討論中，我們僅列出平均值向上偏移之結果。

根據模擬結果，吾人發現若直接使用類神經網路每次所回報之決策區間值“ $h$ ”通常太小（低估），而導致本研究所提之管制方法過於敏感，這顯示本法並無法滿足預設管制內平均連串長度之需求。為求與傳統累積和管制法在偵測成效上比較的公平性，吾人將同步調整每次類神經網路所輸出之決策區間值，如表 2 所示。由表 2 之結果可得，無論使用方式 1 或方式 2，本研究方法之管制能力均優於傳統累積和管制法。其中，當製程產生微量變動時本研究方法所提升之成效相當有限，但隨製程偏移量增加時，則本研究方法愈顯得有效。其可能原因為，當比較對象為傳統累積和管制法於  $k=0.5$  時之偵測能力時，累積和管制法在製程微量變動方面

表 2. 管制法之 ARL 比較

Mean shifts	CUSUM $k=0.5, h=5.0$	方法 1		方法 2	
		$h_1=h/0.865^1$	$\rho$	$h_2=h/0.985^1$	$\rho$
0.00	465.400	465.400	---	473.800	---
0.25	139.500	128.100	0.918	109.800	0.787
0.50	37.400	35.230	0.942	30.710	0.821
0.75	17.050	16.880	0.990	14.720	0.863
1.00	10.380	10.570	1.018	9.180	0.884
1.25	7.393	7.385	0.999	6.505	0.880
1.50	5.747	5.517	0.960	4.899	0.852
1.75	4.714	4.315	0.915	3.971	0.842
2.00	4.009	3.528	0.880	3.279	0.818
2.25	3.499	2.973	0.850	2.833	0.810
2.50	3.114	2.526	0.811	2.480	0.796
2.75	2.813	2.229	0.792	2.236	0.795
3.00	2.537	1.998	0.788	2.029	0.800
3.25	2.381	1.808	0.759	1.879	0.789
3.50	2.227	1.664	0.747	1.746	0.784
3.75	2.107	1.539	0.730	1.646	0.781
4.00	2.013	1.423	0.707	1.539	0.765
$\rho$ 值		$\bar{\rho} = 0.863$		$\bar{\rho} = 0.817$	

註：<sup>1</sup>修正後的決策區間值

已經擁有相當靈敏之偵測能力，因此改善有限。但相較於製程大量變動時， $k=0.5$  之傳統方法已不敷使用，而本研究方法適可彌補此一缺點。

在整體偵測成效方面，由表 2 中可看出，本研究方法於製程產生大量變動時製程偵測能力可顯著提升。另外，當使用方式 2 時，整體管制效益約可提升 20%，這與 Cheng [3] 所得之研究成果相當，但本研究可同時提供製程偏移量之資訊，以提供製程矯正者之參考依據。

#### 五、結果與討論

本文所提供之累積和管制法改善方案，修正了傳統累積和管制法需固定某特定參考值之缺點，並可擴大累積和管制法之有效偵測範圍。在類神經網路的應用方面，本研究與以往學者著墨之最大不同點為，現有文獻中大多以發展類神經網路管制法來與累積和管制法相抗衡，而本研究則視類神經網路為輔助性工具，並藉由其網路運算求得適當之參考值後再交由累積和管制法來進行製程判斷。由於本研究之管制方法在以連串長度為基礎的比較上有良好的表現，因此也相當適合累積和管制法之替代方案。這免除了當製程平均數之偏移未知時使用累積和管制圖的困擾，同時也避免了在 Cheng [2, 3] 的研究中只適合特定參考值的侷限性。

另外，在研究過程中吾人也發現，當製程一開始便處於異常狀態或修正動作並無法有效消除製程偏移時，單獨使用類神經網路管制法將因等待製程資料進入類神經網路之處理單元而有延滯狀況。但此種情況可藉由停止類神經網路之運作，單純由具有快速起始回應，Lucas [7] 之累積和管制法來改善。在未來研究中，我們將嘗試把加指數加權移動平均管制法納入本研究之模式，以期提升指數加權移動平均管制法的製程偵測能力。

### 參考文獻

1. Champ, C. A. and W. H. Woodall (1987) Exact results for Shewhart control charts with supplementary runs rules. *Technometrics*, 29(4), 393-399.
2. Cheng, C. S. (1994) Detecting changes in the process mean using artificial neural networks approach. *Journal of the Chinese Institute of Industrial Engineers*, 11(1), 47-54.
3. Cheng, C. S. (1995) A multi-layer neural network model for detecting changes in the process mean. *Computers & Industrial Engineering*, 28(1), 51-61.
4. Cheng, C. S. and C. A. Tzeng (1994) A neural network approach for detecting shifts in the process mean and variability. *Journal of the Chinese Institute of Industrial Engineers*, 11(2), 67-76.
5. Davis, R. B. and A. Homer (1990) Performance of the zone control chart. *Communications in Statistics-Theory and Methods*, 19(5), 1581-1587.
6. Lucas, J. M. (1982) Combined Shewhart-CUSUM quality control schemes. *Journal of Quality Technology*, 14(2), 51-59.
7. Lucas, J. M. and R. B. Crosier (1982) Fast initial response for CUSUM quality control schemes: Give your CUSUM a head start. *Technometrics*, 24(3), 199-205.
8. Page, E. S. (1954) Continuous inspection schemes. *Biometrika*, 41(1), 100-115.
9. Shewhart, W. A. (1931) *Economic Control of Quality of Manufactured Product*, D. Van Nostrand, New York, NY.
10. Smith, A. E. (1994) X-bar and R control chart interpretation using neural computing. *International Journal of Production Research*, 32(2), 309-320.
11. Waldmann, K. H. (1996) Design of double CUSUM quality control schemes. *European Journal of Operational Research*, 95(3), 641-648.

收件：95.03.13 修正：95.03.28 接受：95.05.05