

第一章 緒論

1.1 研究動機與目的

隨著科技發展日新月異，影像辨識應用的範疇越來越廣，從一九六八年開始研究影像處理辨識，主要是研究樣型識別運用在染色體與指紋的辨識上，現今影像辨識技術日臻成熟，大幅縮短資料輸入與物件識別的時間。目前影像辨識大體上可分為三類，分別為文字辨識、圖形辨識和生物辨識。文字辨識常見的應用領域在手寫或印刷文字(中、英文)、郵件和車輛牌照……等。圖形辨識的應用範圍可見於辨識影像資料庫物件、移動影像物件、印鑑、條碼和工業零件……等。生物辨識主要是以辨識人類生理特徵為主，常見的應用領域在視網膜辨識、指紋辨識、掌紋辨識、臉型辨識和 DNA 辨識……等。

目前許多研發方向透過影像辨識達成影像互動的操作功能，主要是利用影像辨識的方法，在使用者不配戴任何感測元件的狀況下，透過網路攝影機追蹤到使用者的手勢動作，抓取影像中手勢的位置與運動軌跡，藉由電腦分析辨識影像中手勢的語意，電腦操作機器平台作出適當的回應，使用上不僅操控介面簡單，而且不需要觸碰任何機械或電子元件(例如螢幕、鍵盤、滑鼠……等)，不僅比較衛生，也符合環保與經濟成本上的考量。其應用範圍在監控系統、樓層導覽、交通資訊查詢、機器人、智慧型照護系統和電視介面操作……等，相信未來影像互動會大幅度的改變人類生活習慣，提升生活與休閒的品質。

本論文的目的是希望藉由影像處理技術取得手勢影像的特徵並透過倒傳遞類神經網路來訓練與驗證手勢特徵，透過電腦辨識手勢背後所代表的意義，以達到利用智慧型辨識法則完成影像互動操作的功能，期望未來人類可以利用手勢透過電腦來操作機器平台，使其隨時注意人們生活上的需求並提供服務。

1.2 文獻回顧

隨著現代社會型態的轉變，在少子化、老齡化的趨勢下，世界各國積極發展機器人以提供娛樂、陪伴、療傷與互動等諸多功能，相信未來會有越來越多具備互動學習、情緒辨識、互動感知的機器人，同時兼具有外觀美化與友善功能的設計。其研發領域與關鍵技術包涵環境感知、影像辨識技術、語音辨識與語意理解、情緒辨識與理解、互動學習、人工智慧和機構設計……等，因此如何以創新技術降低成本將是機器人發展的關鍵。人與機器人間的互動主要是透過電腦運作，在電腦普及化下的今天，使用者與電腦間的溝通方式不外乎是鍵盤、滑鼠和筆……等，這種互動方式相較於人與人之間的溝通模式當然不夠自然，然而手勢在人類生活中的使用確實很頻繁，如果能利用手勢在人與電腦間做一個溝通橋樑的話，應該可以使人與電腦間達到一個自然的互動，當中以影像辨識技術為基礎的手勢介面吸引許多人的注意，因為這方式並不需要配戴任何感測元件，就可以達到人與機器人間的互動。

隨著時代的進步，手勢辨識的應用範圍越來越廣泛，在手勢辨識的領域當中，已經有相當多的相關文獻在這方面做探討，不論是醫學上的應用或人機介面上的互動，這些發展的目的就是讓人與機器的互動上能夠更自然、更便利的操作。目前在手勢辨識的研究文獻中，主要分為應用資料手套方式[1-3]、應用視覺方式兩個較具代表性，雖然資料手套可以精確判斷出手指的變動，但是因為需要戴感測器手套，會有成本較高與便利較低的缺點。視覺式手勢辨識是經由攝影機或相機拍攝影像，運用影像辨識達到了解手勢的語意，其優點為開發成本低、操作便利，在視覺式手勢辨識的相關文獻與技術上，可分區分為兩類，一類以建立模型為基礎的方法[4-10]，此方法是先找出手勢特徵做為辨識的依據，再以先前的模型樣本做比對以完成辨識，因為常常使用3D影像資訊或較為複雜的公式，一般而言其計算量較為龐大，難以做到即時處理；另一類以外觀輪廓資訊為基礎的方法[11-14]，其方式是先取得手勢區域的影像，在影像區域內取出手勢的輪廓，根據其手勢輪廓的特徵進行辨識，在相關的文獻中有以手形輪廓掃描方式[15-17]找出手勢的手指數並判斷出其手勢的語意，由於此類方法的計算

量較低，所以為目前最常用的手勢辨識方法。

所以在本論文應用中，因為不需要精確的手勢資訊，兼具成本與操作便利性上的考量，不考慮應用資料手套的方式，而採用視覺式手勢辨識中的以外觀輪廓資訊為基礎的方法，先經過影像處理找到手勢的影像區域，再以手形輪廓掃描的方式取得手勢的特徵，並透過倒傳遞類神經網路來訓練與驗證手勢特徵，期望利用此智慧型辨識法則達到人與機器互動的功能。

1.3 本文架構

本篇論文共分為五個章節，分別為緒論、手勢影像處理、智慧型手勢辨識、實驗結果、結論與未來展望。第一章為緒論，簡單扼要說明本論文的研究動機與目的、文獻回顧和本文架構。第二章為手勢影像處理，主要說明利用影像處理的流程獲得手勢的影像，利用手形輪廓掃描的方式取得手勢的特徵。第三章為智慧型手勢辨識，精簡介紹倒傳遞類神經網路原理，以及設計倒傳遞類神經網路參數來訓練手勢的特徵。第四章為實驗結果，即樣本經過倒傳遞類神經網路測試後，輸出實驗數據並討論其實驗結果。第五章為結論與未來展望。

第二章 手勢影像處理

2.1 手形輪廓掃描

在手勢辨識的領域中，已經有許多相關的文獻加以探討，隨著科技日新月異，手勢辨識的應用範圍也越來越廣泛，讓人類在使用機器上能夠更便利。手形辨識的方法主要區分為使用資料手套或使用拍攝的影像作處理，兩者間的差異主要是成本上的考量，雖然資料手套可以精確的判斷出手指的變動，然而成本相對較高，本論文在成本考量下不使用資料手套，而以手勢影像處理的方式來做手勢辨識，影像處理的方式將以文獻[18]為基礎，擷取各種手勢的特徵，其方式是利用手形輪廓掃描的方式[15][17][19-23]，從手勢的重心點計算延伸往外到相切手指的距離。

經由影像處理擷取到手勢影像後，透過手形輪廓掃描的方式，先求出手勢重心的位置，並以此重心為圓心，每間隔角度1度來計算手掌外圍與手掌重心間的距離，如圖2.1所示，即可以繪出角度及距離的關係圖，如圖2.2所示，橫軸代表角度 ω ，縱軸代表手勢重心至手掌各點的距離 D 。將影像中非手指區域刪除掉，可以減少手勢辨識的干擾，其方法是在重心到手掌外圍與角度的圖中找出距離變化較平緩的範圍如圖2.2所示，並以此範圍的中心點 ω_q 為基準，可以將手分成手指區域及非手指區域兩部分，其中非手指區域為 $\omega_q - 90 < \omega < \omega_q + 90$ 。



圖2.1重心到手掌外圍示意圖

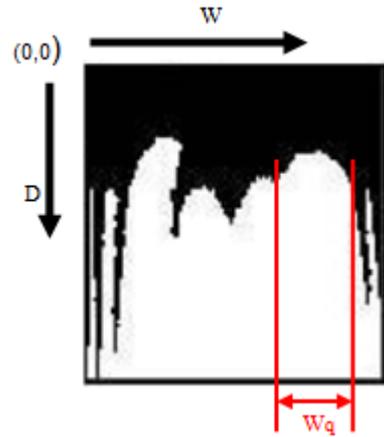


圖2.2重心到手掌外圍與角度示意圖

2.2 手勢影像擷取

影像處理的目的是把處理後的結果提供給圖形辨認做最有效的資料處理與分析，在本章節中將討論如何利用兩張影像擷取出手勢特徵，以利後續的影像辨識，要如何從外在複雜的環境下，順利把手勢的影像擷取出來當然非常重要。選取手勢影像的流程大致分為雜訊濾除、背景處理、膚色偵側、連通物件法和選取手勢特徵等五大步驟如圖 2.3 所示，其流程中的細項將分別在下面的章節做討論。

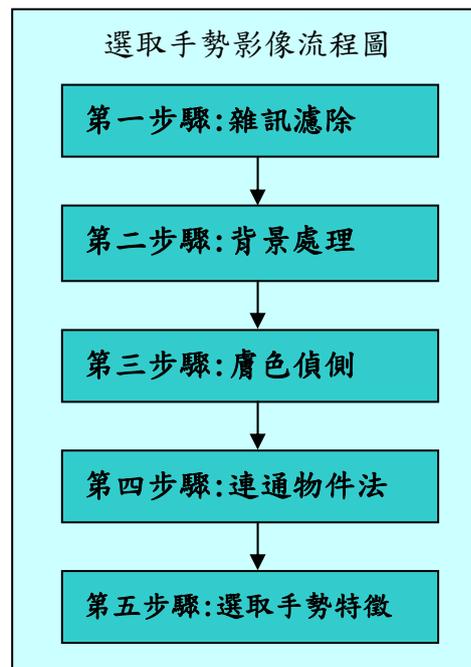


圖 2.3 選取手勢影像流程圖

選取手勢影像流程的第一步驟為雜訊濾除，因為經由數位照相機所取得的影像，常因周遭環境變化而受到高頻雜訊的干擾，造成影像品質的不良影響，所以必須使用濾波器加以處理。本論文將採用均值濾波器來抑制雜訊，空間濾波的方式如圖 2.4 中將影像中每一個像素點 (x, y) ，與此點為中心的八個相鄰的像素點一起取出，放置在預先設置的 3×3 遮罩中，計算出各像素點交互乘積之和，運算出新的計算值取代原像素點 (x, y) ，其公式如下所示：

$$Q(x, y) = \sum_{s=-a}^a \sum_{t=-b}^b w(s, t) f(x + s, y + t) \quad (2.1)$$

其中 $f(x + s, y + t)$ 代表遮罩底下影像部分像素，而 $w(s, t)$ 代表遮罩上的係數， $Q(x, y)$ 則為經過濾波器運算出的新像素點 (x, y) 。

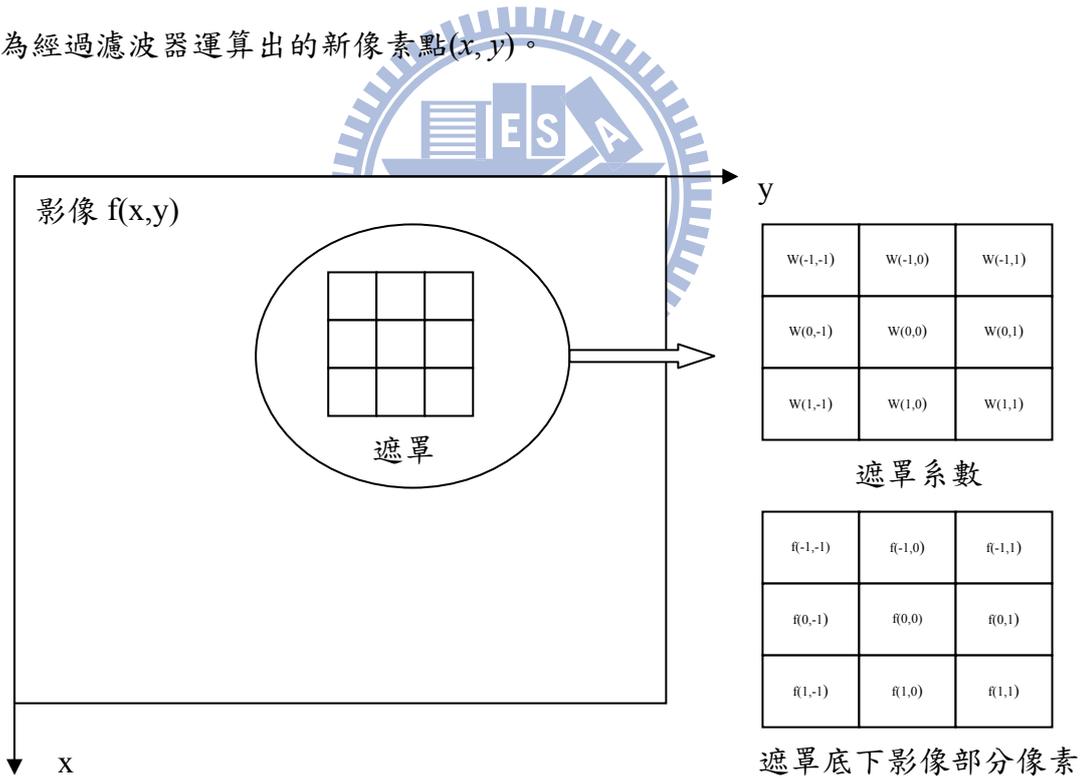


圖 2.4 空間濾波的方式

採用均值濾波器濾除高頻的雜訊干擾，將會使影像趨於平滑，並且達到去除高頻雜訊干擾的效果。

選取手勢影像流程的第二步驟為背景處理，目前影像處理在偵測移動物件的方面，主要有兩種方法，分別為連續影像相減法與背景相減法。

連續影像相減法是利用時間上連續的影像做一對一的pixel相減，若兩張影像的差異不為零，就表示此pixel為移動物件，反之，則不是移動物件。此方法對於環境的改變適應性佳，但是偵測出的移動物件常常會發生內部破碎的情形，對於後續移動物件的追蹤與辨識將無法提供較完整的資訊。

背景相減法會先建立一張背景影像，再將新影像與背景影像作一對一的pixel亮度值相減，偵測出完整的物件形狀，因此背景相減法不會有物件內部破碎的問題。

上述兩種方法中以背景相減法較受歡迎，其原因是除了可以擷取出物件的完整形狀外，對雜訊也有相對較好的容忍度，為了能在複雜環境中找出手勢的區域，本論文將採用最有效又簡單的方式，即是對影像做背景相減的動作。

其原理是在複雜的環境中取得一張背景影像 IMG_{back} 為基準，將每次取得的新影像 IMG_{now} 與背景 IMG_{back} 做比較，從中擷取出影像中手勢變動的區域，如公式(3-1)所示，其中 Y_{th} 、 Cb_{th} 、 Cr_{th} 分別為 Y、Cb 和 C_r 的門檻值， $IMG_{back}^Y(x,y)$ 、 $IMG_{back}^{Cb}(x,y)$ 、 $IMG_{back}^{Cr}(x,y)$ 分別為背景影像中每個 pixel 的 Y(亮度)、Cb(藍色彩度)、 C_r (紅色彩度)值， $IMG_{now}^Y(x,y)$ 、 $IMG_{now}^{Cb}(x,y)$ 、 $IMG_{now}^{Cr}(x,y)$ 分別為影像中每個 pixel 的 Y、Cb、 C_r 值， $IMG_C(x,y)$ 為影像相減後的 pixel，當 $IMG_C(x,y) = 1$ 時代表此 pixel 與背景影像相異，就可以擷取影像中手變化的區域。

$$IMG_C = \begin{cases} 0, & \text{if } IMG_{now}^Y(x,y) - IMG_{back}^Y(x,y) < Y_{th} \\ & \text{and } IMG_{now}^{Cb}(x,y) - IMG_{back}^{Cb}(x,y) < Cb_{th} \\ & \text{and } IMG_{now}^{Cr}(x,y) - IMG_{back}^{Cr}(x,y) < Cr_{th} \\ 1, & \text{others} \end{cases} \quad (2-2)$$

在複雜的環境中，為了讓影像不受外在亮度變化的影響，將代表亮度 Y 的因素移除，公式 2-2 改寫成公式 2-3，為了能在背景複雜的影像中，可以有效的擷取手勢的影像，再將公式 2-3 改寫成公式 2-4，在本論文中設定的門檻值為 $Cb_{th} = Cr_{th} = 8$ 。

$$IMG_c = \begin{cases} 0, & \text{if } IMG_{now}^{C_b}(x, y) - IMG_{back}^{C_b}(x, y) < Cb_{th} \\ & \text{and } IMG_{now}^{C_r}(x, y) - IMG_{back}^{C_r}(x, y) < Cr_{th} \\ 1, & \text{others} \end{cases} \quad (2-3)$$

$$IMG_c = \begin{cases} 0, & \text{if } IMG_{now}^{C_b}(x, y) - IMG_{back}^{C_b}(x, y) < Cb_{th} \\ & \text{or } IMG_{now}^{C_r}(x, y) - IMG_{back}^{C_r}(x, y) < Cr_{th} \\ 1, & \text{others} \end{cases} \quad (2-4)$$

圖 2.5/圖 2.6/圖 2.7/圖 2.8 分別為背景影像、目前影像、背景相減後的影像和背景相減後再經過濾波的影像。在第二步驟的背景處理中，經過背景相減後的影像會有不必要的雜訊存在，所以會再次利用均值濾波器濾除雜訊如圖 2.7 所示，圖 2.8 可以知道除了有手勢的影像外，還有一部分頭部的影像，因為在拍攝的過程中，頭部難免會有些微的移動，所以在往後的章節中將會對這部分做處理。



圖 2.5 背景影像

圖 2.6 目前影像

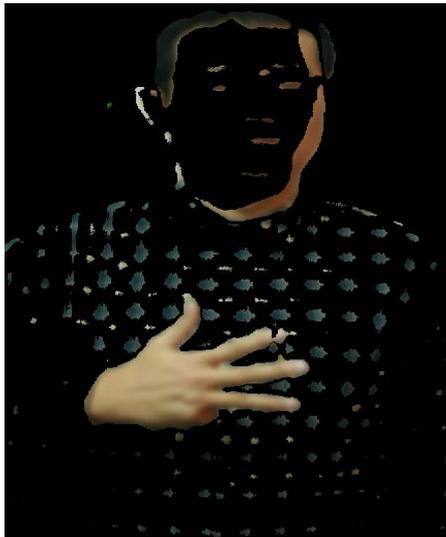


圖 2.7 背景相減後的影像

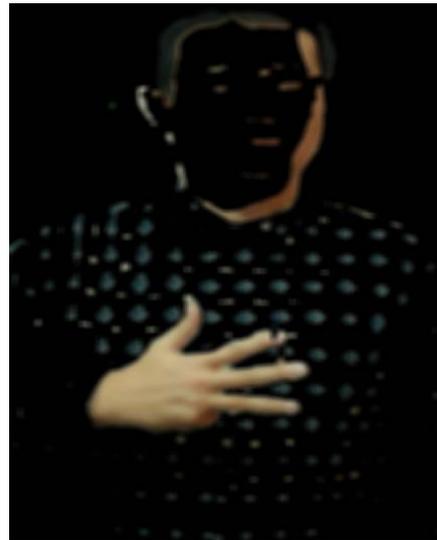


圖 2.8 背景相減後再經過濾波的影像

選取手勢影像流程的第三步驟為膚色偵測，由於人種、攝影器材、環境光線等種種因素上的差異，膚色也會有所不同，所以膚色必須隨著應用而個別定義才能滿足需求，經過比較膚色偵測技術後[24]，發現膚色偵測必須考慮到三個問題，分別是如何選擇色彩空間、如何分類膚色群和非膚色群以及如何分割或處理分類後的膚色群，在本論文中選擇 YC_bC_r 作為膚色偵測的色彩空間，其主要原因是膚色分布在 YC_bC_r 上有不錯的集中效果而且能減少顏色對外在環境亮度的影響，其中 Y 為亮度， C_b 為藍色彩度， C_r 為紅色彩度， YC_bC_r 對亮度的分離性高，可以與彩度分開操作，適合將其使用於膚色偵測。

決定了色彩空間之後，就要決定採取何種方法來分類膚色像素和非膚色像素，其中最簡單的方式是利用 C_b 、 C_r 的數據來決定一個門檻值，因此將採用 Douglas Chai [25] 所提出膚色偵測的範圍 ($77 < C_b < 127, 133 < C_r < 173$) 來決定單一像素之 C_b 、 C_r 是否屬於膚色或非膚色群組，如式(2-5)所示 $IMG_S(x,y)$ 為經過膚色偵測後的影像， $IMG_C^r(x,y)$ 、 $IMG_C^b(x,y)$ 分別為經過影像相減後的pixel。

$$IMG_S = \begin{cases} 1, & \text{if } 77 < IMG_C^b(x,y) < 127 \\ & \text{and } 133 < IMG_C^r(x,y) < 173 \\ 0, & \text{others} \end{cases} \quad (2-5)$$

圖2.9/圖2.10分別為背景相減後再經過濾波的影像和膚色偵測後的影像，圖2.10中除了完整的手勢影像外，另外還有因為頭部移動所造成的影像。

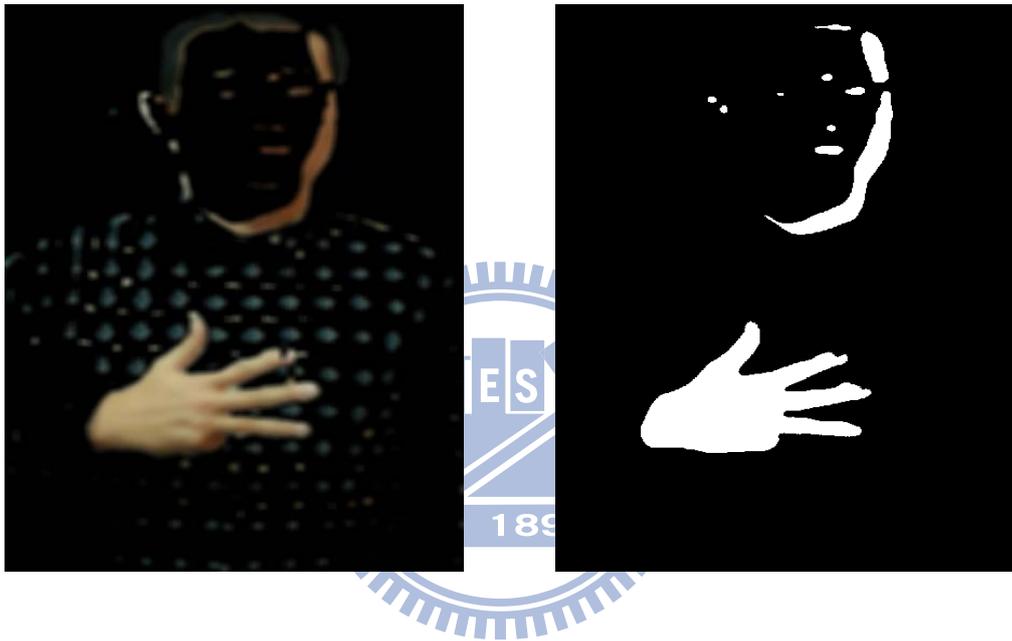


圖 2.9 背景相減後再經過濾波的影像

圖 2.10 膚色偵測後的影像

選取手勢影像流程的第四步驟為使用連通物件法，因為經過膚色偵測後，頭部移動所造成較大的雜訊影像仍舊存在，所以必須消除掉，否則將會影響後續手勢特徵的擷取，本論文將採用連通物件法來擷取手勢的影像，連通物件法的原理是將影像中的區塊給予編號，彼此以四鄰接方式將相互連接的像素點給予相同的編號，不同的物件將有不同的編號，且相連通區域的像素將給予相同的編號，下面將以四鄰接的連通物件法來敘述。

IMG_C 表示於 $A5$ 點像素的編號如圖2.11所示，一開始以由上至下、由左至右的方式掃描影像中的每個點，當 $A5 = 0$ （像素點沒有值）時將不給予編號，反之當 $A5 = 1$

(像素點有值)時則判斷點A5的上方點A2及左方點A4的狀態，有下列五種判斷如下所示：

- (1) 當 $A2 = 0$ 、 $A4 = 0$ 時，則給予 IMG_C 新的編號。
- (2) 當 $A2 = 1$ 、 $A4 = 0$ 時，則 $IMG_C = IMG(A2)$ 。
- (3) 當 $A2 = 0$ 、 $A4 = 1$ 時，則 $IMG_C = IMG(A4)$ 。
- (4) 當 $A2 = 1$ 、 $A4 = 1$ 時，若 $IMG(A2) = IMG(A4)$ ，則 $IMG_C = IMG(A2)$ 或 $IMG_C = IMG(A4)$ 。
- (5) 當 $A2 = 1$ 、 $A4 = 1$ 時，若 $IMG(A2) \neq IMG(A4)$ ，則 $IMG_C = IMG(A2)$ ，並將 $IMG(A5)$ 及 $IMG(A4)$ 設為同一個集合。

A1	A2	A3
A4	A5	A6
A7	A8	A9

圖 2.11 影像元素

經過連通物件法演算後，會把影像中每個物件建立好編號，並會統計出各個物件編號在影像中占多少像素數量，再從中比較各個物件的像素數量保留像素數量最大的物件。如此就可以去除較大的雜訊影像而取出需要的手勢影像主體如圖2.12所示。



圖2.12 經過連通物件法所得的影像

選取手勢影像流程的第五步驟為選取手勢特徵，在獲得手勢影像後，將求出其手部重心的位置，並以此重心為圓心，用手形輪廓掃描的方式，從0度到360度掃描整張影像，如圖2.13所示，角度由0度開始增加(每K度為一個間隔)，若掃描到手部則記錄此間隔的角度及重心到手部的距離(單位像素)，有手部區塊就表示已找到手部的輪廓，接著繼續對下一個間隔做掃描，最後產生出以手部重心為圓心，角度與重心到手部輪廓的距離關係圖，如圖2.14所示(設K=6)。在角度距離曲線圖中找出距離變化較平緩的區域，將非手指的資料刪除如圖2.15所示。

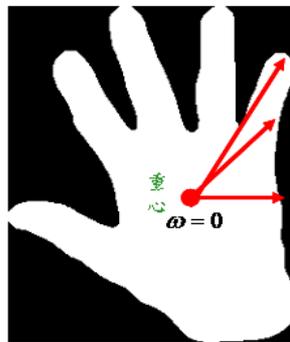


圖 2.13 手勢輪廓掃描

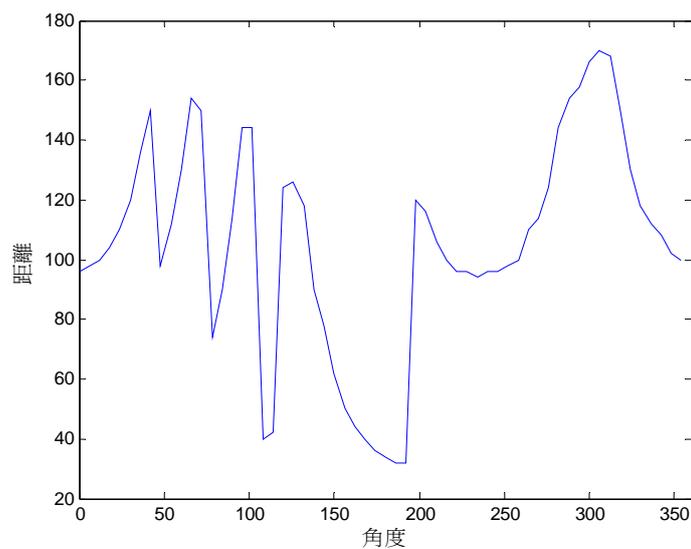


圖2.14角度距離曲線圖

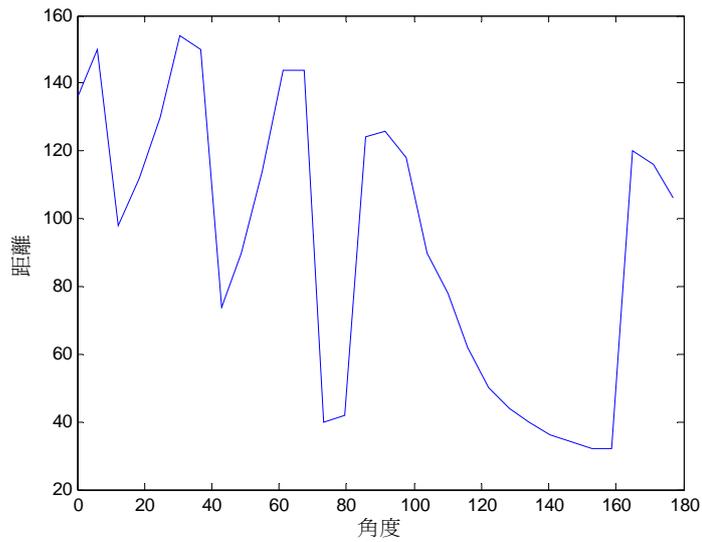


圖2.15角度距離曲線圖(去掉非手指的資料)

最後必須對手勢特徵作正常化處理，因為在拍攝手勢的過程中，因為擺放手的位置與角度的不同，造成手勢影像的大小不同，將手勢特徵作正常化處理可以改善這問題，其作法是將手勢特徵全部乘以一個倍率（倍率=250/最大值），使手勢特徵的最大值為250，如圖2.16所示。

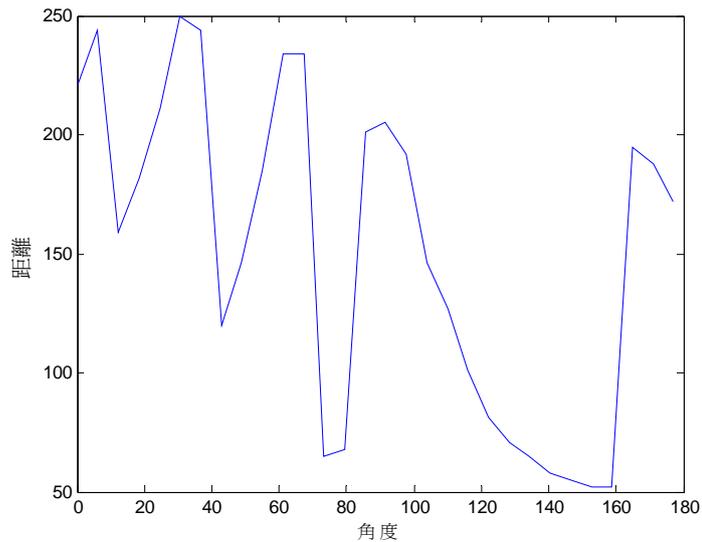


圖2.16對手勢特徵作正常化處理

第三章 智慧型手勢辨識

3.1 倒傳遞類神經網路

在類神經網路發展的初期，主要的目的是為了模擬人腦中神經元的工作模式，人腦的重要部分包括神經元、胞突連接、樹狀突和軸突，其中神經元（Neuron）為主要的處理單元，負責蒐集訊號並決定如何處理，胞突連接（Synapses）為神經元間訊號傳遞的连接點，樹狀突（Dendrites）為樹狀傳遞線負責接受其它神經元的訊號，軸突（Axon）主要為傳遞介質負責將訊號傳至其他神經元的樹狀突，其神經元結構的簡圖如圖 3.1 所示。

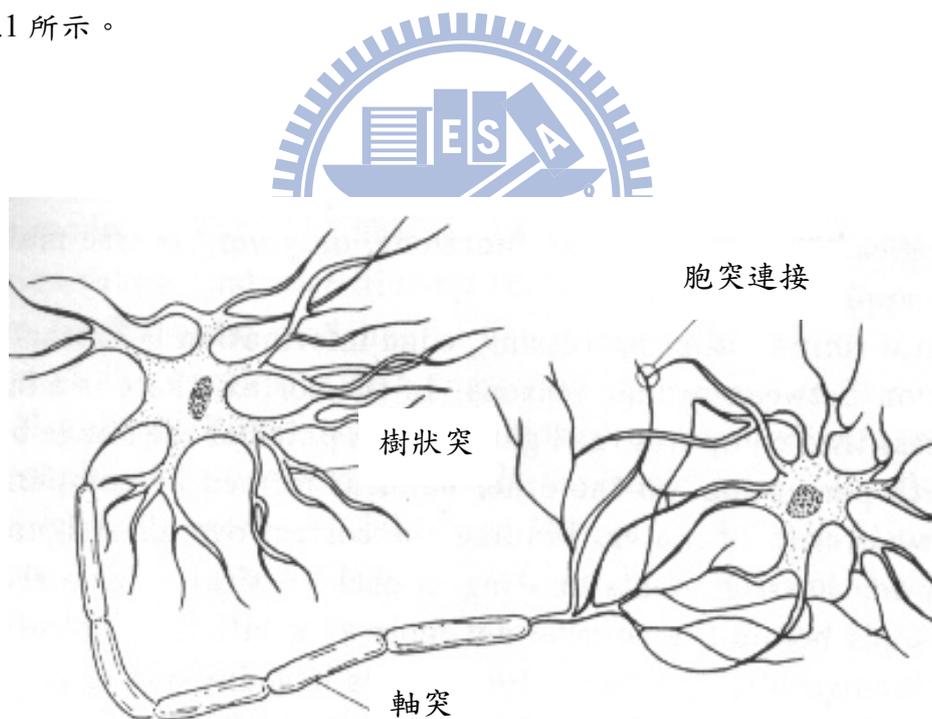


圖 3.1 神經元結構的簡圖

類神經網路為了模仿人腦神經元的工作，其神經元模式被設計如圖 3.2 所示，由圖可知神經元先將輸入各自乘上一個連接權值，再將所有的乘積加總，最後由活化函數決定臨界值是否被輸出。

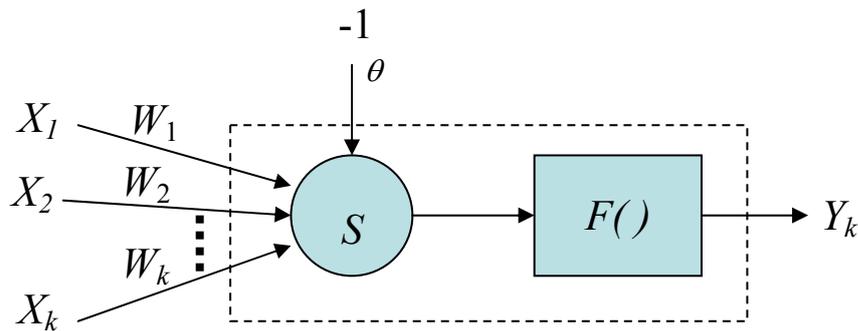


圖 3.2 單一神經元模式

X ：稱為輸入層神經元的輸入。

W ：稱為鍵結值。

θ ：稱為閾值，有偏移的效果。

S ：稱為加法單元，將每一個輸入與鍵結值相乘後做一加總的動作。

$F()$ ：稱為活化函數，通常是非線性函數，其目的是將 S 的值做映射得到所需要的輸出。

Y_k ：稱為輸出層神經元的輸出，即所需要的結果。

類神經網路的訓練就是在調整鍵結值，使其變得更大或是更小，通常由隨機的方式產生介於 +1 到 -1 之間的初始值。鍵結值可視為一種加權效果，其值越大則代表連結的神經元越容易被激發。

類神經網路基本概念在於模擬人類神經元，其網路有許多非線性的運算單元組成，運作方式如同大腦，在已知的實例資料、歷史資料中學習，獲取並累積經驗、儲存知識，並利用非線性函數的轉換，建立獨特的學習網路，可以對大量的資料進行分析，目前類神經網路的種類及理論快速發展，並且被廣泛應用在各實務面上，常用類神經網路包括倒傳遞類神經網路、輻狀基底函數類神經網路、自組性類神經網路、回饋式類神經網路、模糊集合與模糊邏輯系統等。其中倒傳遞網路在訓練的階段中以調整網路輸出值與目標值為一致，完成輸入資料與輸出資料之間的映射關係，在本論文

中主要是以第二章影像處理後所取得的手勢特徵，利用倒傳遞類神經網路來訓練，利用其基本原理最陡坡降法（The Gradient Steepest Descent Method）的觀念，將誤差函數最小化，使網路誤差可以達到理想目標，其運作過程分別包含訓練和驗證兩階段，首先為訓練階段，其目的是將輸入向量與對應的輸出向量的訓練資料輸入至類神經網路中，得到推論的輸出值與理想輸出值間的誤差，以最陡坡降法計算出應調整之權重值，並利用疊代方式做調整，使兩者間均方誤差達到最小值，最後達到收斂的準確度指標，此階段通常是以一次一個訓練範例的方式進行，直到學習完所有訓練範例。而驗證階段的目的是將訓練階段所訓練出的目標權重值輸入類神經網路中，經由目標權重計算出最佳的估測輸出。

訓練與驗證階段的簡要步驟如下：

訓練階段：

1. 選取類神經網路輸入層、隱藏層、輸出層的神經元數目與訓練樣本數目。
2. 做參數初始化，以隨機亂數方式產生各層間的連接加權值向量矩陣 W_{ij} 、 W_{jk} 與偏權值向量矩陣 θ_j 、 θ_k 。
3. 輸入訓練樣本(包含輸入向量 x_i 及目標輸出向量 T_k)。
4. 計算出隱藏層及輸出層的輸出向量。

(1) 隱藏層輸出向量 H_j ，其數學式如(3-1)：

$$\begin{aligned} net_j &= \sum W_{ij} x_i - \theta_j \\ H_j &= f(net_j) \end{aligned} \quad (3-1)$$

將輸入資料至隱藏層的數據作統合計算所得到的隱藏層第 j 個神經元的加權乘積和，再代入所選用的活化函數中計算得到 H_j ，即為隱藏層第 j 個神經元的輸出值。

(2) 輸出層輸出向量 Y_k ，其數學式如(3-2)：

$$\begin{aligned} net_k &= \sum W_{jk} H_j - \theta_k \\ Y_k &= f(net_k) \end{aligned} \quad (3-2)$$

以隱藏層的輸出作為輸入輸出層第 k 個神經元做加權乘積，再代入所選用的

活化函數，推論出輸出值 Y_k 。

5. 計算誤差量大小。

(1) 輸出層第 k 個神經元的誤差量 δ_k ：

$$\delta_k = (T_k - Y_k) \cdot f'(net_k) = (T_k - Y_k)(Y_k)(1 - Y_k) \quad (3-3)$$

其中 δ_k 為輸出層第 k 個神經元的誤差量，而 $(T_k - Y_k)$ 為目標輸出與推論輸出的誤差量。

(2) 隱藏層第 k 個神經元的誤差量 δ_{hj} ：

$$\delta_{hj} = \left(\sum \delta_{hj} W_{jk} \right) \cdot f'(net_k) = \left(\sum \delta_{hj} W_{jk} \right) \cdot H_j (1 - H_j) \quad (3-4)$$

6. 做輸出層與隱藏層的權重和偏權重的修正。

(1) 輸出層權重和偏權值修正：

$$\begin{aligned} \Delta W_{jk} &= \eta \cdot \delta_k \cdot H_j \\ \Delta \theta_k &= -\eta \cdot \delta_k \\ W'_{jk} &= W_{jk} + \Delta W_{jk} \end{aligned} \quad (3-5)$$

其中 ΔW_{jk} 、 $\Delta \theta_k$ 分別為輸出層與隱藏層間的權重和偏權值修正的值，而 η 為學習速率。

(2) 隱藏層權重和偏權值修正：

$$\begin{aligned} \Delta W_{jk} &= \eta \cdot \delta_k \cdot H_j \\ \Delta \theta_k &= -\eta \cdot \delta_k \\ W'_{jk} &= W_{jk} + \Delta W_{jk} \end{aligned} \quad (3-6)$$

驗證階段：

驗證過程其步驟如下：

1. 選取類神經網路輸入層、隱藏層、輸出層的神經元數目。
2. 在類神經網路中代入訓練階段所得的加權值向量矩陣與偏權值向量矩陣。
3. 輸入測試樣本。
4. 計算出類神經網路的推論輸出向量。

3.1.1 倒傳遞類神經相關理論

倒傳遞類神經網路的基本架構包括輸入層、隱藏層和輸出層，其中隱藏層與外界資訊隔離，只透過輸入層與輸出層作為對外的介面，用來表現輸入單元間的交互影響，網路可以不只一層隱藏層，也可以沒有隱藏層，視問題的複雜程度而決定其網路架構，如圖 3.3 所示為倒傳遞網路模型。

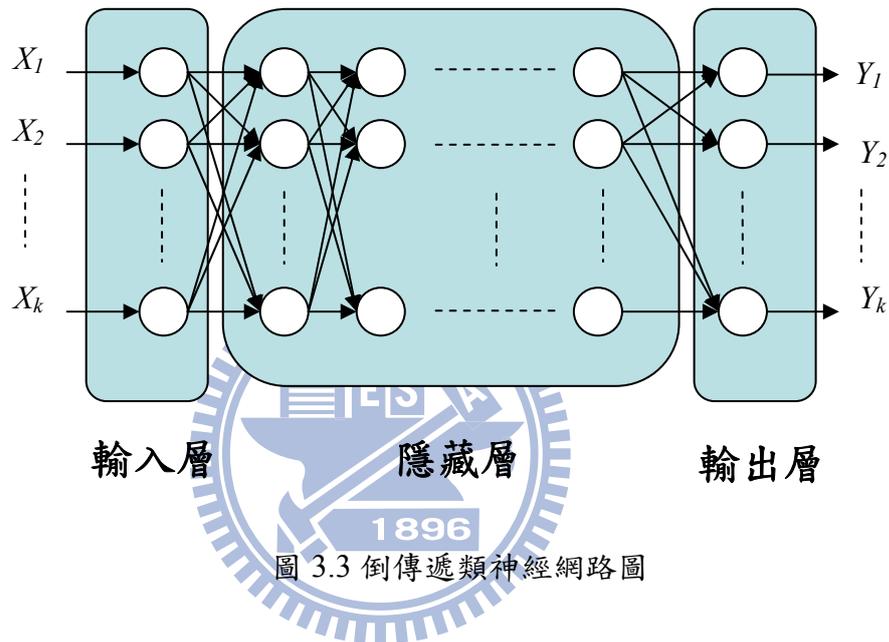


圖 3.3 倒傳遞類神經網路圖

輸入層代表網路的輸入變數，其處理單元的數目則依據處理問題的狀態來決定，隱藏層代表輸入處理單元間的交互影響，處理單元的數目沒有標準的方式可以做依據，通常需要以試驗的方式來決定最佳的數目，輸出層代表網路的輸出變數，其處理單元的數目則依據處理問題的狀態來決定。

在隱藏層中的處理單元數目越多，收斂速度越慢，可以達到更小的誤差值，但是隱藏層處理單元數目太多只會增加執行的負擔與時間，並不一定會降低測試樣本的誤差。處理單元數目太少，不足以反應輸入變數間的交互作用，會有較大的誤差值。一般決定隱藏層單元數目的選取可依實驗測試找出，或依照問題的複雜程度可大略決定，問題複雜性高，隱藏層處理單元數目宜多；測試樣本的誤差遠高於訓練樣本的誤差，隱藏層單元的數目宜減少。

類神經網路的運算過程中，其活化函數可以控制輸出單元的結果，可以利用數學公式(3-7)描述活化函數與神經元的關係：

$$u_j = \sum_{i=1}^p w_{ji} x_i \quad (3-7)$$

$$y_j = f(u_j - \theta_j)$$

其中 w_{ji} 代表第 i 維輸入至第 j 個神經元的鍵結值， θ_j 代表神經元所需觸發的閾值， $x_i = (x_1, x_2, \dots, x_m)^T$ 代表 m 維的輸入， u_j 為加總後整體的輸入量， y_j 則代表神經元的輸出值。

一般類神經網路常用非線性函數作為活化函數，其常用的活化函數有嚴格限制函數、區域線性函數、對數雙彎曲函數、正切雙彎曲函數和高斯函數，其數學表示式如下所示：

(1) 嚴格限制函數：

$$f(n) = \begin{cases} 1 & \text{if } n \geq 0 \\ 0 & \text{if } n < 0 \end{cases} \quad (3-8)$$

(2) 飽和線性函數：

$$f(n) = \begin{cases} 1 & n > 1 \\ n & 0 \leq n \leq 1 \\ 0 & n < 0 \end{cases} \quad (3-9)$$

(3) 對數雙彎曲函數：

$$f(n) = \frac{1}{1 + e^{-n}} \quad (3-10)$$

(4) 正切雙彎曲函數：

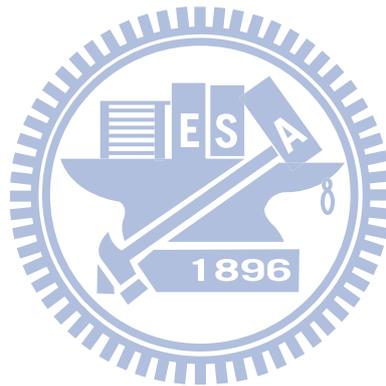
$$f(n) = \frac{e^n - e^{-n}}{e^n + e^{-n}} \quad (3-11)$$

(5)高斯函數：

$$f(n) = \exp\left(-\frac{n^2}{2\sigma^2}\right) \quad (3-12)$$

其中正切雙彎曲函數能根據輸入的不同而有不同的輸出，且將輸出限制在 0 到 1 之間，一般類神經網路架構常採用此函數。

學習速率為類神經網路的設定參數，其目的是控制類神經網路學習速度的快慢，學習速率較大會使網路加權值有較大修正量，可以較快速度逼近函數最小值，但過大的學習速率會導致加權值過量修正，造成數值震盪，難以達到收斂的目的。一般經驗會取值在 0.1~1.0 之間，因此不同的問題與訓練樣本資料會導致學習速率可能低至 0.01 或高至 10 以上，所以學習速率的決定需要多次的嘗試，或採取自動調整學習速率的方式來處理。



3.2 手勢辨識法則

本論文將選用倒傳遞類神經網路做數字的手勢辨識，其辨識數字的實驗項目將分成兩部分，實驗I是利用倒傳遞類神經網路辨識數字由1至5，而實驗II則是利用倒傳遞類神經網路辨識數字由0至9。將藉由網路參數設定的差異來討論其辨識率、收斂次數與收斂時間，而網路參數修改的主要項目分別為改變活化函數、學習速率、隱藏層神經元個數與輸入層神經元個數。

實驗I-A為固定輸入層神經元個數為30、隱藏層神經元個數為60、輸出層神經元個數為3，改變學習速率為0.001、0.0002、0.00003，並且改變活化函數分別為對數雙彎曲函數、正切雙彎曲函數、飽和線性函數，觀察其辨識率、收斂次數與收斂時間如何變化，設定其性能目標為0.001，如表3.1所示（選用不同的活化函數）。

實驗I-A		數字1至5的辨識
輸入層神經元個數		30
隱藏層個數		60
輸出層神經元個數		3
編號	活化函數	學習速率參數 η
1	對數雙彎曲函數	0.001
2	正切雙彎曲函數	0.0002
3	飽和線性函數	0.00003

表3.1選用不同的活化函數

實驗I-B為固定輸入層神經元個數為30、隱藏層神經元個數為60、輸出層神經元個數為3、活化函數選用對數雙彎曲函數，只改變學習速率分別為0.003、0.001、0.0008，藉由改變學習速率觀察其辨識率、收斂次數與收斂時間如何變化，設定其性能目標為0.001，如表3.2所示（選用不同的學習速率）。

實驗I-B		數字1至5的辨識
輸入層神經元個數		30
隱藏層個數		60
輸出層神經元個數		3
活化函數		對數雙彎曲函數
編號	學習速率參數 η	
1	0.003	
2	0.001	
3	0.0008	

表3.2選用不同的學習速率

實驗I-C為固定輸入層神經元個數為30、輸出層神經元個數為3、學習速率為0.001、活化函數選用對數雙彎曲函數，只改變隱藏層神經元個數分別為30、60、90，觀察其辨識率、收斂次數與收斂時間如何變化，設定其性能目標為0.001，如表3.3所示（選用不同的隱藏層神經元個數）。

實驗I-C		數字1至5的辨識
輸入層神經元個數		30
輸出層神經元個數		3
學習速率參數 η		0.001
活化函數		對數雙彎曲函數
編號	隱藏層個數	
1	30	
2	60	
3	90	

表3.3選用不同的隱藏層神經元個數

輸入層神經元個數代表著手勢特徵的個數，即在360度中每K角度取樣一次，由重心到手勢外圍的距離，再去除非手指的區域，而手勢特徵個數等於 $m(m=360/2K)$ ，所以實驗I-D的網路參數設定會固定輸出層神經元個數為3、學習速率為0.001、活化函數選用對數雙彎曲函數，只改變輸入層神經元個數為30與隱藏層層數為30、輸入層神經元個數為60與隱藏層層數為60、輸入層神經元個數為90與隱藏層層數為90，設定其性能目標為0.001，如表3.4所示（選用不同的輸入層神經元個數）。

實驗I-D		數字1至5的辨識	
輸出層神經元個數		3	
學習速率參數 η		0.001	
活化函數		對數雙彎曲函數	
編號	輸入層神經元個數	隱藏層個數	
1	30	30	
2	60	60	
3	90	90	

表3.4選用不同的輸入層神經元個數

另外在倒傳遞類神經網路中輸出層將以3bit的方式代表數字1至5的目標輸出，所以位元數共有3位元，數字1的目標輸出為000、數字2的目標輸出為100、數字3的目標輸出為010、數字4的目標輸出為001、數字5的目標輸出為110，如表3.5所示。

數字	目標輸出位元
1	000
2	100
3	010
4	001
5	110

表3.5代表數字1至5目標輸出位元

實驗II-A則是利用倒傳遞類神經網路辨識數字由0至9，藉由之前數字由1至5的網路參數設定來討論其辨識率、收斂次數與收斂時間，選用的網路參數設定為輸入層神經元個數為30、隱藏層神經元個數為60、輸出層神經元個數為4、學習速率為0.001、活化函數選用對數雙彎曲函數，設定其性能目標為0.001，如表3.6所示。

實驗II-A		數字0至9的辨識
輸入層神經元個數		30
輸出層神經元個數		4
學習速率參數 η		0.001
活化函數		對數雙彎曲函數
編號	隱藏層個數	
1	60	
2	90	
3	120	
4	150	

表3.6數字0至9的參數設定

而在倒傳遞類神經網路中輸出層將以4bit的方式代表數字0至9的目標輸出，所以其位元數共有4位元，數字0的目標輸出為0000、數字1的目標輸出為1000、數字2的目標輸出為0100、數字3的目標輸出為0010、數字4的目標輸出為0001、數字5的目標輸出為1100、數字6的目標輸出為1010、數字7的目標輸出為1001、數字8的目標輸出為1110、數字9的目標輸出為1101，如表3.7所示。

數字	目標輸出位元	數字	目標輸出位元
0	0000	5	1100
1	1000	6	1010
2	0100	7	1001
3	0010	8	1110
4	0001	9	1101

表3.7代表數字0至9目標輸出位元

第四章 實驗結果

實驗 I 為利用倒傳遞類神經網路辨識數字由 1 至 5，本論文定義五種手勢分別代表數字由 1 至 5，如表 4.1 所示，由相機取得的每張影像大小為 1288x1936 像素，訓練樣本為 125 張，測試樣本為 25 張。

數字	1	2	3	4	5
手勢影像					
目標輸出	000	100	010	001	110

表 4.1 五種手勢的定義

實驗 I-A 為固定輸入層神經元個數為 30、隱藏層神經元個數為 60、輸出層神經元個數為 3、改變學習速率為 0.001、0.0002、0.00003，改變活化函數分別為對數雙彎曲函數、正切雙彎曲函數、飽和線性函數，設定其性能目標為 0.001，設定輸出層輸出數值大於 0.5 代表輸出位元為 1，反之，小於或等於 0.5 則代表輸出層輸出位元為 0，在規劃這實驗項目時，事先針對個別的活化函數來選用其最佳的學習速率，所以在實驗數據中知道其辨識率都可以達到 100%，如表 4.2 所示，但是從每次訓練時間上來鑑別，活化函數選用對數雙彎曲函數是較佳的，圖 4.1/4.2/4.3 分別代表實驗 I-A 編號 1、2、3 的訓練過程圖，從編號 2 的訓練過程圖中可以知道活化函數選用正切雙彎曲函數時，其收斂的曲線非常的差。

實驗I-A			數字1至5的辨識			
輸入層神經元個數			30			
隱藏層個數			60			
輸出層神經元個數			3			
編號	活化函數	學習速率參數 η	訓練次數	訓練時間(sec)	訓練時間(sec)/次	辨識率
1	對數雙彎曲函數	0.001	6902	59	0.00855	100%
2	正切雙彎曲函數	0.0002	21400	194	0.00907	100%
3	飽和線性函數	0.00003	23733	246	0.01037	100%

表4.2驗證與測試不同的活化函數

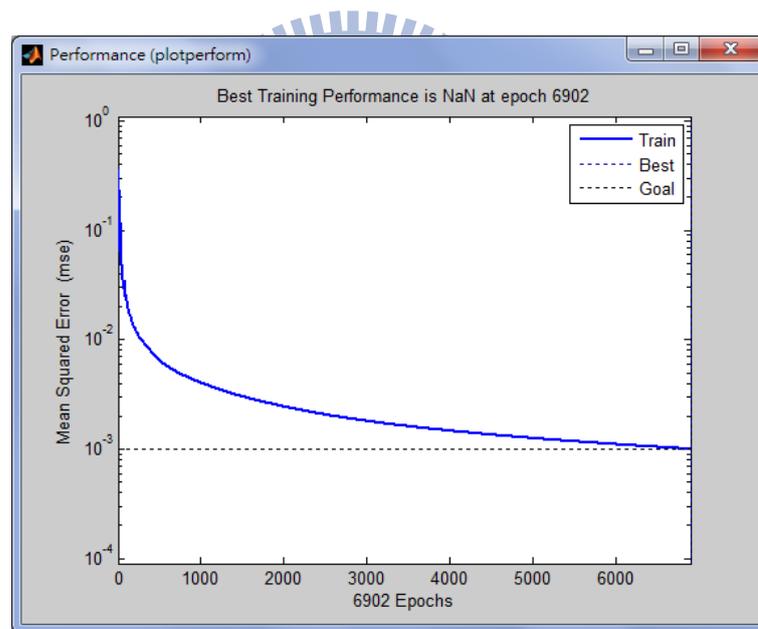


圖 4.1 實驗 I-A 編號 1 的訓練過程圖

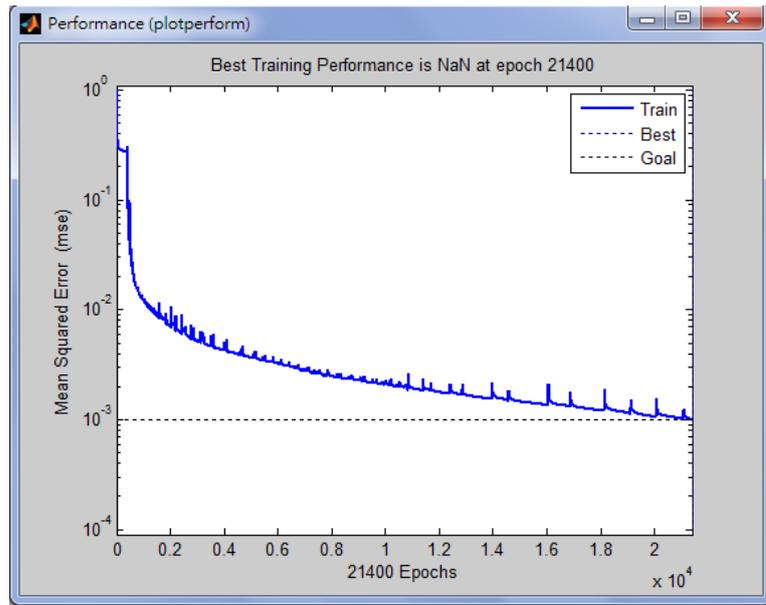


圖 4.2 實驗 I-A 編號 2 的訓練過程圖

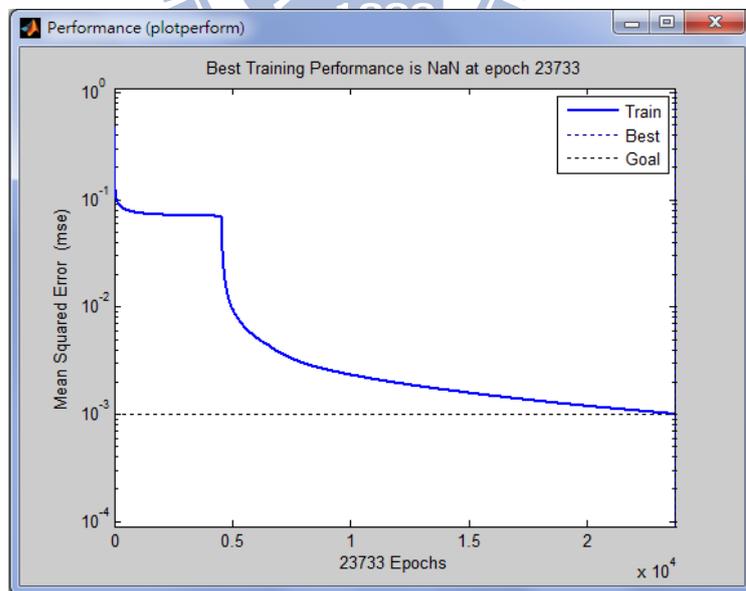


圖 4.3 實驗 I-A 編號 3 的訓練過程圖

實驗I-B為固定輸入層神經元個數為30、隱藏層神經元個數為60、輸出層神經元個數為3、活化函數選用對數雙彎曲函數，只改變學習速率分別為0.003、0.001、0.0008，設定其性能目標為0.001，設定輸出層輸出數值大於0.5代表輸出位元為1，反之小於或等於0.5則代表輸出層輸出位元為0，從表4.3中可得知，其辨識率都可以達到100%，學習速率在特定的範圍內如實驗編號2(輸入層神經元個數為30、隱藏層神經元個數為60、輸出層神經元個數為3、活化函數選用對數雙彎曲函數)的實驗數據，其訓練次數或每次訓練時間為最少，可以減少類神經網路在訓練階段的計算量或時間，如果學習速率超出特定的範圍，在整個訓練階段類神經網路是無法收斂的。

實驗I-B		數字1至5的辨識			
輸入層神經元個數		30			
隱藏層個數		60			
輸出層神經元個數		3			
活化函數		對數雙彎曲函數			
編號	學習速率參數 η	訓練次數	訓練時間(sec)	訓練時間(sec)/次	辨識率
1	0.003	12498	119	0.00952	100%
2	0.001	6902	59	0.00855	100%
3	0.0008	15184	147	0.00968	100%

表4.3驗證與測試不同的學習速率

圖4.4/4.5/4.6分別代表實驗I-B編號1、2、3的訓練過程圖，由圖中可知當學習速率在特定的範圍內會使其訓練曲線較快速收斂至性能目標。

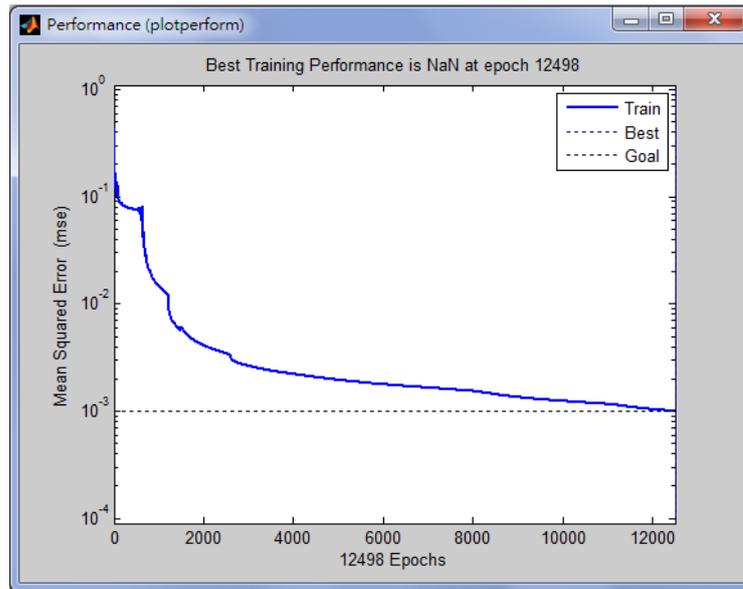


圖 4.4 實驗 I-B 編號 1 的訓練過程圖

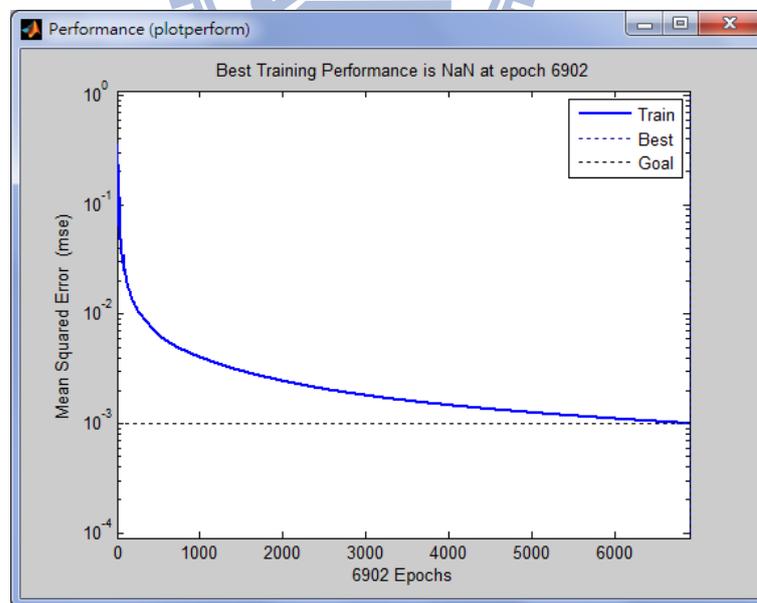


圖 4.5 實驗 I-B 編號 2 的訓練過程圖

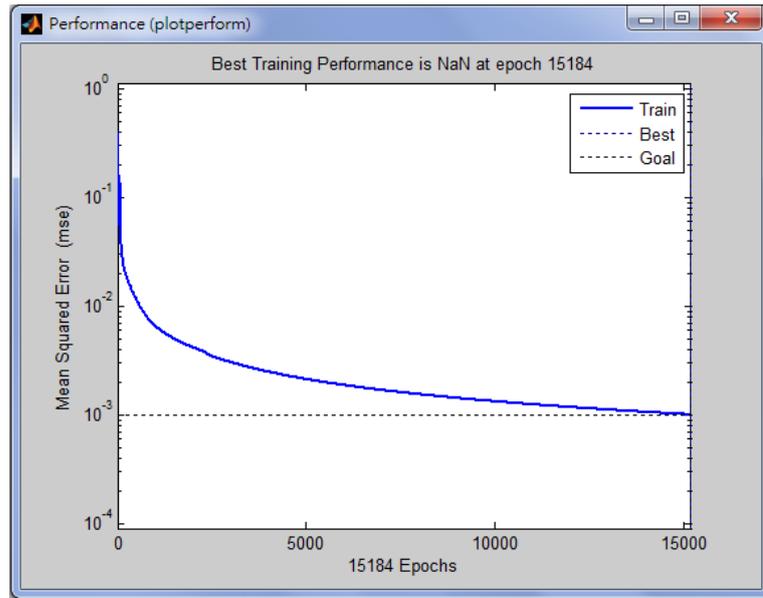


圖 4.6 實驗 I-B 編號 3 的訓練過程圖

實驗 I-C 為固定輸入層神經元個數為 30、輸出層神經元個數為 3、學習速率為 0.001、活化函數選用對數雙彎曲函數，只改變隱藏層神經元個數分別為 30、60、90，設定其性能目標為 0.001，設定輸出層輸出數值大於 0.5 代表輸出位元為 1，反之小於或等於 0.5 則代表輸出層輸出位元為 0，從表 4.4 中發現其實驗數據逐次增加隱藏層神經元個數從 30 到 90 個，其訓練次數會逐漸減少，但是其辨識率並沒有因為增加隱藏層神經元個數而增加，其辨識率維持在 100%，當增加隱藏層神經元個數時，雖然訓練次數會逐漸減少，但是會增加類神經網路的計算量或每次訓練時間，不利於電腦即時處理，所以實驗編號 2 為辨識數字由 1 至 5 的最佳網路參數(輸入層神經元個數為 30、輸出層神經元個數為 3、學習速率為 0.001、活化函數選用對數雙彎曲函數)。

實驗I-C		數字1至5的辨識			
輸入層神經元個數		30			
輸出層神經元個數		3			
學習速率參數 η		0.001			
活化函數		對數雙彎曲函數			
編號	隱藏層個數	訓練次數	訓練時間(sec)	訓練時間(sec)/次	辨識率
1	30	17378	157	0.00903	100%
2	60	6902	59	0.00855	100%
3	90	6015	63	0.01047	100%

表4.4驗證與測試不同的隱藏層神經元個數

圖4.7/4.8/4.9分別代表實驗I-C編號1、2、3的訓練過程圖，由圖中可以知道當增加隱藏層神經元個數會使其訓練曲線較快速收斂至性能目標。

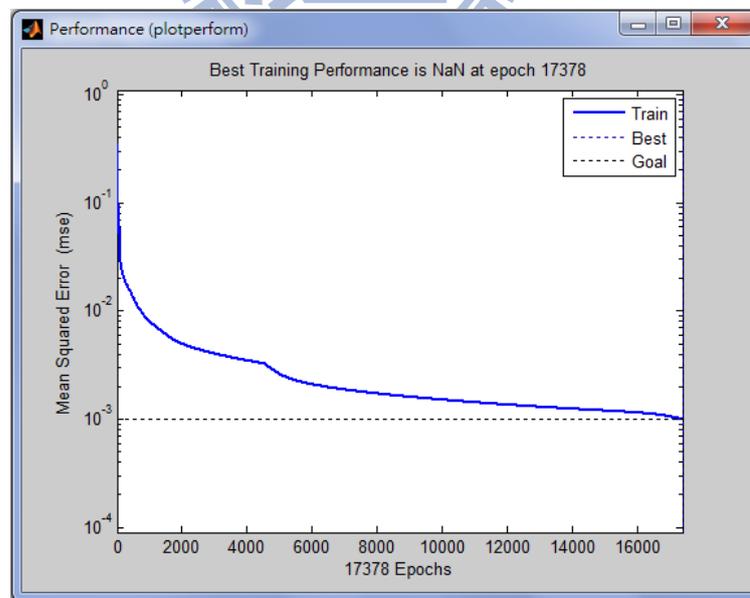


圖 4.7 實驗 I-C 編號 1 的訓練過程圖

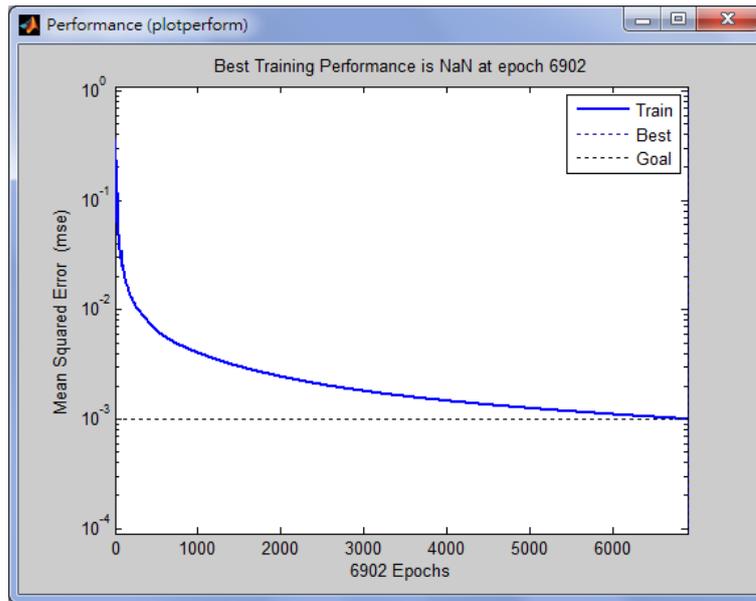


圖 4.8 實驗 I-C 編號 2 的訓練過程圖

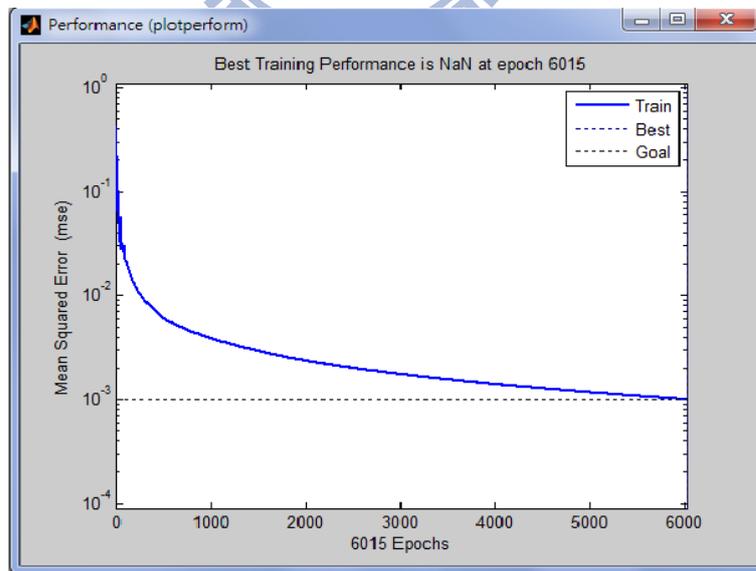


圖 4.9 實驗 I-C 編號 3 的訓練過程圖

實驗I-D為固定輸出層神經元個數為3、學習速率為0.001、活化函數選用對數雙彎曲函數，只改變輸入層神經元個數為30與隱藏層層數為30、輸入層神經元個數為60與隱藏層層數為60、輸入層神經元個數為90與隱藏層層數為90，設定其性能目標為0.001，設定輸出層輸出數值大於0.5代表輸出位元為1，反之，小於或等於0.5則代表輸出層輸出位元為0，從表4.5內的實驗數據中發現逐次增加輸入層神經元個數與隱藏層神經元個數從30到90個，其訓練次數會逐漸減少，但是發現其辨識率並沒有因為輸入層神經元個數與隱藏層神經元個數增加而增加，其辨識率維持在100%，另外當增加輸入層神經元個數與隱藏層神經元個數時，雖然訓練次數會逐漸減少，但是會增加影像處理與類神經網路的計算量或每次訓練時間，不利於電腦即時處理。

實驗I-D			數字1至5的辨識			
輸出層神經元個數			3			
學習速率參數 η			0.001			
活化函數			對數雙彎曲函數			
編號	輸入層神經元個數	隱藏層個數	訓練次數	訓練時間(sec)	訓練時間(sec)/次	辨識率
1	30	30	17378	157	0.00903	100%
2	60	60	14759	144	0.00976	100%
3	90	90	9276	101	0.01089	100%

表4.5驗證與測試不同的輸入層神經元個數

圖4.10/4.11/4.12分別代表實驗I-D編號1、2、3的訓練過程圖，由圖中可以知道當增加輸入層神經元個數與隱藏層神經元個數會使其訓練曲線較快速收斂至性能目標，因而訓練次數會逐漸減少。

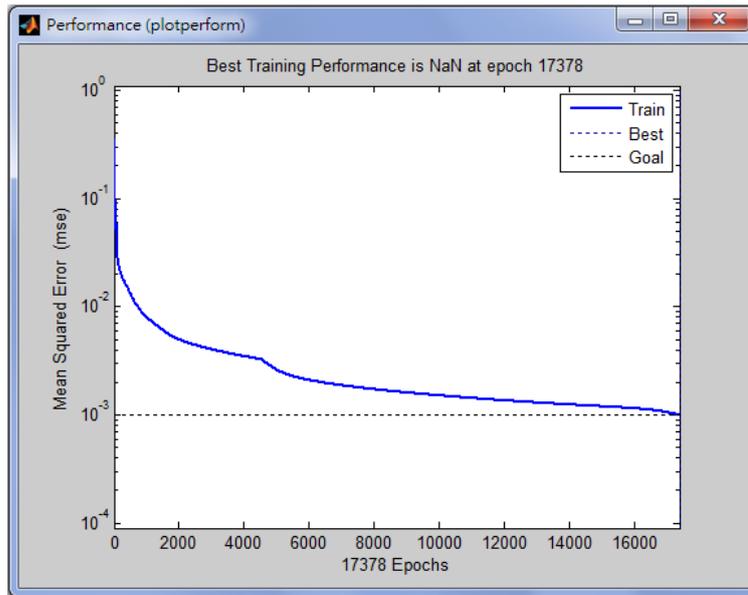


圖 4.10 實驗 I-D 編號 1 的訓練過程圖

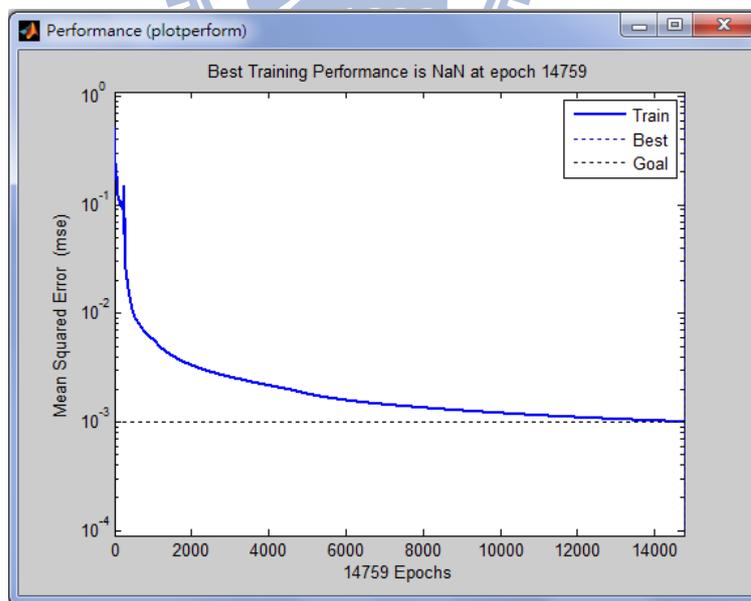


圖 4.11 實驗 I-D 編號 2 的訓練過程圖

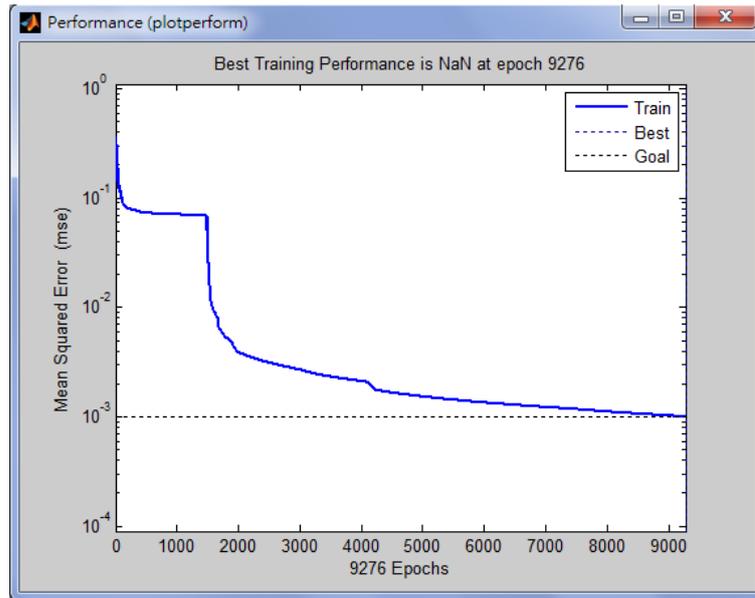


圖 4.12 實驗 I-D 編號 3 的訓練過程圖

實驗 II 為利用倒傳遞類神經網路辨識數字由 0 至 9，首先定義十種手勢分別代表數字由 0 至 9，如表 4.6 所示，由相機取得的每張影像大小為 1288 X 1936 像素，訓練樣本為 500 張，測試樣本為 50 張。

數字	0	1	2	3	4
手勢影像					
目標輸出	0000	1000	0100	0010	0001
數字	5	6	7	8	9
手勢影像					
目標輸出	1100	1010	1001	1110	1101

表 4.6 十種手勢的定義

實驗II-A為選用的網路參數設定為輸入層神經元個數為30、隱藏層神經元個數分別為60/90/120/150、輸出層神經元個數為4、學習速率為0.001、活化函數選用對數雙彎曲函數，設定其性能目標為0.001，設定輸出層輸出數值大於0.5代表輸出位元為1，反之，小於或等於0.5則代表輸出層輸出位元為0，從表4.7的實驗數據中發現逐次增加隱藏層神經元個數從60到120個，其訓練次數會逐漸減少，但是發現其辨識率並沒有跟著隱藏層神經元個數增加而增加，其辨識率維持在92~94%間，如表4.7所示。

實驗II-A		數字0至9的辨識			
輸入層神經元個數		30			
輸出層神經元個數		4			
學習速率參數 η		0.001			
活化函數		對數雙彎曲函數			
編號	隱藏層個數	訓練次數	訓練時間(sec)	訓練時間(sec)/次	辨識率
1	60	77124	1282	0.01662	92%
2	90	20884	428	0.02049	94%
3	120	14189	261	0.01839	92%
4	150	11719	248	0.02116	94%

表4.7驗證與測試數字0至9的參數設定 (1)

為了能提升其辨識率，所以實驗II-B是將網路參數設定為輸入層神經元個數為60、隱藏層神經元個數分別為60/120/180/240、輸出層神經元個數為4、學習速率為0.001、活化函數選用對數雙彎曲函數，設定其性能目標為0.001，設定輸出層輸出數值大於0.5代表輸出位元為1，反之，小於或等於0.5則代表輸出層輸出位元為0，從表4.8內的實驗數據中發現逐次增加隱藏層神經元個數從60到240個，其訓練次數會逐漸減少，每次訓練的時間會增加，辨識率會逐漸提高，但是發現當隱藏層神經元個數增加到240個時其辨識率不會跟著提高，如表4.8所示。

實驗II-B		數字0至9的辨識			
輸入層神經元個數		60			
輸出層神經元個數		4			
學習速率參數 η		0.001			
活化函數		對數雙彎曲函數			
編號	隱藏層個數	訓練次數	訓練時間(sec)	訓練時間(sec)/次	辨識率
1	60	24782	351	0.01416	88%
2	120	6151	123	0.02000	92%
3	180	3843	98	0.02550	94%
4	240	3416	104	0.03044	94%

表4.8驗證與測試數字0至9的參數設定 (2)

實驗II-C是將網路參數設定為輸入層神經元個數為90、隱藏層神經元個數分別為90/180/200、輸出層神經元個數為4、學習速率為0.001、活化函數選用對數雙彎曲函數，設定其性能目標為0.001，設定輸出層輸出數值大於0.5代表輸出位元為1，反之，小於或等於0.5則代表輸出層輸出位元為0，從表4.9內的實驗數據中發現逐次增加隱藏層神經元個數從90到200個，其訓練次數會逐漸減少，辨識率會逐漸提高，發現當隱藏層神經元個數增加到200個時其辨識率可以達到100%，如表4.9所示。

實驗II-C		數字0至9的辨識			
輸入層神經元個數		90			
輸出層神經元個數		4			
學習速率參數 η		0.001			
活化函數		對數雙彎曲函數			
編號	隱藏層個數	訓練次數	訓練時間(sec)	訓練時間(sec)/次	辨識率
1	90	5477	97	0.01771	98%
2	180	3070	78	0.02541	98%
3	200	2737	78	0.02850	100%

表4.9驗證與測試數字0至9的參數設定 (3)

第五章 結論與未來展望

5.1 結論

因為考量操作便利性與成本，所以不考慮應用資料手套的方式，而採用以外觀輪廓資訊為基礎的方法獲取手勢的特徵，其方式是先經過影像處理找到手勢的影像區域，再以手形輪廓掃描的方式取得手勢的特徵，經由調整倒傳遞類神經網路參數來訓練與驗證手勢特徵，觀察其辨識率、收斂次數與收斂時間如何變化。

網路參數的主要項目分別為活化函數、學習速率、隱藏層神經元個數與輸入層神經元個數，在實驗 I-A 中可以知道從每次訓練時間上來鑑別，活化函數選用對數雙彎曲函數是較佳的。從實驗 I-B 得到驗證學習速率必須在特定的範圍內，其訓練次數或每次訓練時間為最少，如果學習速率超出特定的範圍，在訓練階段類神經網路是無法收斂的。由實驗 II-B 可以知道增加隱藏層神經元個數可以逐步的增加其辨識率。輸入層神經元個數代表著手勢特徵的個數，即等於取樣手形輪廓的解析度，由實驗 II-A、實驗 II-B、實驗 II-C 中可以知道辨識數字 0 至 9 可以經由增加輸入層神經元個數提升其辨識率達 100%。

所以在本論文中提出以影像處理技術獲取手勢特徵，再利用倒傳遞類神經網路訓練與驗證手勢特徵，利用此智慧型辨識法則辨識手勢背後所代表的意義是可行的，從實驗數據中可以得知對於數字 1 至 5 的辨識率可以達到 100%，另外對於數字 0 至 9 的辨識率經由增加輸入層神經元個數為 90 個也可以達到 100%，期望未來人類可以利用手勢透過電腦來操作機器平台，使其隨時注意人們生活上的需求並提供服務。

5.2 未來展望

從實驗數據中可以得知無論辨識數字1至5或辨識數字0至9，其辨識率都可以達到100%，但是仍有些不足之處未來可以繼續改進與討論，目前需要改進的項目如下所述：

- 1.所拍攝的影像會受外在環境光線的影響，雖然在本論文中使用 $YCbCr$ 色彩空間降低光線影響的問題，但是不論是光源過亮或是過暗，其效果仍然有限，因此希望未來能夠朝著動態色彩參數調整的方向改進，以提升影像資訊的準確性。
- 2.在拍攝手勢影像的過程中，限制手勢活動的範圍不可以在人臉的區域範圍內，因為在截取手勢影像的方法是採用膚色偵測，一旦手勢進入人臉區域，將無法明確辨識人臉，希望未來能夠利用其它方式分離出手與人臉的影像，以增加手勢活動的範圍。
- 3.因為手腕可以旋轉，所以在拍攝手勢影像的過程中，限制手掌面盡量對鏡頭(手腕盡量不做旋轉的動作)，只做手臂的上下移動，因為當手腕旋轉至特定角度後，影像中手指會與手掌重疊，無法區分出手指與手掌的影像，且旋轉角度越大，所獲得的特徵函數越不明顯，希望未來能夠增加手腕旋轉後的影像。
- 4.因為手有正反面與左右手，在本論文中只針對右手做手勢辨識，未來可以增加手正反面與左右手的影像作手勢辨識。
- 5.未來可以利用倒傳遞類神經網路做雙手的手勢辨識。
- 6.未來可以再增加特殊手勢的影像，提供倒傳遞類神經網路來做測試。
- 7.對於數字 0 至 9 的辨識率雖然可以達 100%，但是輸入層的個數必須達到 90 個，這會造成影像處理與類神經網路的計算量變大，希望未來可以朝減少輸入層的個數，或利用其它的類神經網路來增加手勢辨識的辨識率。

若能利用影像辨識作為人與機器間互動的媒介，使用上不僅簡單且兼具有衛生、環保，以及低成本上的優點，相信未來影像互動會為人類提升生活與休閒的品質。

參考文獻

- [1] H. J. Park, "Adptive EMG-driven communication for the disability" Proceedings of the First Joint BMES/EMBS Conference, pp.656, 1999.
- [2] 史傑州, 「應用感應手套模擬手部復健評估之研究」, 成功大學工業設計研究所碩士論文, 民國89年。
- [3] 王國榮, 「基於資料手套的智慧型手勢辨識之廣泛研究」, 臺灣科技大學電機工程系碩士論文, 民國90年。
- [4] C. L. Huang and S. H. Jeng, "A model-based hand gesture recognition system", Machine Vision and Appl., vol.12, pp.243-258, 2001.
- [5] V.I. Pavlovic, R. Sharma, and T.S. Huang, "Visual Interpretation of Hand Gestures for Human-Computer Interaction: A Review", Transactions on Pat-tern Analysis and Machine Intelligence, 19(7):677-695, 1997.
- [6] Y. Yasumuro, Qian Chen, and K. Chihara, "3D modeling of human hand with motion constraints", Proc. of the Int. Conf. on 3-D Digital Imaging and Modeling, pp.275-282, May 1997.
- [7] T. S. Huang, Ying Wu, and John Lin, "3D model-based visual hand tracking", Proc. of the 2002 IEEE Int. Conf. on Multimedia and Expo, vol.1, pp.905-908, 2002.
- [8] J. Davis and M. Shah, "Visual gesture recognition", Proc. of IEE on Vision, Image and Signal Processing, Vol.141, pp.101-106, Apr. 1994.
- [9] S. Wagner, B. Alefs, and C. Picus, "Framework for a portable gesture interface," The Proceedings of the 7th International Conference on Automatic Face and Gesture Recognition, April 10-12, 2006, pp. 275-280.
- [10] L. Gupta and M. Suwei, "Gesture-based interaction and communication: automated classification of hand gesture contours," IEEE Transactions on Systems, Man, and

Cybernetics, Part C: Applications and Reviews, vol. 31, pp. 114-120, 2001. 55

- [11] P. Peixoto, J. Gonçalves, H. Araújo, “Real-Time Gesture Recognition System Based on Contour Signatures”, ICPR'2002 --16th International Conference on Pattern Recognition, Quebec City, Canada, August 11-15, 2002.
- [12] Wei Du and Hua Li, “Vision based gesture recognition system with single camera”, Proc. of ICSP2000, vol.2, pp.1351-1357, 2000.
- [13] L Bretzner, I Laptev, T Lindeberg, “Hand gesture recognition using multiscale colour features, hierarchical models and particle filtering”, Proceedings of the fifth IEEE international conference on automatic face and gesture recognition, 2002.
- [14] G. Iannizzotto, M. Villari, and L. Vita, “Hand tracking for human-computer interaction with gray level visual glove: Turning back to the simple way”, In 60 Proc. PUI01, Orlando, Florida, USA, November 2001.
- [15] E. J. Holden and R. Owens, “Recognizing moving hand shapes,” The Proceedings of International Conference on Image Analysis and Processing, September 17-19, 2003, pp. 14-19.
- [16] X. Yin and X. Zhu, “Hand posture recognition in gesture-based human-robot interaction,” The Proceedings of IEEE Conference on Industrial Electronics and Applications, May 24-26, 2006, pp. 1-6.
- [17] 曹文潔，「猜拳機」，碩士論文，中央大學電機工程所，2007。
- [18] 黃俊捷，「互動雙足式機器人之設計與實現(I)」，碩士論文，中央大學電機工程所，2008。
- [19] Y. Fang, K. Wang, J. Cheng and H. Lu, “A Real-Time Hand Gesture Recognition Method,” IEEE of International Conference on Multimedia and Expo (ICME'07), Beijing, China, 2-5 July, pp. 995-998, 2007.
- [20] N. D. Binh and T. Ejima, “Real-Time Hand Gesture Recognition Using Pseudo 3-D Hidden Markov Model,” ICCI 2006, 5th IEEE International Conference on Cognitive

Informatics, Beijing China, Vol. 2, 17-19 July, pp. 820-824, 2006.

- [21] Y. Sriboonruang, P. Kumhom, and K. Chamnongthai, “Visual Hand Gestur Interface for Computer Board Game Control,” IEEE International Conference on Tenth International Symposium, St. Petersburg Russia, 28 June-01 July, pp. 1-5, 2006.
- [22] K. Umeda, I. Furusawa and S. Tanaka, “Recognition of Hand Gestures Using Range Images,” IEEE/RSJ International Conference on Intelligent Robots and Systems, Victoria, BC Canada, Vol. 3, Oct. 13-17, pp. 1727-1732, 1998.
- [23] E.J.Holden and R. Owens, “Recognizing Moving Hand Shapes,” International Conference on Image Analysis and Processing, Mantova, Italy, 17-19 Sept., pp.14-19, 2003.
- [24] V.Vezhnevets, V. Sazonov, and A. Andreeva, “A Survey on Pixel-Based Skin ColorDetection Techniques,” Proc. Graphicon-2003, pp. 85-92, Moscow, Russia, Sep. 2003.
- [25] D.Chai and K. N. Ngan, “Face segmentation using skin-color map in videophone applications,” IEEE Transactions on Circuits and Systems for Video Technology, vol. 9, no. 4, pp. 551-564, June 1999.