

應用影像視覺於超薄型表面載式電感器之瑕疵品辨識

陳昭雄 鄭光宏

大葉大學機械與自動化工程學系
515 彰化縣大村鄉山腳路 112 號

摘要

本文主要發展一影像處理技術包括影像定位、色彩分離、字型辨識及影像歸類等，以應用於超薄型表面載式電感器之瑕疵品線上檢測。瑕疵檢測主要分成兩部分進行，首先利用正交色彩空間轉換技術，以降低光線強度變化對色彩之影響，並歸納出銅色彩像素點空間分佈之區域，以辨識出電感器細小之鐵心破裂、斷線和線圈外露等瑕疵；再者，利用字元切割與細線化技術處理電感器上之型號，再歸納出各型號字元之端點和交叉點特徵，以辨識電感器印字模糊和混料等瑕疵。另外，本文爲了提高型號字元之辨識率，發展一全新自適應性類神經網路系統以當做字型之歸類器，利用幾何慣性法則萃取字型之形狀特徵值，以當做此類神經系統之輸入，克服字型位移、旋轉和縮放等問題，並推導出一非線性最小平方誤差之學習法則，能自動調整隱藏層神經元之個數和所有參數，此學習法則能確保所有系統參數快速收斂，具備高度之字型辨識強健度。最後，將所發展出之影像檢測技術應用於實際之超薄型表面載式電感器生產線，以驗證所提方法之有效性，瑕疵品辨識率可達 98% 以上。

關鍵詞：機械視覺，影像辨識，超薄型表面載式電感器，自適應性類神經網路系統

A Defect-Inspection Technique for a Low-Profile Power Inductor Using Machine Vision

CHAIIO-SHIUNG CHEN and WGOUN-HON ZUWN

*Department of Mechanical and Automation Engineering, Da-Yeh University
112 Shan-Jiau Rd. Da-Tsuen, Changhua, Taiwan*

ABSTRACT

This study develops image-processing techniques including image positioning, color separation, symbol recognition and image classification for on-line inspection of the defects in a power inductor by the use of machine vision. The inspection process is divided into two stages. In the first stage, color separation is applied to the RGB color space of copper. The spread region of normalized copper colors is then incorporated to inspect defects such as broken iron, appearance of coil, etc. In the second stage, the symbols on the inductor are recognized by the use of a node-extraction technique. The extraction features consist of the ends and nodes of a symbol. By using these features to identify the characters on the inductor, the copper-mixing problems can be solved. Moreover, a self-adaptive neural network is developed to improve the symbol recognition.



Geometric moments are employed to extract the symbol features, which are used as the inputs for the neural networks. A recursive nonlinear least-square algorithm is implemented to auto-tune all parameters in the neural network, thereby accelerating the learning convergence and improving the approximation accuracy. Finally, the developed techniques are applied to practical power inductor manufacturing processes to confirm the validity of the proposed method.

Key Words: machine vision, defect recognition, power inductor, self-adaptive neural network system

一、前言

超薄型表面載式電感器 (low-profile SMD power inductor) 為一小型化之被動式電子元件, 主要應用於高科技電器產品之電源整流器 (DC-DC converter), 如通訊類之手機、電腦類之 PC、PDA 和 LCD、視聽機器類之各種 AV 及遊戲機、家用類之數位相機等。在電源變流器中為最重要的元件就是電感器, 台灣的王牌產品 TFT 液晶顯示器每個月至少需用到約 350 萬個此類電感器。由於市面上的電子產品不斷的追求短巧精美、省電和耐用, 使得其相關組件如電源變流器也必須相同的研發小型化、薄型化及降低製作成本, 以配合各個廠商的需求。超薄型表面載式電感器之製造方式為在薄型鐵心上繞上電導線, 製程包括印字、鐵片切割、基座點焊、繞線、個體切割、通電測試及包裝等, 由於追求超薄短小, 其鐵心、導線及基座皆需縮小, 整體外型大小約 5mm*5mm 左右如圖 1 所示, 製程中品質檢驗分兩部分進行, 其中一種為在電感器導線兩端通電, 以檢測電感器之繞線線圈是否斷線, 此檢測是以自動化設備完成, 另一種檢測是以人工應用約 40 倍之顯微鏡檢查表面之瑕疵品, 如鐵心破裂、線圈外露、點焊不良和印字模糊等, 此檢測方式非常浪費時間, 且由於每日生產數量龐大往往無法全檢只能抽檢, 以人工檢驗也容易造成人為疏失, 嚴重影響電感器之品質; 而電感器另有混料之問題, 為了分辨各種不同規格之電感器, 電感器表面皆會印上型號以作區隔, 但由於料筒清除不徹底或工人疏失, 常造成有混料情況發生, 因不同之電感器有不同之繞線圈數和電感值, 如果使用電感值規格不對, 會讓所使用之電子設備燒壞。因此, 研發一套自動化線上之超薄型表面載式電感器檢測系統, 以應用於檢測電感器表面之瑕疵及型號, 以取代人工之檢測是為迫切需要的。

現有影像處理技術應用於 IC 瑕疵品辨識之研究論文非常多, 1997 年 Khunkay 與 Paith [5] 先以 Kohonen 之自組織特徵映射 (self organizing map, SOM) 方法自動萃取影像之模糊特徵值, 然後再以 Fuzzy C-mean 方法尋找這些模糊特



圖 1. 超薄型表面載式電感器

徵值最佳化之歸類法則, 成功完成印刷電路板之不良品檢測。在 [6] 中, Kim 同時利用自適性之學習法則和監督式學習於 LVQ 網路, 解決 IC 導線焊接頭檢測問題, 自適性學習法則先自動選取最佳瑕疵品之歸類神經元數目, 而監督式學習法則再調整其分類邊界。2002 年 Sakurai 等人 [10] 應用影像比對之技術於 IC 之 Hot-Al-Cu 導線層瑕疵品檢測, 透過調整燈光照明強度, 以分離雜訊與不良品影像比對後之灰階分佈, 從不同實驗中找出最佳之門檻值, 但假如雜訊與影像比對之灰階不容易分離, 則辨識率會降低。為了提高辨識率, Kon 與 Cho [7] 結合非監督式 LVQ 類神經網路與模糊邏輯系統應用於 IC 導線焊接頭檢測問題, LVQ 類神經網路先將不良品初步歸類, 再利用模糊邏輯系統, 融入專家辨識經驗, 對類神經網路錯誤之歸類加以更正。在 2003 年, Zervakis, Goumas 與 Rovithakis [14] 利用影像視覺技術以偵測 IC 封裝時, IC 元件焊接在印刷電路板位置偏移之問題, 利用歸類和估測程序預估元件導線之偏移量, 並且利用 Bayesian 網路架構提高估測精度。

超薄型電感器外觀主要為中心之黑色鐵心和週遭之黑色基座, 良品之電感器從外觀看不到大量之黃色銅線圈, 而當鐵心有破裂或繞線外露等瑕疵時, 才可發現較大比率之外露銅線圈, 因此如果以彩色 CCD 攝影機擷取電感器彩色影



像，再以彩色影像辨識技術，以辨識黃色之銅線分佈位置和形狀，可大大提高電感器瑕疵之辨識率。現有之色彩影像辨識技術中，Paschos 與 Valavanis [8] 提出一新的 xyY 色彩空間轉換技術以分離明亮和色彩因子，並以色彩紋路和邊緣偵測而慮除影像之背景。Scharcanski 與 Venetsanopoulos [11] 利用色彩向量空間之統計方法，以偵測彩色影像之多重邊界，藉以得到前景影像之區域，但此法容易受雜訊干擾造成邊界偵測不準。2001 年 Ruzon 與 Tomasi [9] 以彩色影像鄰近點色彩相似度，區隔出彩色影像不同物件間之區域，進而偵測出影像中之邊界和交叉點，但對於色彩較豐富之影像將無法辨識。2004 年 Chen, Zhang 與 Waibel [2] 建立一前景與背景之色彩模型，並透過 HIS 之色彩空間轉換，成功萃取出警告標誌中之符號，再以小波轉換擷取特徵值，達到符號辨識效果，但此方法會因取向角度和方位不同而影響色彩萃取之正確性。Fang, Chen 與 Fuh [3] 利用兩層類神經網路系統萃取出彩色影像中之色彩和形狀特徵，再用模糊邏輯理論成功辨識出交通符號種類，但此方法計算較為繁複。

對於字型字元之辨識一般主要分成文字之特徵值萃取和歸類法則兩步驟，首先針對所要辨識之字元抽取有用之特徵值，再將這些特徵值輸入歸類法則中，以辨識出文字。1993 年 Yuceer 與 Oflazer [13] 利用 T-block、S-black 和 R-block 等三模組於文字之特徵值萃取，使得圖形辨識時不受旋轉、縮放和位移等因素影響，然後利用四層類神經網路系統，經由倒傳遞訓練法則訓練，得到不錯分類效果，但文字同時發生旋轉、縮放和位移等現象時辨識效果較差。1994 年 Chang 與 Lee [1] 將文字轉化為正規化圖形，再與標準圖形比較建立其相對應之歸屬值，利用此歸屬值當作模糊類神經系統之輸入進行訓練和辨識，此方法所花之辨識時間較久。2001 年 Sun [12] 將字元切割成區間方式，再由上而下萃取字元之線段位置、長度和方向，以此當作字元之特徵值，再利用口語化之分類法則辨識字元，此方法對於複雜之字型如中文字有不錯辨識率。

本文之超薄型表面載式電感器瑕疵辨識系統，主要研究主題為發展一影像處理技術包括影像定位、色彩分離、字型辨識和影像歸類等，以辨識電感器之表面瑕疵和型號，檢測電感器之大小約 3-5mm，檢測精度約 0.1mm，檢測速度每秒約 2 個。本文首先利用正交色彩空間轉換技術，以降低光線強度變化對色彩之影響，並以銅色彩像素點空間分佈圖歸納出黃色銅線之分佈範圍，藉以辨識電感器細小之鐵心破

裂、斷線和線圈外露等瑕疵，且利用字元切割與細線化技術處理電感器上之型號，再萃取出各型號字元之特徵，包括水平與垂直的端點數和位置及三叉點和四叉點的個數，藉以識別電感器印字模糊和混料等瑕疵。本文為了提高型號字元之辨識率，另外發展一全新自適應性類神經網路系統當做字型之歸類器，利用幾何慣性法則以萃取字型之形狀特徵值，且發展一非線性最小平方誤差法則 (nonlinear least square error algorithm) 調整此類神經系統之 RBF 神經元所有參數，包括神經元之輸出權重值、中心值和寬度值，此自適應性類神經系統具備如下優點：1. 可依據近似誤差，透過訓練學習自動調整隱藏層神經元個數，以達到符合所要求近似精度之適當大小類神經網路系統；2. 能依據分類邊界各區域非線性程度之不同，適應性的調整神經元之分佈區域；3. 透過非線性最小平方誤差之學習法則自動調整系統所有參數，能確保系統參數快速收斂，具備高度之字元辨識精度。

二、視覺系統硬體架構

本文之影像視覺系統硬體架構如圖 2 所示，其中電腦使用 Pentium IV 2GHz 之個人電腦，系統撰寫軟體為 Borland C++，影像擷取卡則使用 Matrox 公司的 Meteor standard II 型影像擷取卡，影像套裝軟體為該公司之 MIL v7.0，CCD 為 Sony 公司的 1/2" 彩色攝影機，解析度為 640x480，CCD 擷取影像範圍的寬度與高度約為 3.9cmx3.3cm，每個像素的解析度約為 0.054mm，照明燈光使用新亞洲公司之環形燈光，介面卡為 8255 介面卡，溝通介面使用 ISA 介面，藉由 8255 介面卡接收 PLC 送出之電感器定位訊號，以啟動 CCD 取像，而當影像系統有檢測到電感器表面瑕疵時，再經由介面卡送出警示訊號至 PLC。電感器之瑕疵品大略可歸納為印字模糊、銅線圈外露、鐵心破裂和斷線等四種如圖 3 所示，而現有之電感器型號有 4R7、6R8、100 等三種如圖 4 所示。我們將發展影像檢測技術，包括影像定位、色彩分離、字型辨識和影像歸類等，以辨識電感器之表面瑕疵和型號，檢測規格為：1. 電感器之大小約 3-5mm；2. 檢測精度約 0.1mm；3. 檢測速度每秒約 1 個。

三、影像檢測流程

影像檢測系統流程如圖 5 所示，可將此影像處理架構劃分為影像前處理、影像定位、銅顏色搜尋、字元切割和字元辨識等五部分，分別說明如下。



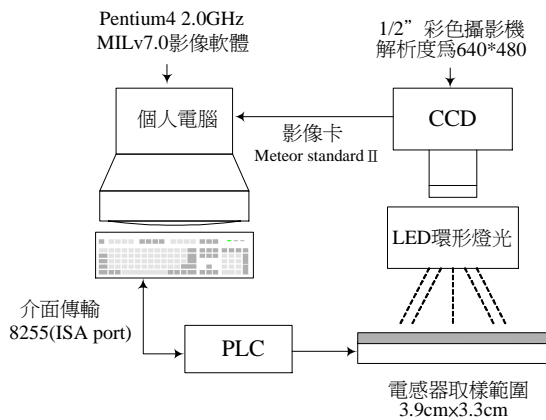


圖 2. 影像系統硬體架構



圖 3. 電感器之瑕疵種類



圖 4. 電感器之型號

(一) 影像前處理

影像前處理可分成影像濾波與影像二值化兩種，其中影像濾波應用在影像雜訊之濾除，而影像二值化主要是濾除影像之背景，以利影像定位與辨識處理。影像濾波為使用均化濾波器 (smooth filter) 去除影像之高雜訊，其 3*3 之遮罩如圖 6 所示，而為去除待測片與標準片影像光亮度不同的影響，以平均灰階值的觀念來拉近光亮點的差異，首先算出標準片與待測片影像平均灰階值之差異值 li_img 如下式：

$$li_img = \frac{1}{M \times N} \sum_{y=1}^N \sum_{x=1}^M [f_{st}(x, y) - f_{in}(x, y)] \quad (1)$$

其中 $f_{st}(x, y)$ 和 $f_{in}(x, y)$ 分別為標準影像和待測影像在 (x, y) 位置的灰階值，再將待測物影像之每個像素灰階值加上 (1)




圖 5. 影像檢測系統流程圖

1/16	2/16	1/16
2/16	4/16	2/16
1/16	2/16	1/16

圖 6. 均化濾波器之 3*3 遮罩

式算出之差異值 li_img ，以去除標準片與待測片影像亮度之差異，而待測片影像之新的灰階值 $Nin(x, y)$ 如下式：

$$Nin(x, y) = f_{in}(x, y) + li_img \quad (2)$$

所擷取之電感器影像可區分為背景和目標物，目標物為電感器鐵心本體，背景為電感器之固定座，因此在做電感器瑕疵檢測前，必須先將背景影像濾除，留下目標物影像以進行影像處理。根據電感器影像灰階的分佈範圍，透過找尋影像分離之灰階門檻值，可將影像分割出背景跟目標物，而找尋此灰階門檻值本文利用 Otsu 統計法 [4]，如圖 7 所示，透過疊代方式找到一個二值化之最佳灰階閾值 K^* ，使電感器之目標與背景影像兩群集之灰階變異數加權總和最小：

$$\sigma^2 = \omega_0 \times \sigma_0^2 + \omega_1 \times \sigma_1^2 \quad (3)$$

其中 ω_0 、 σ_0 、和 ω_1 、 σ_1 分別為目標影像和背景影像之灰階平均值和變異量。圖 8 為經過二值化後之電感器影像。






圖 7. Otsu 統計法示意圖




圖 8. 二值化後之電感器影像

(二) 影像定位

電感器之中央部份為圓形狀之鐵心，可透過找尋此鐵心之圓心當做電感器影像之定位點，如圖 8 之經二值化後之電感器影像，可由圓內向外依序不同方向找尋首次不為零之像素點，這些像素點即為鐵心圓之所有邊界點， $(x_n, y_n), n=1, \dots, N$ ，然後以最小平方方法利用這些邊界點求出鐵心圓之圓心，假如圓孔之方程式為：

$$r^2 = (x - c_x)^2 + (y - c_y)^2 \quad (4)$$

其中 r 為圓半徑和 (c_x, c_y) 為圓心座標，尋找最佳之圓半徑 r 和圓心 (c_x, c_y) 以最小化如下之價值函數：

$$L(r_0, c_x, c_y) = \frac{1}{2} \sum_{n=1}^N [r_0^2 - (x_n - c_x)^2 - (y_n - c_y)^2]^2 \quad (5)$$

針對 (5) 式分別對 r_0 、 c_x 和 c_y 偏微且令其等於零，並解方程式可得如下最佳之圓半徑和圓心：

$$r_0 = \sqrt{\frac{\sum_{n=1}^N x_n^2 - 2c_x \sum_{n=1}^N x_n + Nc_x^2 + \sum_{n=1}^N y_n^2 - 2c_y \sum_{n=1}^N y_n + Nc_y^2}{N}} \quad (6)$$

$$\begin{bmatrix} c_x \\ c_y \end{bmatrix} = AB \quad (7)$$

$$A = \begin{bmatrix} 2 \left[N \sum_{n=1}^N x_n^2 - \left(\sum_{n=1}^N x_n \right)^2 \right] & 2 \left[N \sum_{n=1}^N y_n x_n - \sum_{n=1}^N y_n \sum_{n=1}^N x_n \right] \\ 2 \left[N \sum_{n=1}^N y_n x_n - \sum_{n=1}^N x_n \sum_{n=1}^N y_n \right] & 2 \left[N \sum_{n=1}^N y_n^2 - \left(\sum_{n=1}^N y_n \right)^2 \right] \end{bmatrix}^{-1} \quad (8)$$

$$B = \begin{bmatrix} N \left(\sum_{n=1}^N x_n^3 + \sum_{n=1}^N y_n^2 x_n \right) - \sum_{n=1}^N x_n \left(\sum_{n=1}^N x_n^2 + \sum_{n=1}^N y_n^2 \right) \\ N \left(\sum_{n=1}^N x_n^2 y_n + \sum_{n=1}^N y_n^3 \right) - \sum_{n=1}^N y_n \left(\sum_{n=1}^N x_n^2 + \sum_{n=1}^N y_n^2 \right) \end{bmatrix} \quad (9)$$

以此圓半徑和圓心，我們能成功切割出電感器之鐵心如圖 9 所示。

(三) 銅顏色搜尋

銅顏色的搜尋主要是在於檢測電感器表面之瑕疵，透過尋找和計算電感器中裸露銅的位置和比例，以辨識出鐵心破裂或繞線時少量銅線裸露等瑕疵。為了歸納銅色彩像素點之 RGB 空間分佈區域，先將電感器中銅線之像素點萃取出來，由於彩色之 RGB 表示法，對於光線變化有相當敏感，因此將 RGB 彩色空間，轉換到 NCC (normalized color coordinates) 彩色空間，以減少顏色對於亮度的依賴，其轉換的方式如下所示：

$$R_N = \frac{R}{R+G+B} \quad (10)$$

$$G_N = \frac{G}{R+G+B} \quad (11)$$

$$B_N = \frac{B}{R+G+B} \quad (12)$$

由於 B_N 對光線較為敏感，因此只取銅線色彩之 R_N 與 G_N 值作分析，並畫出 2D 之空間分佈圖如圖 10 所示，根據此圖



圖 9. 被切割出之電感器鐵心






圖 10. 銅色彩 R_N 與 G_N 之 2D 分佈圖

我們可界定出屬於銅顏色之區域如下所示：

$$S = \begin{cases} 1, & w < 0.06 \text{ AND } w > 0.0004 \text{ AND } R_N > 0.28 \text{ AND } G_N > 0.3 \\ 0, & \text{otherwise} \end{cases} \quad (13)$$

$$w = (R_N - 0.3)^2 + (G_N - 0.3)^2 \quad (14)$$

其中 w 代表一以 $(0.3, 0.3)$ 為圓心之圓，此區域為白色像素點可能座落之區域，必須排除。如圖 10 所示， $S=1$ 代表是銅顏色區域， $S=0$ 代表非銅顏色區域。利用此判斷式，可正確尋找出電感器中屬於銅顏色區域如圖 11 所示，如銅所佔區域比率過大或是出現在鐵心之外緣，代表電感器鐵心有破裂或是銅線外露之瑕疵發生。

(四) 字元切割

電感器之型號為印刷在其鐵心圓上，但印刷位置不確定。如圖 9 所示，型號一般由三個字元所組成，且型號上端有一印刷小圓，為了切割型號字元，先針對鐵心圓做二值化處理，以分離出型號字元，再利用型號字元分別在 X 軸與 Y




圖 11. 電感器中銅顏色區域

軸之投影像素點個數之方法，做為字元切割之依據，如圖 12 所示，由 Y 軸位置投影圖，我們發現印刷小圓跟型號字元的像素投影個數很明顯的可區分開，因此可切割出型號字元在 Y 軸之座標範圍。另外，由 X 軸之投影位置圖，可觀察出三個型號字元的像素投影個數，彼此間也各有一明顯區隔距離，因此可切割出三個型號字元分別在 X 軸之座標範圍。為了避免不必要的雜訊介於字元間之干擾，我們必須訂立一適當之門檻值，做為切割字元之依據，當投影像素點個數小於此門檻值時，都將被視為雜訊而排除，大於此門檻值之像素點位置，才是三個型號字元可能所在之位置。

(五) 字元辨識

本文所要辨識之電感器型號主要有 4R7、100 和 6R8 等三種，由於不同之字元或字母在形狀上會有不同的結構特徵，因此本文將擷取各型號字元之端點和交叉點，做為字元識別之依據。先針對被切割出型號字元之尺寸做正規化處理，依據各個字的寬與長，分別放大或縮小成 50×50 像素點大小的圖形，因影像經由放大或縮小，圖形有可能發生空洞，因此利用膨脹運算步驟 [4]，將可能產生錯誤的空洞點填補，最後得到正規化後之型號字元如圖 13 所示。針對此正規化後之型號字元做細線化，細線化之執行步驟敘述如下：

針對如圖 14 之 3×3 遮罩，像素點 $P(1)$ 是否刪除以疊代執行底下兩步驟做判別：

步驟一：同時滿足以下四個條件就刪除。




圖 12. 型號字元分別在 X 軸與 Y 軸之像素點投影圖



圖 13. 正規化後之型號字元






圖 14. 細線化之遮罩




圖 16. 節點特徵判定

- (1) $2 < B(P) < 6$
- (2) $A(P) = 1$
- (3) $P(2) = 0$ or $P(4) = 0$ or $P(6) = 0$
- (4) $P(4) = 0$ or $P(6) = 0$ or $P(8) = 0$

步驟二：同時滿足以下四個條件就刪除。

- (1) $2 < B(P) < 6$
- (2) $A(P) = 1$
- (3) $P(2) = 0$ or $P(4) = 0$ or $P(8) = 0$
- (4) $P(2) = 0$ or $P(6) = 0$ or $P(8) = 0$

其中 $A(P)$ 為由 $P(2)$ 依序至 $P(9)$ 有多少次 0 變 1 或 1 變 0 的次數，而 $B(P)$ 為 $P(1)$ 至 $P(9)$ 為 1 的總個數。細線化步驟一是判斷字元影像右下角是否需要消除的點，而步驟二為消去字元影像左上角的點，將這兩個步驟疊代利用，直到整個字元影像沒有點需要被消除時為止，最後可得字元細線化後的骨架，如圖 15 所示。針對此細線化後之字元骨架，擷取形狀特徵值以做字元判別，敘述如下。

1. 節點特徵值擷取

節點定義為字元中端點、三叉點或四叉點之樣式，本文以一個 3*3 遮罩應用於細線化後的字元影像，如圖 16 所示，藉由計算各字元像素點之 $A(P)$ 值來判定節點樣式，若所計算出來的 $A(P) = 1$ ，則判定該像素點具端點特徵， $A(P) = 3$ ，則判定該像素點具三叉點特徵， $A(P) = 4$ ，則判定該像素點具四叉點特徵，針對字元由左至右由上至下進行掃描，以統計出字元影像所有之節點特徵數。

2. 水平和垂直軸位置編碼

首先將字元影像依據垂直及水平方向等區分成 A、B、C 與 D、E、F 六個區域，分別針對此六個區域內進行找尋，



圖 15. 細線化後之型號字元

假如區域內存在等於或大於兩個端點數則將該區域編碼為 1，否則為零，依此可編成六碼。另外，假如 A、B 和 C 三個垂直區域內，只要有一個區域編碼為 1 時，則其垂直編碼為 1，否則為零，而水平方向 D、E 和 F 三個區域也以相似方式編碼，因此可得另一水平編碼，依此組成二碼。以字元 3 為例，經過細線化處理後可得到 3 個端點，如圖 17 所示，在 A 至 F 六個區域中因 A 區有兩個端點，因此 A 編碼為 1，其餘 B 至 F 並無兩個端點以上出現，因此編得六碼為 000001，而在垂直方向 A 至 C 區域，因有 A 區編碼為 1，因此垂直編碼為 1，而在水平方向 D 至 F 區域，並沒有任何區域編為 1，因此水平編碼為 0，因此編得二碼為 10，如圖 18 所示。

依上述之編碼方式，針對圖 15 之七個型號字元，我們可歸類出相對應之特徵碼如表 1 所示，利用此特徵碼可做為字元辨識之依據。




圖 17. 字元 3 之垂直和水平區域切割

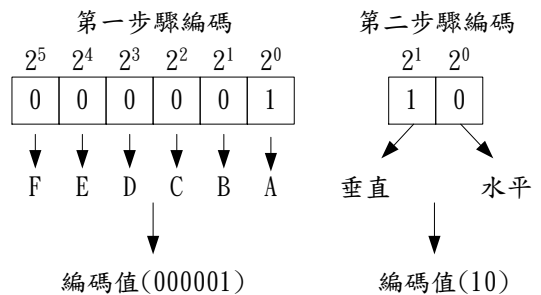


圖 18. 字元 3 之水平和垂直軸位置編碼



表 1. 型號字元的特徵碼

字元	節點特徵值			水平和垂直軸位置編碼							
	端點數	三叉點數	四叉點數	水平區域			垂直區域			組合編碼	
				F	E	D	C	B	A	水平	垂直
0	0	0	0	0	0	0	0	0	0	0	0
1	3	1	0	0	0	1	1	0	0	1	1
4	4	2	1	1	0	0	1	0	0	1	1
6	1	1	0	0	0	0	0	0	0	0	0
7	3	1	0	0	0	1	0	0	1	1	1
8	0	2	0	0	0	0	0	0	0	0	0
R	2	2	0	1	0	0	0	0	0	1	0

四、自適應性類神經網路系統

利用第三節以擷取幾何特徵編碼之字元辨識方式，當字元影像取像較不清楚時，容易受到雜訊干擾，而造成字元影像編碼錯誤，以致於誤判字元，因此，本節將另外提出一自適應性類神經網路架構，做為字元辨識之歸類器，以提高字元辨識之強度。

為了克服字型位移、旋轉和縮放等問題，及減少影像處理之複雜，本文利用統計之幾何慣性（moments）法則，分別萃取型號字元幾何形狀特徵值，所萃取之特徵值將當作類神經網路系統之輸入，做為字型歸類之依據。對於任意一字元影像 $G(x,y)$ 之 $\alpha+\beta$ 階（order）幾何慣性值定義如下：

$$M_{\alpha\beta} = \sum_x \sum_y x^\alpha y^\beta G(x,y) \quad (15)$$

第零階慣性值 M_{00} 代表影像像素點灰階值總合，而高階之慣性值代表影像之空間幾何分佈。第（15）式之幾何慣性值容易受影像位置偏移影響，而中心幾何慣性值（central moments）可以修正此問題定義如下：

$$\mu_{\alpha\beta} = \sum_x \sum_y (x-\bar{x})^\alpha (y-\bar{y})^\beta G(x,y) \quad (16)$$

其中 $\bar{x} = M_{10}/M_{00}$ 和 $\bar{y} = M_{01}/M_{00}$ 。此中心幾何慣性值可進一步被正規化（normalized）如下：

$$\eta_{\alpha\beta} = \mu_{\alpha\beta} / \mu_{00}^\gamma \quad (17)$$

其中 $\gamma = 1 + (\alpha + \beta) / 2$ 。我們可以利用（16）和（17）式分別對正規化後之型號字元，取前幾階之中心幾何慣性值當作

字元識別之特徵值，本文取 η_{00} 、 η_{01} 、 η_{10} 、 η_{20} 、 η_{21} 、 η_{02} 、 η_{12} 和 η_{22} 等八個中心幾何慣性值當作類神經網路系統之輸入。

傳統之輻射狀（RBF）類神經網路系統如圖 19 所示，其中 $\mathbf{x} = [x_1, x_2, \dots, x_m]^T$ 為網路 m 個輸入， $f(\mathbf{x})$ 為網路單個輸出，隱藏層有 N 個神經元及所相對應之 N 個 RBF 函數 $\phi_1(\mathbf{x}, \sigma_1, \mathbf{c}_1), \phi_2(\mathbf{x}, \sigma_2, \mathbf{c}_2), \dots, \phi_N(\mathbf{x}, \sigma_N, \mathbf{c}_N)$ ，和與輸出相連之權重 $\alpha_1, \alpha_2, \dots, \alpha_N$ 。此 RBF 類神經網路系統可當作字元辨識之歸類器，其輸入 $\mathbf{x} \in R^m$ 為上述型號字元之中心幾何慣性值，單個輸出 $f(\mathbf{x})$ 代表型號字元，如圖 13 之七個型號字形，為了方便運算可以用數值代表歸類種類，譬如字元“0”為 1、字元“1”為 3、字元“4”為 5、字元“6”為 7、字元“7”為 9、字元“8”為 11 和、字元“R”為 13。此類神經系統之輸出如下：

$$f(\mathbf{x}) = \alpha_0 + \sum_{i=1}^N \alpha_i \phi_i(\mathbf{x}, \sigma_i, \mathbf{c}_i) \quad (18)$$




圖 19. 傳統之 RBF 類神經網路系統



$$\phi_i(\mathbf{x}, \mathbf{c}_i, \sigma_i) = \exp\left(-\frac{\|\mathbf{x} - \mathbf{c}_i\|^2}{\sigma_i^2}\right) \quad (19)$$

其中 \mathbf{c}_i 為中心和 σ_i 為 RBF 寬度。給定一欲近似函數 $y(\mathbf{x})$ ，定義類神經網路系統之最佳參數值如下：

$$\left(\alpha_0^*, \alpha_1^*, \sigma_1^*, \mathbf{c}_1^*, \dots, \alpha_N^*, \sigma_N^*, \mathbf{c}_N^*\right) = \arg \min_{(\alpha_i, \sigma_i, \mathbf{c}_i)} \left[\sup_{\mathbf{x} \in U_N} |f(\mathbf{x}) - y(\mathbf{x})| \right] \quad (20)$$

因此 $y(\mathbf{x})$ 可被表示成如下式：

$$y(\mathbf{x}) = \alpha_0^* + \sum_{i=1}^N \alpha_i^* \phi_i(\mathbf{x}, \sigma_i^*, \mathbf{c}_i^*) + \varepsilon_N(\mathbf{x}) \quad (21)$$

其中 $\varepsilon_N(\mathbf{x})$ 為近似誤差。第 (18) 式之類神經網路系統具有全稱近似性，即透過加大隱藏層神經元個數 N ，近似誤差 $\varepsilon_N(\mathbf{x})$ 可被降至任意小之值。雖然隱藏層神經元個數增加時，類神經網路系統之近似誤差會降低，但當神經元個數增加到一定程度時，近似誤差降低速度將趨慢，此時再增加神經元個數對降低近似誤差沒有太大幫助，甚至會造成過分近似 (over-fitting) 問題，因此，如何找到一具有適當隱藏層神經元個數之類神經系統，以完成所要求之近似精度，此問題是類神經網路系統一直待解的問題，本文發展一自適應性類神經網路系統以調整神經元個數，並推導非線性最小平方誤差法則 (nonlinear least square error algorithm) 調整此類神經系統之神經元所有參數，包括神經元之輸出權重值、中心值和寬度值，此類神經網路架構能確保系統參數快速收斂，具備高度之辨識精度。

如第 (18) 式之類神經網路系統，分別定義系統最佳參數向量值、估計向量值和誤差向量如下：

$$\mathbf{W}_N^* \equiv [\alpha_0^*, \alpha_1^*, \sigma_1^*, \mathbf{c}_1^*, \dots, \alpha_N^*, \sigma_N^*, \mathbf{c}_N^*]^T \quad (22)$$

$$\hat{\mathbf{W}}_N \equiv [\hat{\alpha}_0, \hat{\alpha}_1, \hat{\sigma}_1, \hat{\mathbf{c}}_1, \dots, \hat{\alpha}_N, \hat{\sigma}_N, \hat{\mathbf{c}}_N]^T \quad (23)$$

$$\tilde{\mathbf{W}}_N = \mathbf{W}_N^* - \hat{\mathbf{W}}_N \quad (24)$$

對 (18) 式之類神經網路系統而言，神經元之輸出權重值 $\hat{\boldsymbol{\alpha}} = [\hat{\alpha}_1, \hat{\alpha}_2, \dots, \hat{\alpha}_N]^T$ 為線性參數，較好調整，一般傳統 RBF 類神經系統之學習法則只調整此輸出權重值，但這樣不能發揮類神經系統最佳之近似性能；而神經元之寬度向量

$\hat{\boldsymbol{\sigma}} = [\hat{\sigma}_1, \hat{\sigma}_2, \dots, \hat{\sigma}_N]^T$ 和中心向量 $\hat{\mathbf{c}} = [\hat{\mathbf{c}}_1, \hat{\mathbf{c}}_2, \dots, \hat{\mathbf{c}}_N]^T$ 為非線性參數，則較難調整。因此，針對 $\phi_i(\mathbf{x}, \sigma_i^*, \mathbf{c}_i^*)$ 利用泰勒展開式於 $(\hat{\sigma}_i, \hat{\mathbf{c}}_i)$ 處展開，可得下式：

$$\phi_i^* = \hat{\phi}_i + \phi'_{\sigma_i} (\sigma_i^* - \hat{\sigma}_i) + \phi'_{\mathbf{c}_i} (\mathbf{c}_i^* - \hat{\mathbf{c}}_i) + h_i \quad (25)$$

其中 $\phi_i^* \equiv \phi_i(\mathbf{x}, \sigma_i^*, \mathbf{c}_i^*)$, $\hat{\phi}_i \equiv \phi_i(\mathbf{x}, \hat{\sigma}_i, \hat{\mathbf{c}}_i)$,

$$\phi'_{\sigma_i} \equiv \phi'_{\sigma_i}(\mathbf{x}, \hat{\sigma}_i, \hat{\mathbf{c}}_i) = \left. \frac{\partial \phi_i(\mathbf{x}, \sigma_i^*, \mathbf{c}_i^*)}{\partial \sigma_i^*} \right|_{\substack{\sigma_i^* = \hat{\sigma}_i \\ \mathbf{c}_i^* = \hat{\mathbf{c}}_i}} = 2\|\mathbf{x} - \hat{\mathbf{c}}_i\|^2 \phi_i(\mathbf{x}, \hat{\sigma}_i, \hat{\mathbf{c}}_i) / \hat{\sigma}_i^3, \quad (26)$$

$$\phi'_{\mathbf{c}_i} \equiv \phi'_{\mathbf{c}_i}(\mathbf{x}, \hat{\sigma}_i, \hat{\mathbf{c}}_i) = \left. \frac{\partial \phi_i(\mathbf{x}, \sigma_i^*, \mathbf{c}_i^*)}{\partial \mathbf{c}_i^*} \right|_{\substack{\sigma_i^* = \hat{\sigma}_i \\ \mathbf{c}_i^* = \hat{\mathbf{c}}_i}} = 2\|\mathbf{x} - \hat{\mathbf{c}}_i\|^2 \phi_i(\mathbf{x}, \hat{\sigma}_i, \hat{\mathbf{c}}_i) (\mathbf{x} - \hat{\mathbf{c}}_i)^T / \hat{\sigma}_i^2 \quad (27)$$

和 $h_i \equiv (\mathbf{x}, \hat{\sigma}_i, \hat{\mathbf{c}}_i)$ 為高階之剩餘項 (residual terms)。由 (21) 式和 (25) 式可推得類神經網路系統之輸出誤差如下：

$$\begin{aligned} e_N(\mathbf{x}) &= y(\mathbf{x}) - \left[\hat{\alpha}_0 + \sum_{i=1}^N \hat{\alpha}_i \phi_i(\mathbf{x}, \hat{\sigma}_i, \hat{\mathbf{c}}_i) \right] \\ &= \left[\alpha_0^* + \sum_{i=1}^N \alpha_i^* \phi_i(\mathbf{x}, \sigma_i^*, \mathbf{c}_i^*) \right] - \left[\hat{\alpha}_0 + \sum_{i=1}^N \hat{\alpha}_i \phi_i(\mathbf{x}, \hat{\sigma}_i, \hat{\mathbf{c}}_i) \right] + \varepsilon_N(\mathbf{x}) \\ &= \tilde{\alpha}_0 + \sum_{i=1}^N [\hat{\phi}_i - \phi'_{\sigma_i} \hat{\sigma}_i - \phi'_{\mathbf{c}_i} \hat{\mathbf{c}}_i] \tilde{\alpha}_i + \sum_{i=1}^N \hat{\alpha}_i \phi'_{\sigma_i} \tilde{\sigma}_i + \sum_{i=1}^N \hat{\alpha}_i \phi'_{\mathbf{c}_i} \tilde{\mathbf{c}}_i + \varepsilon_h + \varepsilon_N(\mathbf{x}) \\ &= \boldsymbol{\Psi}_N^T \tilde{\mathbf{W}}_N + \varepsilon_T \end{aligned} \quad (28)$$

其中

$$\begin{aligned} \boldsymbol{\Psi}'_N &\equiv \boldsymbol{\Psi}'_N(\mathbf{x}, \hat{\boldsymbol{\sigma}}, \hat{\mathbf{c}}) \\ &= \left[\hat{\phi}_1 - \phi'_{\sigma_1} \hat{\sigma}_1 - \phi'_{\mathbf{c}_1} \hat{\mathbf{c}}_1, \hat{\alpha}_1 \phi'_{\sigma_1}, \hat{\alpha}_1 \phi'_{\mathbf{c}_1}, \dots, \right. \\ &\quad \left. \hat{\phi}_N - \phi'_{\sigma_N} \hat{\sigma}_N - \phi'_{\mathbf{c}_N} \hat{\mathbf{c}}_N, \hat{\alpha}_N \phi'_{\sigma_N}, \hat{\alpha}_N \phi'_{\mathbf{c}_N} \right]^T \end{aligned} \quad (29)$$

$$\varepsilon_h \equiv \varepsilon_h(\mathbf{x}, \hat{\boldsymbol{\sigma}}, \hat{\mathbf{c}}) = \sum_{i=1}^N \tilde{\alpha}_i [\phi'_{\sigma_i} \tilde{\sigma}_i + \phi'_{\mathbf{c}_i} \tilde{\mathbf{c}}_i] + \sum_{i=1}^N \hat{\alpha}_i h_i(\mathbf{x}, \sigma_i, \mathbf{c}_i) \quad (30)$$

$$\varepsilon_T \equiv \varepsilon_T(\mathbf{x}, \hat{\boldsymbol{\sigma}}, \hat{\mathbf{c}}) = \varepsilon_h(\mathbf{x}, \hat{\boldsymbol{\sigma}}, \hat{\mathbf{c}}) + \varepsilon_N(\mathbf{x}) \quad (31)$$



$\hat{\boldsymbol{\sigma}} = [\hat{\sigma}_1, \hat{\sigma}_2, \dots, \hat{\sigma}_N]^T$ 和 $\hat{\mathbf{c}} = [\hat{c}_1, \hat{c}_2, \dots, \hat{c}_N]^T$ 。當 $\hat{\alpha}_i \rightarrow \alpha_i^*$ 、 $\hat{\sigma}_i \rightarrow \sigma_i^*$ 和 $\hat{c}_i \rightarrow c_i^*$ 時，則 $h_i \rightarrow 0$ 和 $\varepsilon_h \rightarrow 0$ ，因此總體之近似誤差 ε_T 為一有限值。

當此類神經網路被應用於型號字元之辨識前，所有系統參數必須經過訓練以得到最佳之辨識效果。首先針對各種不同形式之型號字元，利用 (16) 和 (17) 式計算前幾階之中心幾何慣性值，以取得 M 組訓練資料 $\{(\mathbf{x}(k), y(k)), i=1, \dots, M\}$ ，並最小化如下之價值函數：

$$J(\hat{\mathbf{W}}_N) = \frac{1}{2} \sum_{k=1}^M \left\{ y(k) - \left[\hat{\alpha}_0 + \sum_{i=1}^N \hat{\alpha}_i \phi_i(\mathbf{x}, \hat{\boldsymbol{\sigma}}, \hat{\mathbf{c}}_i) \right] \right\}^2 \quad (32)$$

利用 (28) 式和 (32) 式可推得非線性最小平方誤差學習法則如下：

$$e_N(k) = y(k) - \left[\hat{\alpha}_0(k-1) + \sum_{i=1}^N \hat{\alpha}_i(k-1) \phi_i(\mathbf{x}(k), \hat{\boldsymbol{\sigma}}(k-1), \hat{\mathbf{c}}_i(k-1)) \right] \quad (33)$$

$$\hat{\mathbf{W}}_N(k) = \hat{\mathbf{W}}_N(k-1) + \frac{\mathbf{P}_N(k-1) \boldsymbol{\psi}'_N(k)}{1 + \boldsymbol{\psi}'_N(k) \mathbf{P}_N(k-1) \boldsymbol{\psi}'_N(k)} \times e_N(k) \quad (34)$$

$$\mathbf{P}_N(k) = \mathbf{P}_N(k-1) - \frac{\mathbf{P}_N(k-1) \boldsymbol{\psi}'_N(k) \boldsymbol{\psi}'_N(k) \mathbf{P}_N(k-1)}{1 + \boldsymbol{\psi}'_N(k) \mathbf{P}_N(k-1) \boldsymbol{\psi}'_N(k)} \quad (35)$$

其中 $\mathbf{P}_N(k)$ 為輸入之共變異矩陣 (covariance matrix)。

因此，假如給定一欲達到之近似誤差 E_f ，自適應性類神經網路系統將自動增加或減少隱藏層神經元個數，以得到符合此近似誤差 E_f 之最適合大小類神經網路系統，其調整步驟如下：

STEP1：輸入一組訓練資料 $(\mathbf{x}(k), y(k))$ ，由 (18) 式計算網路之輸出 $f(\mathbf{x}(k))$ 。

STEP2：假如底下之條件同時被符合，代表此時類神經網路之近似誤差太大，需增加一隱藏層神經元。

$$|e(k)| = |y(k) - f(\mathbf{x}(k))| > E_f + E_1(k) \quad (36)$$

$$d = \|\mathbf{x}(k) - \mathbf{c}_{kr}\| > E_2 \quad (37)$$

其中 \mathbf{c}_{kr} 為所有隱藏層神經元之中心最靠近輸入 $\mathbf{x}(k)$ 者， $E_1(k)$ 為遞減函數，當 $k \rightarrow \infty$ ，則 $E_1(k) \rightarrow 0$ ， E_2 為一門檻值。第 (36) 式用以檢查現有之神經網路個數是否符合誤差要求，而第 (37) 式用以檢查所要新增神經元之中心向量是否夠遠離現有存在之神經元。所增加之隱藏層神經元樣式如下：

$$\begin{aligned} \hat{\alpha}_{N+1} &= e(k), & \hat{\mathbf{c}}_{N+1} &= \mathbf{x}(k), \\ \hat{\sigma}_{N+1} &= \kappa \|\mathbf{x}(k) - \mathbf{c}_{kr}\| \end{aligned} \quad (38)$$

其中 κ 為神經元之重疊係數。

STEP3：假如底下之條件被符合，代表近似誤差太小，可能有過分近似情形，需移除一隱藏層神經元。

$$|e(k)| = |y(k) - f(\mathbf{x}(k))| < E_3(k) \quad (39)$$

其中 $E_3(k)$ 為遞減函數。而中心向量 \mathbf{c}_{kr} 最靠近輸入 $\mathbf{x}(k)$ 之隱藏層神經元，因影響類神經系統輸出最大，將被去除。

STEP4：移除輸出值貢獻小之隱藏層神經元，經 N_w 次觀察假如隱藏層之神經元經正規化之輸出值一直小於一門檻值 δ ，則消去此隱藏層神經元。隱藏層神經元之輸出為

$$o_i = \hat{\alpha}_i \exp(-\|\mathbf{x} - \hat{\mathbf{c}}_i\|^2 / \hat{\sigma}_i^2), i=1, \dots, N \quad (40)$$

除以最大神經元輸出值得到正規化值如下：

$$r_i = \frac{o_i}{\max\{o_1, o_2, \dots, o_N\}}, i=1, \dots, N \quad (41)$$

當 r_i 值經 N_w 次觀察一直小於一門檻值 δ 時，則消去此隱藏層神經元。

STEP5：依 (33) 式計算輸出誤差值，並以 (34) 和 (35) 式之非線性最小平方誤差法則，調整 $\hat{\mathbf{W}}_N$ 。

經由上述之學習步驟，所訓練出之類神經網路系統具有最適量之隱藏層神經元個數及最佳之系統參數，以符合所要之近似誤差 E_f 。



五、實驗與結果

將本文所發展方法應用於實際各種不同型號之電感器，實驗內容主要針對銅顏色搜尋和型號字元辨識分別進行實驗，且分別以電感器在黑色與透明兩種包裝帶子下測試。銅顏色搜尋，用於找尋和計算電感器中裸露銅的位置和比例，如果比例值偏高，表示有鐵心破裂或繞線時少量銅線裸露等瑕疵，實驗時我們分別取 200 筆之電感器包含鐵心破裂、銅線外露與未破裂影像做各別測試，電腦執行時間約每個 80msec，瑕疵品辨識成功率約 98%，此方法對於少量銅線外露之電感器瑕疵品有較差之辨識率。而型號字元辨識我們利用節點特徵編碼和自適應性類神經網路系統兩種方法分別進行測試，並比較優劣，我們各取 300 筆包含各種不同型號和樣式之字元當作類神經之訓練和測試資料，每筆資料利用 (16) 和 (17) 式擷取 η_{00} 、 η_{01} 、 η_{10} 、 η_{20} 、 η_{21} 、 η_{02} 、 η_{12} 和 η_{22} 等八個中心幾何慣性值，以當作類神經網路系統之輸入，RBF 類神經網路之初始隱藏層個數 N 為 50 個，初始之輸出權重值 $\hat{\alpha}_0, \hat{\alpha}_1, \dots, \hat{\alpha}_N$ 為分佈於 0 至 15 區間之任意實數值，所有之初始寬度值 $\hat{\sigma}_i$ 為 2.0，所有初始中心向量 \hat{c}_i 之各座標值取為分佈於 -1 和 +1 間之任意實數值，而自適應性類神經網路系統參數設定：所要求之近似誤差 $E_f=0.1$ ；遞減函數 $E_1(k)$ 和 $E_3(k)$ 取為 $E_1(k)=E_2(k)=0.05e^{-0.1k}$ ；門檻值 $E_2=0.1$ ；神經元之重疊係數 $k=2.0$ ； $N_w=50$ 次觀察和門檻值 $\delta=0.001$ 。系統參數則依據 (34) 和 (35) 式做調整。圖 20 為類神經網路之收斂情形，約經 35 批次訓練後類神經網路系統到達穩定收斂狀態，再針對 300 筆測試資料進行測試，總合均方根誤差 (RMS) 約為 7.2，辨識率約 99%，每筆型號字元執行辨識時間約為 500msec，圖 21 為隱藏層神經元個數收斂之情形，最終隱藏層個數為 36 個；而利用節點特徵編碼，辨識率約 92%，每筆型號字元辨識執行時間約為 450msec。因此，所發展之類神經網路系統有較佳之辨識率，但相對有較長之執行時間。最後，將本文所發展之影像視覺系統應用於實際超薄型表面載式電感器製程生產線如圖 22 所示，影像檢測程式為利用 Borland C++ 撰寫，電腦檢測畫面如圖 23 所示，結果驗證本文所提方法之有效性。

六、結論

本文成功發展一影像處理技術包括影像定位、色彩分離、字型辨識和影像歸類等，以檢測電感器之表面瑕疵和型




圖 20. 類神經網路系統收斂情形




圖 21. 隱藏層神經元個數收斂情形




圖 22. 實際超薄型表面載式電感器製程生產線



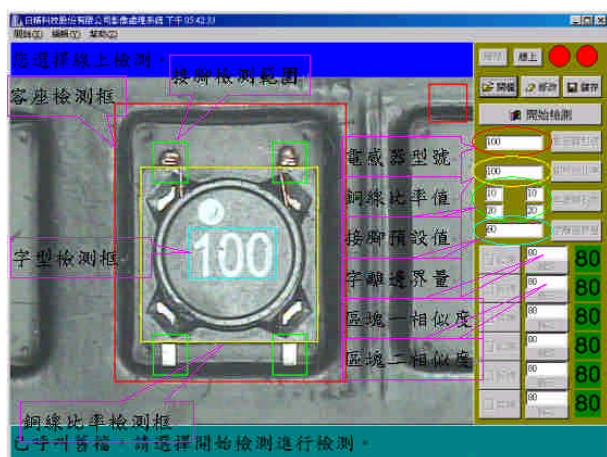


圖 23. 電腦檢測畫面

號，檢測電感器之大小約 3-5mm，檢測精度約 0.1mm，檢測速度每秒約 1 個。本文利用正交色彩空間轉換技術，降低光線強度變化對色彩之影響，並以銅色彩像素點空間分佈圖歸納出銅線之分佈範圍，藉以辨識電感器細小之鐵心破裂、斷線和線圈外露等瑕疵。利用字元切割與細線化技術處理電感器上之型號，再針對各型號字元之節點特徵編碼共編成八碼，藉以檢測電感器印字模糊和混料等瑕疵。另外，本文為了提高型號字元之辨識率，提出一全新自適應性類神經網路系統當做字型之歸類，首先利用幾何慣性法則萃取字型之形狀特徵值，以克服字型位移、旋轉和縮放等問題，最後擷取八個中心幾何慣性值當作類神經網路系統之輸入，並發展一非線性最小平方誤差法則調整此類神經系統之 RBF 神經元所有參數，包括神經元之輸出權重值、中心值和寬度值，確保系統參數快速收斂，此自適應性類神經系統可依據近似誤差，透過訓練學習自動調整隱藏層神經元個數，以達到符合所要求近似精度之隱藏層神經元個數。最後，將所發展出之影像檢測技術應用於實際之超薄型表面載式電感器生產線，以驗證所提方法之有效性，電感器表面瑕疵辨識率可達 98% 以上，而型號字元辨識率可達 99% 以上。

誌謝

本研究承蒙國科會經費補助特此感謝，計畫編號：NSC 93-2212-E-212-012。

參考文獻

1. Chang, J. Y. and C. L. Lee (1994) Translation, rotation, and scaling invariant pattern recognition by fuzzy neural networks. The 2nd National Conference on Fuzzy Theory and Application, Tainwan.
2. Chen, X. J., Y. J. Zhang and A. Waibel (2004) Automatic detection and recognition of signs from natural scenes. *IEEE Transactions on Image Processing*, 13(1), 87-99.
3. Fang, C. Y., S. W. Chen and C. S. Fuh (2003) Road-Sign Detection and Tracking. *IEEE Transactions on Vehicular Technology*, 52(5), 1329-1341.
4. Gonzalez, R. C. and R. E. Woods (1992) *Digital Image Processing*, 100-120. Addison Wesley, Menlo Park, CA.
5. Khunkay, S. and K. Paith (1997) Image segmentation by fuzzy rule and Kohonen-constraint satisfaction fuzzy c-mean. ICICS'97 Singapore, Singapore.
6. Kim, J. K. and H. S. Cho (1995) Neural network-based inspection of solder joints using a circular illumination. *Image Vision Computation*, 13, 479-490.
7. Kon, K. W. and H. S. Cho (2000) Solder joints inspection using a neural network and fuzzy rule based classification method. *IEEE Transactions on Electronics Packaging Manufacturing*, 23(2), 93-103.
8. Paschos, G. and K. P. Valavanis (1999) A color texture based visual monitoring system for automated surveillance. *IEEE Transactions on Systems, Man, and Cybernetics- Part C: Applications and Reviews*, 29(1), 298-307.
9. Ruzon, M. A. and C. Tomasi (2001) Edge, junction, and corner detection using color distributions. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 23(11), 1281-1295.
10. Sakurai, K., A. Onoyama, T. Fujii, K. I. Yamanishi, S. Fujii and H. Morita (2002) Solution of pattern matching inspection problem for grainy metal layers. *IEEE Transactions on Semiconductor Manufacturing*, 15(1), 118-126.
11. Scharcanski, J. and A. N. Venetsanopoulos (1997) Edge detection of Color Images using directional operators. *IEEE Transactions on Circuits System Video Technology*, 7(2), 397-401.
12. Sun, S. M. (2001) A new stroke extraction method of Chinese character. *International Journal of Pattern Recognition and Artificial Intelligence*, 5(4), 707-721.



-
13. Yuceer, C. and K. Oflazer (1993) A rotation, scaling, and translation invariant pattern classification system. *Pattern Recognition*, 26(5), 687-719.
14. Zervakis, M. E., S. K. Goumas and G. A. Rovithakis (2003) A Bayesian framework for multilead SMD post-placement quality inspection. *IEEE Transactions on Systems, Man, and Cybernetics-part B: Cybernetics*, 1-13.
- 收件：94.04.12 修正：94.06.09 接受：94.09.26

