

結合製程統計特徵值與類神經網路於管制圖異常形狀之辨識

¹顧瑞祥 ²施炳光

¹國立虎尾科技大學工業工程與管理研究所副教授

²國立虎尾科技大學工業工程與管理研究所研究生

(632 雲林縣虎尾鎮文化路 64 號)

²ddt10002000@yahoo.com.tw

摘要

管制圖圖形可以用來決定系統的狀態。它們可以用來偵測製程中隨時可能發生的異常情況，因此顯的極為重要。異常的管制圖形狀與製程變異中一些特殊的非機遇性原因有關聯，因此有效地辨識管制圖形狀能減少可能需要的檢查次數，並加速診斷搜尋。近年來類神經網路已經成功地用在管制圖形狀辨識上，但大多數的研究均以原始資料作為類神經網路輸入向量；部分研究則是利用由原始資料，計算出其統計特徵當作輸入向量供類神經網路訓練用。在本文中，我們提供一個改進方法，其同時利用原始資料與擷取出的製程統計特徵值當作輸入向量，再利用類神經網路來偵測與區別異常的管制圖形狀。實驗結果顯示其績效較先前的研究來的要好。

關鍵字：統計特徵值、管制圖、圖形辨識、類神經網路、倒傳遞神經網路、統計製程管制。

1. 緒論

管制圖(Control Chart)早在1930年代即由W. A. Shewhart創造出來，歷經七十多年的應用，管制圖至今仍是產品品質改善最常使用的工具之一。而所謂的品質改善，其實就是降低產品與製程的變異。從統計的角度來看，製程的變異情形以統計方式描述或許較為合適，故降低變異可運用統計方法。這種將統計方法運用在品質改善上以降低產品與製程變異的作法，統稱為統計品質管制(Statistical Quality Control)。而統計製程管制(Statistical Process Control)是以統計手法針對製程進行監控、分析與異常情況之改善，其適用於統計品質管制導入的中期且為全面品質管理(TQM)最有效的方法之一。管制圖與一般統計圖不同，因其不僅能將數據以曲線表示出來，以觀察變異的趨勢，且能顯示變異是屬於機遇性原因(Chance cause)或者是非機遇性原因(Assignable cause)，以判斷製程是否處於異常狀態，藉此幫助管理者採取適當的補救措施。所謂非機遇性原因，就是引起產品品質大變動之原因，又稱為可避免之原因、人為原因、特殊原因等，例如由機器之不同、材料相異、操作疏忽、量具不準確所造成；機遇原因又稱不可避免之原因、非人為原因、共

同原因、偶然原因等等，例如原料之微小變異、機械之微小振動、儀器測定時不十分精確之作法[1]。然而這兩種原因在日常工作中並不容易分辨，而利用管制圖可以有效地用來區分此兩種原因。利用管制圖方法來辨別機遇性與非機遇性原因較利用經驗法則來的客觀，也較不容易犯下嚴重之錯誤，故我們利用管制圖來了解製程是否處在管制狀態(in-control)。

近年來，許多學者發展出不同型式的類神經網路已成功地運用在許多相關領域中。目前於統計製程管制中領域中，類神經網路可應用於分析與偵測製程數據中的平均值變化、製程變異性變化、製程相關參數之變化量與管制圖形分類等相關研究。但大多數的研究均以原始資料作為輸入向量供神經網路訓練用；而部分研究則利用計算相關的統計特徵值當作輸入向量用供類神經網路訓練。在本文中，我們提供一個改進方法，其同時結合原始製程數據與擷取出的統計特徵值來當作輸入向量，再利用倒傳遞類神經網路來偵測與區別異常的管制圖形狀。實驗結果顯示，其績效較先前的研究來的要好。

2. 文獻探討

製程不在管制中的情形為當製程數據落於管制界線外或是管制圖形呈現異常的形狀[14]。前者的情形可以很容易地被偵測出來，而後者的情形則較難有效精確地偵測出來，因為製程中的機遇原因會扭曲真實的製程資料。統計品質管制手冊(Statistical Quality Control Handbook)[22]中提到除了製程中非隨機的辨識，若對於製程能擁有適當的認知與經驗，則可得知異常的管制圖與特定的非機遇性原因是有某種程度的關聯。因此於統計製程管制中，利用管制圖形狀辨識來找出潛藏的非機遇性原因可以說是一項非常重要的工作。圖1為一些典型的異常管制圖形狀。




圖 1. 典型的異常管制圖形狀

近年來，類神經網路大量地被運用在各個領域中，其具備學習能力、自我組

織能力且能有效地運用在管制圖形狀辨識與分類[11]。在辨識問題上，類神經網路可以從雜訊高或不完整的資料中回想出已經學習過的訓練資料。這項能力使得類神經網路非常適合用在管制圖形狀辨識，因為在製程中異常的管制圖形狀通常也會受到自然變異的影響，使工業與製造業領域中管制圖形狀辨識的工作更加困難。相關研究應用的結果均顯示，類神經網路不論在準確率或學習速度上均勝過傳統的統計製程管制辨識方法。Pugh [15][16]以蕭華特管制圖與倒傳遞神經網路模型來比較偵測製程中的平均跳動。Guh及Tannock[6]研究結果顯示類神經網路可以辨識出至少兩種的混合管制圖圖形，並利用階段式分析來辨識其平均值、趨勢、週期，並估計其參數值，以提升辨識績效。Chiu及Chen及Lee[4]利用倒傳遞神經網路偵測制程參數值的跳動根據不同自相關係數的時間數列模型，其結果顯示類神經網路可以成功地分出一到三個標準差。相較之下，針對相同過程傳統方法則無法辨識出來。Guh[7]研究結果顯示以類神經網路作為管制圖形的辨識器，對於製程中雜訊的容忍與績效表現均相當優異。Guh[8]更實際應用以類神經網路為管制圖形狀辨識的方法運用在生產實務上。此外，自然製程變異會導致跳動圖形與趨勢圖形相類似。事實上，在管制圖形產生的初期，潛在的隨機製程變異會致使跳動圖形、趨勢圖形、週期圖形、系統性圖形產生非常相似的形狀特徵，因此錯誤的分類將導致大量時間與成本於尋找非機遇性原因上。

大型類神經網路結構是由大量的原始資料所產生，其對於辨識複雜的問題相當沒效率但準確率較高；小型類神經網路結構是由少量的原始資料所產生，其能縮短學習所需要的時間，但相對上準確率較低，較不能完整地呈現原始資料。為了克服大型類神經網路的先天限制，可利用資料中的一些特徵來代表原始資料以減少輸入資料量，相關的應用例如Hassan[10]應用於SPC管制圖形辨識上、Zeki及Zakaria[24]應用於手寫辨識上、Utku[21]應用於穀類特徵與分級等。Pandya及Macy[17]指出從原始資料中萃取出特徵的動機是為了減少資料維度，即是大量地減少輸入向量的數目，其研究顯示出較小的類神經網路結構配合以特徵為基礎的管制圖形分類器其績效比較以原始資料為基礎的類神經網路來的要好。有少數的研究利用統計管制圖形訊號中的特徵當作輸入向量供類神經網路使用。Pham及Wani[18]介紹九種幾何特徵為基礎的管制圖形狀辨識，分別為斜率、平均線交叉數、最小均方線交叉數、週期關係、線段平均斜率、斜率差及三種區域性測量。這些方法的目的主要在於藉由特徵的使用來縮小輸入資料的維度。Tontini[20]利用模糊輻射半徑基底函數網路(Fuzzy RBF network)發展出線上即時的統計製程管制圖形分類器。其輸入向量包含60個原始觀測值、平均數、15個統計視窗的標準差、與長度為10的自相關數據、累和管制圖計算結果與卡方統計量，上述的輸入數據會產生很大的輸入向量且實驗結果也沒有與原始數據當作輸入向量的模型做比較，其研究僅在於強調所發展出的線上即時學習模型。Pham及Wani[18]與Tontini [19]並沒有介紹出使用原始資料與特徵資料來當作輸入向量的優點。

Lavangnananda及Nakkathon[12]從原始資料萃取六個統計特徵值當作輸入向量供類神經網路使用，其辨識準確率為85.78%。此外Lavangnananda及Piyatumrong[13]更利用六個統計特徵值結合移動平均法與二階段時間數列轉換法所擷取的資料當作輸入向量供類神經網路使用，辨識準確率向上提升為90.47%，作者於文中並未結合原始資料與特徵資料當作輸入向量來做比較。因此本篇的研究主要是彌補上述的缺點，利用結合統計特徵與原始資料當作類神經網路輸入向量，並比較結合前後與單獨使用統計特徵值的管制圖形狀分類辨識率。在本文中，我們提供一個改進式的合成訓練資料，其結合了連續製程數據值與統計特徵值，再利用類神經網路來訓練並測試以偵測與區別出異常的管制圖形狀。這些有用的統計特徵值分別為平均值、標準差、偏態係數、峰態係數、斜率與皮爾森相關係數。實驗結果顯示結合了製程數據與統計特徵可提升異常的管制圖形狀辨識準確率。

3. 研究流程與方法

3.1 研究架構

在本文中使用蒙地卡羅模擬法來產生所需要的訓練與測試管制圖形狀範例，其原因有三：第一，因為訓練與測試需要大量的管制圖形狀範例；第二，可以產生出具有各種辨識困難度的管制圖形狀；第三，其他的研究者容易複製所模擬的管制圖形狀。本研究所使用的管制圖形狀範例產生方式可參考文獻[5-9]。所有產生的管制圖形狀均由 C 語言程式建構，類神經網路的建構軟體為 NeuroWorks Professional II Plus。測試用的電腦硬體為 Intel P4 3.0G 512Ram。圖 2 為管制圖形狀辨識的流程圖。




圖 2. 管制圖形狀辨識的流程圖

3.2 類神經網路

葉怡成[2]提出一個對於類神經網路較為完整的定義：「類神經網路是一種計算系統，包含軟體與硬體，並使用大量簡單的相連人工神經元(Neuron)來模仿生物神經網路的能力。人工神經元是生物神經元的簡單模擬，他從外界環境或者其他人工神經元取得資訊，並加以非常簡單的運算，再輸出其結果到外界環境或者其他人工神經元。」其中以倒傳遞類神經網路(Back-Propagation Network, BPN)應用最為普遍。倒傳遞類神經網路模式是目前類神經網路學習模式中最具代表且應用最為普遍的模式之一，其主要的功能為分類與預測。此外倒傳遞類神經網路的學習速度較其他模式慢，但其學習的精確度較高且對於雜訊的容忍度優於其他網路，其基本原理為利用最陡坡降法(The Gradient Steepest Descent Method)的觀念，將誤差函數予以最小化。屬於監督式學習網路，因而適合於診斷、預測等應用。

在處理具有相關性的製程資料時，許多研究亦嘗試應用類神經網路於製程管制上，其中最廣泛被使用的就是倒傳遞類神經網路[23]。倒傳遞網路之基本架構主要包含輸入層(input layer)、輸出層(output layer)及隱藏層(hidden layer)。圖3為本研究所使用的網路架構，其中輸入層是用來接受外界之輸入訊號，其運算元個數是依照問題特性而決定；二層隱藏層，介於輸入層及輸出層之間，是用來接受前一層運算後的輸出值作為輸入訊號，經過運算後輸出訊號給下一層。在這些層與層之間主要是以連接鍵相互連接，作為網路訊號的傳遞路徑，以權數(weight)的方式來表示，又稱為連接強度(connection strength)，經加權累加後再透過活化函數轉換得到一輸出值，再傳入輸出層。輸出層是表示網路的輸出變數，將經過此網路運算之結果輸出到外界，運算元個數亦是依照問題所需而定[3]。圖3為本研究中所使用的圖形辨識網路架構。




圖 3. 本研究中所使用的形狀辨識網路架構

本研究所使用的網路模型為一個四層的倒傳遞類神經網路，其輸入層為6、24、30個神經元當作輸入向量，其中24個神經元即為管制圖中24個連續的模擬數據值。輸出層包含7個神經元，其輸出值介於[0, 1]，每一個分別代表一種管制圖圖形種類，1代表完全屬於某分類，而0代表完全不屬於某分類。隱藏層1與隱藏層2各擁有18個神經元。根據先前的研究顯示若增加隱藏層神經元數目會提升準確率[9]。在本研究中隱藏層神經元數目，根據多次實驗之結果發現，當隱藏層神經元數目超過18個時準確率會停止上升，若再增加反而會提高網路複雜度與運算所需的時間，故採用18個神經元。此外對於類神經網路應用於統計製程管制另一個須仔細考量的因素為視窗大小，即輸入層之個數。本研究以24個連續製程數據值所構成的輸入訊號作為一個分析視窗(analysis window)。一般而言，小的分析視窗通常用來作快速偵測異常圖形，並產生較短的管制內平均串聯長度(in-control ARL)，並導致較高的型I誤差；然而大的分析視窗於偵測管制圖時會隨著時間長度的增加而降低辨識率，並產生較高的型II誤差或較長的管制外平均串聯長度(out-of-control ARL)。本研究中採用一個分析視窗大小為24的視窗長度來辨識圖形。根據實驗顯示，此規格之視窗可以較有效地平衡型I誤差與型II誤差。至於結合式的訓練範例則為24個原始製程數據加上六個擷取出的統計特徵值，所以本文所要實驗用的主要訓練與測試範例的輸入向量為30個神經元。實驗對照組則為6個統計特徵值與24個原始資料分別供實驗進行比較。

3.3 模型參數設定

有效的網路學習決定於是否有足夠的訓練範例供類神經網路訓練使用。本文一共使用5930筆訓練範例，其中包含800筆正常圖形、810筆向上跳動圖形、810筆向下跳動圖形、810筆向上趨勢圖形、810筆向下趨勢圖形、1080筆週期圖形、810筆系統圖形。表1為管制圖形狀訓練集的參數範圍，設定可參考文獻[6-8]。

表 1. 管制圖形狀訓練範例集的參數設定

圖形種類	參數	參數範圍	數量
		下界，上界，間隔	
正常			800
向上跳動	製程平均值	$(1.0, 3.0, 0.25)\sigma$	810
向下跳動	製程平均值	$(-3.0, -1.0, 0.25)\sigma$	810
向上趨勢	斜率	$(0.1, 0.26, 0.02)\sigma$	810
向下趨勢	斜率	$(-0.26, -0.1, 0.02)\sigma$	810
週期	振幅大小	$(1.0, 3.0, 0.25)\sigma$	1080
系統	製程波動大小	$(1.0, 3.0, 0.25)\sigma$	810

這些管制圖形狀的參數設定可以確保大部分的模擬管制圖形狀落在 $\pm 3\sigma$ 之間。而最重要的目的為使異常圖形的資料點不會超出蕭華特管制界線。本研究網

路初始連結權重隨機設定於 $[-0.01, +0.01]$ ，學習速率(learning rate)為0.5，慣性因子(momentum factor)為0.4。連結權重的更新利用Delta-rule法則，而收斂條件為分類率超過0.95[24]。介於隱藏層與輸出層的轉換函數為採用雙彎曲函數(sigmoid function)：

$$f(X) = \frac{1}{1 + e^{-x}} \quad (1)$$

3.4 統計特徵

本文中，原始的訓練資料即為製程數據的實際值，也就是一連串標記在管制圖內的時間數列值，而統計特徵值則是從這些原始資料中利用統計方法計算出。我們從原始製程數據中擷取一些較合適的統計特徵值作為視窗處理使用，這些所選取的特徵必須要容易計算，且對於變化不敏感並容易達到令人滿意的績效。一般最常見的特徵值其統計公式如下所示，分別為平均值(Average)、標準差(Standard deviation)、偏態係數(Skewness)、峰態係數(Kurtosis)、斜率(Slope)、皮爾森相關係數(Pearson's Product-Moment Correlation Coefficient)，其中 n 為 24，代表 24 個連續點製程數據資料，即分析視窗(analysis window)大小； X 代表製程時間點； Y 代表製程數據值； μ 代表製程平均值； σ 代表製程標準差：

$$\text{(平均值)} \quad \mu = \frac{\sum_{t=1}^n y(t)}{n} \quad (2)$$

$$\text{(標準差)} \quad \sigma = \sqrt{\frac{\sum_{t=1}^n (y(t) - \mu)^2}{n}} \quad (3)$$

$$\text{(偏態係數)} \quad SKEW = \frac{\sum_{t=1}^n (y(t) - \mu)^3}{n\sigma^3} \quad (4)$$

$$\text{(峰態係數)} \quad KURT = \frac{\sum_{t=1}^n (y(t) - \mu)^4}{n\sigma^4} - 3 \quad (5)$$

$$\text{(斜率)} \quad Slope = \frac{\sum XY}{\sum X^2} \quad (6)$$

$$\text{(皮爾森相關係數)} \quad Pearson = \frac{n(\sum XY) - (\sum X)(\sum Y)}{\sqrt{(n\sum X^2 - (\sum X)^2)(n\sum Y^2 - (\sum Y)^2)}} \quad (7)$$

平均數為集中趨勢的一種測度。標準差為一種離散程度的指標。平均值與標準差可以用來偵測出正常圖形與週期性圖形之間的變化。偏態係數為測量一組資料對稱與否(偏斜程度與方向)的指標，可用來偵測管制圖形是處於漸增或是漸減趨勢；而峰態係數則為測量機率密度函數上鋒的尖銳程度，能偵測出管制圖形是處於漸增趨勢或向上跳動與漸減趨勢或向下跳動之間的差異。當斜率很小或者是雜訊值太高時，漸增趨勢與漸減趨勢之間的差異變得很小導致偵測困難。因此在本文中，我們使用斜率與皮爾森相關係數來減低上述的缺點並提升辨識率。這兩個統計值能有效地偵測出管制圖形是處於漸增趨勢、或漸減趨勢，還是正常趨勢狀態。

4. 實驗結果

在本研究的實驗中，我們針對不同的標準差大小來對不同輸入向量的倒傳類遞類神經網路做準確率比較。RB(Raw data based)代表只用模擬管制圖形狀的 24 個連續製程數據值；FB(Feature data based)代表只用擷取出模擬管制圖形數據值的 6 個統計特徵值；HB(Hybrid data based)代表使用結合 RB 與 FB 兩者作為輸入向量。研究中，我們利用標準差代替系統或生產線上的雜訊值，標準差越大代表製程受干擾的程度越大，而研究中的標準差介於[0,1]。表 2 顯示分別對不同標準差 0.5 到 1.0 間所作的準確率實驗結果。類神經網路訓練循環次數(Epochs)設定為 10 次，而實驗對模擬所產生訓練範例 5930 筆重覆進行 59300 次學習，即十次完整的訓練。測試所得出來的平均準確率為不同的標準差下各五次測試的平均值。表 2、表 3、表 4 分別為 RB、FB、HB 三者在不同標準差之間的準確率。由表 2 與表 4 可以得到下列的推論，在未加入統計特徵值之前，RB 正常圖形辨識準確率均小於 FB，在加入統計特徵值之後，HB 正常圖形辨識準確率在不同標準差之下均大於 FB，表示加入此六種統計特徵值是有效的。若從製程角度來分析，研究結果發現此六種統計特徵值的加入可以減少製程一開始所產生的型 I 誤差，節省了可能產生的時間與成本。表 3 中 FB 週期的辨識準確率明顯小於 RB 與 HB，此原因可能為統計特徵值並無法完整表現出全部 24 個連續製程輸入值，由此可知僅用統計特徵值當作輸入向量其準確率略小於 RB。然而，若僅使用統計特徵值在不會影響準確率太大情形下，對於大型的輸入向量反而可以大幅減少所需的運算時間。

表 2. RB 準確率 vs. 製程資料標準差

管制圖樣式	辨識率	管制圖樣式	辨識率	管制圖樣式	辨識率	管制圖樣式	辨識率	管制圖樣式	辨識率	管制圖樣式	辨識率
標準差	0.5	標準差	0.6	標準差	0.7	標準差	0.8	標準差	0.9	標準差	1
正常	0.9863	正常	0.9757	正常	0.9687	正常	0.9401	正常	0.9325	正常	0.9262
向上跳動	0.9838	向上跳動	0.9784	向上跳動	0.9630	向上跳動	0.9444	向上跳動	0.9494	向上跳動	0.9296
向下跳動	0.9809	向下跳動	0.9753	向下跳動	0.9728	向下跳動	0.9469	向下跳動	0.9605	向下跳動	0.9358
向上趨勢	0.9825	向上趨勢	0.9789	向上趨勢	0.9667	向上趨勢	0.9628	向上趨勢	0.9556	向上趨勢	0.9395
向下趨勢	0.9836	向下趨勢	0.9803	向下趨勢	0.9779	向下趨勢	0.9697	向下趨勢	0.9433	向下趨勢	0.9309
週期	0.9838	週期	0.9782	週期	0.9729	週期	0.9689	週期	0.9646	週期	0.9601
系統	1.0000	系統	0.9933	系統	0.9849	系統	0.9788	系統	0.9721	系統	0.9663

表 3. FB 準確率 vs. 製程資料標準差

管制圖樣式	辨識率	管制圖樣式	辨識率	管制圖樣式	辨識率	管制圖樣式	辨識率	管制圖樣式	辨識率	管制圖樣式	辨識率
標準差	0.5	標準差	0.6	標準差	0.7	標準差	0.8	標準差	0.9	標準差	1
正常	0.9968	正常	0.9863	正常	0.9805	正常	0.9723	正常	0.9631	正常	0.9547
向上跳動	0.9819	向上跳動	0.9748	向上跳動	0.9648	向上跳動	0.9421	向上跳動	0.9338	向上跳動	0.9111
向下跳動	0.9820	向下跳動	0.9731	向下跳動	0.9618	向下跳動	0.9424	向下跳動	0.9359	向下跳動	0.9150
向上趨勢	0.9877	向上趨勢	0.9864	向上趨勢	0.9790	向上趨勢	0.9630	向上趨勢	0.9444	向上趨勢	0.9469
向下趨勢	0.9775	向下趨勢	0.9864	向下趨勢	0.9802	向下趨勢	0.9630	向下趨勢	0.9420	向下趨勢	0.9444
週期	0.9234	週期	0.9130	週期	0.8887	週期	0.8615	週期	0.8487	週期	0.8289
系統	1.0000	系統	0.9908	系統	0.9838	系統	0.9798	系統	0.9691	系統	0.9611

表 4. HB 準確率 vs. 製程資料標準差

管制圖樣式	辨識率	管制圖樣式	辨識率	管制圖樣式	辨識率	管制圖樣式	辨識率	管制圖樣式	辨識率	管制圖樣式	辨識率
標準差	0.5	標準差	0.6	標準差	0.7	標準差	0.8	標準差	0.9	標準差	1
正常	1.0000	正常	0.9963	正常	0.9883	正常	0.9789	正常	0.9727	正常	0.9685
向上跳動	0.9905	向上跳動	0.9877	向上跳動	0.9813	向上跳動	0.9779	向上跳動	0.9699	向上跳動	0.9641
向下跳動	0.9922	向下跳動	0.9852	向下跳動	0.9812	向下跳動	0.9776	向下跳動	0.9686	向下跳動	0.9632
向上趨勢	0.9946	向上趨勢	0.9885	向上趨勢	0.9816	向上趨勢	0.9755	向上趨勢	0.9669	向上趨勢	0.9633
向下趨勢	0.9951	向下趨勢	0.9918	向下趨勢	0.9877	向下趨勢	0.9790	向下趨勢	0.9732	向下趨勢	0.9687
週期	0.9835	週期	0.9752	週期	0.9724	週期	0.9688	週期	0.9625	週期	0.9567
系統	1.0000	系統	0.9975	系統	0.9963	系統	0.9938	系統	0.9889	系統	0.9844




圖 4. 不同標準差 vs. 三種測試資料平均辨識準確率

此外，表 3 表 4 可看出 HB 的系統準確率在 RB 結合 FB 當作輸入向量之後，能使系統準確率再向上提升一些，此代表加入 FB 對於 HB 系統辨識準確率的提升略有幫助。在表 4 中，可以發現結合原始數據與統計特徵值當做輸入向量供類神經網路訓練與測試所得出的各種異常管制圖形狀辨識準確率均較單獨測試時來的高。由圖 4 可明顯看出三種測試資料的辨識準確率均會隨著標準差越來越大而逐漸下降。就 6 種標準差下平均辨識準確率而言，RB 為 96.54%，FB 為 95.29%，而 HB 為 98.07%，即加入統計特徵值可使平均辨識準確率由 96.54% 提升至 98.07%，增加了 1.53%。

5. 結論

在本文中我們提出一個結合原始資料與統計特徵的辦法，其實驗結果顯示準

確率均高於單獨使用原始資料或統計特徵。根據本研究的實驗架構與程式設計，採用分析視窗大小為 24(lags)的長度。而越長的時間數列數據當作輸入向量訓練，相對來說需越長時間的計算，在基於研究架構考量下，本研究並未對數列長度作分析。實驗結果顯示，在加入統計特徵值後，除了可提升各種異常管制圖形狀辨識率外還可減少製程一開始所產生的型 I 誤差，其績效顯示本研究所使用的方法較先前的研究[12][13]要來的好，此方法可使整體準確率由 96.54%(RB)提升到 98.07%(HB)。

6. 未來研究方向

未來研究工作可朝下列幾個方向繼續努力：

1. 本文中的實驗僅限於靜態測試，未來將對所提出的模式做動態測試，且於前後端的處理可加入模糊理論(Fuzzy)，並應用於即時線上偵測系統。
2. 本研究僅討論六種不正常的管制圖圖形，未來可再增加其他種圖形，例如混合圖形(mixtures)、階層圖形(stratification)等等。
3. 雖然倒傳遞神經網路對於管制圖圖形具有良好的辨識效果，但其缺乏記憶性，未來可利用多層感知機(MLP)中的 Time-lag 網路，其具有短期記憶結構或者是利用自適應共振理論網路(Adaptive resonance theory network)來改善這個缺點，使其更適用於多變的環境。

參考文獻

1. 房克成、林清風，管制圖與製程管制，中華民國品質學會，台北 (2004)。
2. 葉怡誠，類神經網路模式應用與實作，儒林圖書有限公司，台北 (2003)。
3. 張斐章、張麗秋、黃浩倫，類神經網路理論與實務，東華書局，台北 (2003)。
4. Chiu, C. C., Chen, M. K., & Lee, K. M., "Shifts recognition in correlated process data using a neural network," International Journal of Systems Science, 32, 137-143 (2001).
5. Guh, R. S., F. Zorriassatine, J.D.T. Tannock, C.O'Brien., "On-line control chart pattern diction and discrimination—a neural network approach," Artificial Intelligence in Engineering, 13, 413-425 (1999).
6. Guh, R. S. and Tannock, J. D. T., "Recognition of control chart concurrent patterns using a neural network approach," International Journal of Production Research, 37, 1743-1765 (1999).
7. Guh, R. S., "Robustness of the neural network based control chart pattern recognition system to non-normality," International Journal of Quality and Reliability Management, 19, 97-112 (2002).

8. Guh, R. S., "Integrating artificial intelligence into on-line statistical process control," *Quality and Reliability Engineering International*, 19, 1-20 (2003).
9. Guh, R. S., "A hybrid learning-based model for on-line detection and analysis of control chart patterns," *Computer and Industrial Engineering*, 49, 35-62 (2005).
10. Hassan, A., Shariff Nabi Baksh, M., Shaharoun, A. M. and Jamaluddin, M., "Improved SPC chart pattern recognition using statistical features", *International Journal of Production Research*, 41, 1587-1603 (2003).
11. Kohonen, T., *An introduction to neural computing*, Springer, 3-16 (1988).
12. Lavangnananda, K. and Nakkathon, A., "Improving Features Extraction in Control Chart Patterns", *Proceedings of the 7th National Computer Science and Engineering Conference*, 364-369 (2003).
13. Lavangnananda, K. and Piyatumrong, A. "Image processing approach to features extraction in classification of control chart patterns", *Proceedings of the 2005 IEEE Mid-Summer Workshop on Soft Computing in Industrial Applications*, 85 – 90 (2005).
14. Montgomery, D. C., *Introduction to statistical quality control*, John Wiley, New York (2004).
15. Pugh, G. A., "Synthetic neural networks for process control", *Computers and Industrial Engineering*, 17, 24-26 (1989).
16. Pugh, G. A., "A comparison of neural networks to SPC charts", *Computers and Industrial Engineering*, 21, 253-255 (1991).
17. Pandya, A. S. and Macy, R. B., *Pattern Recognition with Neural Network in C++*, CRC, Florida (1996).
18. Pham, D. T. and Wani, M. A., "Feature-based control chart pattern recognition", *International Journal of Production Research*, 35, 1875-1890 (1997).
19. Tontini, G., "Pattern identification in statistical process control using fuzzy neural networks", *Proceedings of the 5th IEEE International Conference on Fuzzy Systems*, 3, 2065-2070 (1996).
20. Tontini, G., "Robust learning and identification of patterns in statistical process control charts using a hybrid RBF fuzzy artificial neural network", *IEEE International Joint Conference on Neural Network Proceedings*, 3, 1694-1699 (1998).
21. Utku, H., "Application of the feature selection method to discriminate digitised wheat varieties", *Journal of Food Engineering*, 46, 211-216 (2000).
22. Western Electric, *Statistical quality control handbook*, Western Electric Company (1958).
23. Zorriassatine, F. & Tannock, J. D. T., "A review of neural networks for statistical

- process control”, Journal of Intelligent Manufacturing, 9, 209–224 (1998).
24. Zeki, A. A. and Zakaria, M. S., “New primitive to reduce the effect of noise for handwritten features extraction”, IEEE Tencon Proceedings: Intelligent Systems and Technologies for the New Millennium, 24–27 (2000).

Improved neural network-based control chart pattern recognition using raw data and statistical data simultaneously

Ruey-Shiang Guh Ping-Kuang Shih*

Institute of Industrial Engineering & Management, National Formosa University
(64 Wen-Hua Rd. Huwei, Yunlin)

*ddt10002000@yahoo.com.tw

Abstract

Control chart patterns (CCPs) can be used to determine the status of system. It is important that CCPs can detect the abnormal status during the process control which may occur. Unnatural control chart patterns are associated with a particular set of assignable causes for process variation. Therefore, effectively recognizing CCPs can substantially reduce the set of possible causes to be examined, and accelerate the diagnostic search. In recent years, neural networks (NNs) have been successfully used to the CCP recognition task. Artificial neural network based SPC chart pattern recognition schemes have been introduced by several researchers. In intelligent SPC, using raw data or statistical feature data extracted from raw data as input vector are regular in the most of previous works. In this paper, we present a neural network-based approach that an improved hybrid training data that integrates both the time series data and the statistical feature data to detect and discriminate typical unnatural CCPs. Our experiments yield better performance than previous works using the proposed new method.

Keywords : statistical features, control charts, patterns recognition, artificial neural network, back propagation neural networks, statistical process control.