

基於類神經網路技術之人臉偵測與辨識系統

Face detection and recognition based on neural techniques

蔡賢亮
義守大學
資訊管理學系
助理教授
jim@isu.edu.tw

黃佩玲
義守大學
資訊管理學系
m9622015@
isu.edu.tw

姜程浩
義守大學
資訊管理學系
m9622029@
isu.edu.tw

周煜書
義守大學
資訊管理學系
m9522021@
isu.edu.tw

摘要

在本論文中，我們提出一套能處理較複雜或較具雜訊之影像中的人臉偵測、定位及識別系統。我們的研究目的在能達到精確偵測出複雜影像中的人臉影像，以及提高識別人臉影像身分的辨識效能。

我們將系統分割成二個部份：人臉偵測及定位演算法及類神經人臉辨識演算法。在人臉偵測方面，我們提出兩個改良的模糊神經人臉偵測演算法(FNFD1、FNFD2)來提昇較複雜影像的偵測效果。人臉定位方面，利用高斯擴展的方式搭配閾值設定來找出影像中人臉的位置。而在人臉辨識方面，我們透過模糊概念的模糊 C 均值分群演算法(FCM)進行初步分群[4,5]，再將這些特徵資料輸入到 radial basis function (RBF) 類神經網路來進行訓練或辨識。

從實驗數據來看，我們所提出的人臉偵測及辨識系統確實具有不錯的偵測及辨識效果。

關鍵詞：倒傳遞類神經網路、特徵擷取隱藏層、高斯擴展定位、FCM 分群法、RBF 類神經網路

Abstract

In this paper we present a system which can detect and recognize human faces that are complex and mingled with surrounding noises in images. We employ the threshold value to determine their locations and increase the ability of their recognition.

The system has three steps: (a) human face detection (b) human face location (c) human face recognition. On first, we utilize an improved NNFD. On the second, we use Gaussian spread

method with the right threshold's setting to locate the face location. On the third, we employ Gaussian parameters to extract the face features and use the fuzzy c-means for clustering. These features go into radial basis function (RBF) neural network for training and utilize the RBF neural classifier to recognize faces.

This can be seen in experimental results. Our system has better efficiency for face detection and less training time for neural networks under presumed basic conditions.

Keywords: back propagation neural networks, feature extraction layer, Gaussian filter, fuzzy c-means clustering, radial basis function neural networks.

1. 前言

人工智慧處理圖形辨識技術運用在科技產品上，在近幾年來的發展已經慢慢日趨成熟，而人臉辨識系統在其中是相當熱門的研究話題，人臉辨識系統的主軸分別如下：人臉偵測與定位、人臉特徵的擷取與人臉辨識。

人臉偵測主要目的為，偵測一張影像是否有人臉存在於其中，與定位出人臉的大概位置。但是想要明確的判別此張影像是否有人臉的存在，常常會因為複雜的背景與在影像中人臉的角度、方向、大小、膚色等等因素而提高人臉偵測的難度。在人臉辨識演算法上，此研究使用的是我們先前所提出的 Fuzzy Neural Face Detection(FNFD2)是改良於 Rowley 於 1998 年提出 neural network-based face detection(NNFD)[7]類神經網路應用於人臉偵測的演算法，此研究旨在發展出一套，能偵測出影像中複雜度高以及週遭雜訊去除不完全的人臉和識別人臉影像身分的系統，因此不只需要偵測出人臉還需找出人臉存在於影像中

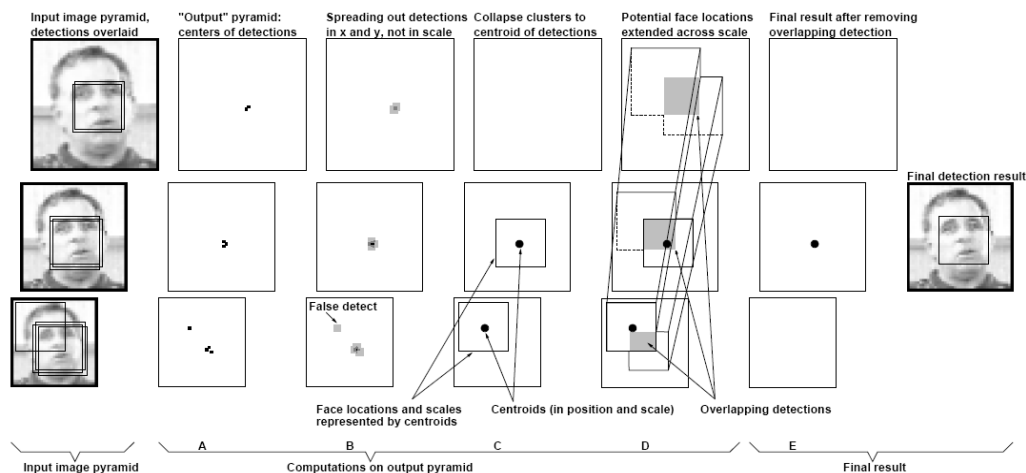


圖 1 NNFD 人臉定位架構

的位置並進一步的去進行身份的辨識。

經由人臉偵測找出人臉區塊，再透過定位去確定人臉區塊的位置。在人臉定位方面參考 Rowley 所提出的合併單一網路部分重疊偵測結果的定位方法，藉由閾值的篩選找出人臉影像的位置。人臉辨識演算法方面，參考了 RBF 類神經網路以及 k-means 分群法。

2. 文獻探討

本章節中，我們分別介紹 Rowley 提出之合併單一網路部份重疊偵測結果的定位方法，以及 RBF 類神經網路與 k-means 分群法。

2.1 Merging Overlapping Detections

Rowley 於 1998 年提出 NNFD 這個演算法時，為了解決此演算法會造成影像中人臉位置的鄰近區域會被重複偵測。在這些鄰近區域當中，會包含一些對於人臉影像來說相符度較低的影像區塊，因為此現象的發生，Rowley 也一併提出合併部分重疊偵測的方法來減少誤判發生。

合併部分重疊偵測的方法是透過計算每一個偵測區塊鄰近範圍內的被偵測次數，如果這個偵測區塊鄰近範圍內的偵測次數高於閾值，則判定為此偵測區塊內包含一張人臉影像，藉由重疊多重偵測結果，當一個主要影像位置被成功判別，其周遭區塊與此區塊重疊時將會有誤判的可能性發生，需進一步排除誤判，透過閾值的計算保留偵測區塊鄰近範圍內的偵測次數較高的偵測位置，排除掉較低的偵測位置，透過此方法來達到重疊偵測的排除，閾值的計算以及重疊偵測的排除，如圖 1 所示。

2.2 Radial Basis Function(RBF) Neural Network

一般來說多層類神經網路配合倒傳遞演算法，被廣泛的應用到人臉辨識。但是倒傳遞演算法，還是有兩個主要的問題存在：1. 密集的計算過程，可能使得收斂速度過慢。2. 有可能產生的結果決定性不夠，這樣的狀況存在於訓練過度所產生的影響，這樣的影響可能使得網路對於訓練樣本以外的樣本辨識能力不佳。RBF 類神經網路具有以下特性，能改善上述缺點：

1. 採用局部調整，所以學習速度快。
2. 能以任意精度逼近任何的連續參數。
3. 架構相較於其他類神經網路更為精簡。

上述的那些特色使得 RBF 類神經網路，被廣泛應用於解決函式的逼近以及樣本辨識等問題，這些問題的樣本維度都是屬於較小的。當 RBF 類神經網路應用於人臉辨識時，會有輸入樣本具有高維度的狀況，舉例來說，當有一張 128×128 pixels 大小的樣本影像輸入時，這張輸入影像的維度將會是 16384 pixels。本研究參考文章利用 principal component analysis (PCA) + Fisher's linear discriminant (FLD) 這兩種方法，來避免 overfitting 和減少計算，並處理具有高維度特徵向量的訓練樣本，如圖 2 所示。

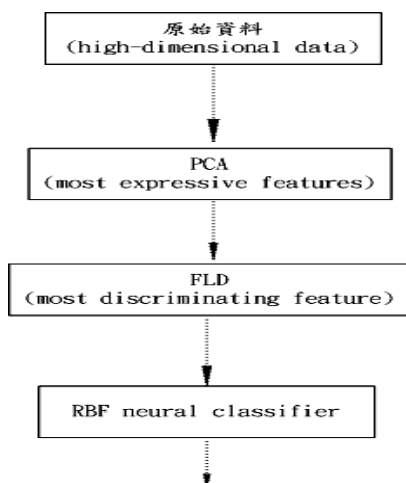


圖 2 依 PCA+FLD 降低樣本維度

PCA 透過特徵的選取將輸入的變數縮減，使得輸入變數由維度較少的主要特徵來表示，但是並不會減少原始數據所包含的內在資訊，將通過 PCA 選擇的特徵結果，經由 FLD 判定過後可以獲得更少維度的主要特徵，使得不同類別間的特徵資料可以拆離至變異最大，並且使同類別間的特徵資料變異最小。對於訓練樣本的分類，使用分群演算法將同性質的訓練樣本分成同一類。




圖 3 k-means 分群狀況

2.3 分群演算法

RBF 類神經網路的主要觀念為，將輸入空間分成一些子空間，因此分群演算法常搭配著 RBF 類神經網路，分群演算中最常被廣泛使用為 k-means 分群演算法。k-means 分群演算法的分群狀況如圖 3 所示。

k-means 分群演算法在初始分群中，即會造成分類錯誤，雖然可以在爾後的 RBF 類神經網路調整，但是卻會影響其效能。因此當要對樣本進行分群時，我們希望不只是針對樣本間的距離來當作分群依據，希望也能把樣本資料的性質也參考進來，將同質性高的分成一群，便能在初始分群時減低分類錯誤的出現，使得接下來的 RBF 類神經網路能夠更有效率。

2.4 系統架構

本研究在人臉偵測演算法上使用我們之前所提出的 FNFD2[11]是改良 Rowley 所提出的 neural network-based face detection (NNFD) 類神經網路人臉偵測演算法，如圖 1，在人臉定位方面參考 Rowley 提出的 merging overlapping detections 的方法，本研究透過高斯函數對於人臉偵測結果進行擴展，藉由閾值的篩選找出人臉影像的位置。人臉辨識演算法方面，本研究使用模糊邏輯概念的分群演算法，對於人臉影像進行初步分群，透過 RBF 類神經網路進行辨識。

2.4.1 FCM 結合 RBF 類神經網路人臉辨識演算法

本研究是將 20×20 的輸入影像，經過直方圖等化處理，將其等化後的灰階值作正規化 (normalization) 至 $[0,1]$ 之間，並將每個像素位置予以正規化，經由高斯模糊的方式來減少影像維度，影像經過高斯模糊計算後會得到 N 個值。本研究以 20×20 的大小輸入影像，其像素個數為 400，並以 4 單位為一區間，予以正規化後，經由高斯模糊歸屬函數計算可得 100 個主要特徵值。應用 RBF 類神經網路解決樣本辨識問題時，訓練樣本的分類將會影響到辨識的效果，在 RBF 類神經網路中有三組可調參數：隱藏層基底函數中心、寬度參數，以及輸出層權重。本研究使用分群演算法選擇基底函數中心，經過高斯模糊化計算的訓練樣本，透過模糊 c-means 分群法 (fuzzy c-means clustering) 簡稱 FCM，將要輸入到 RBF 類神經網路的訓練樣本初始分群，並取得隱藏層神經元的初始參數。FCM 與 k-means 最大的差異在於分群時會考慮分群資料的特性，訓練樣本不再只依據分群資料間的距離遠近來做分群，也會考慮到高斯函數的作用距離，如圖 4 所示。




圖 4 FCM 分群狀況

上圖中的 P 點與類別 j 及類別 k 以歐式距離來看，距離類別 k 的中心點較近，但是要是以高斯函數的作用距離來看應該歸屬到類別 j ，要

是單純只用資料間的距離來分群這個點就會產生分類錯誤，所以我們希望透過 FCM 做分群初始來減少這種分類錯誤的發生。將這些經過初始分群的訓練樣本，輸入到 RBF 類神經網路來做更進一步的訓練，使得本研究的人臉辨識系統對於人臉影像能產生不錯的辨識效果，如圖 5 所示。

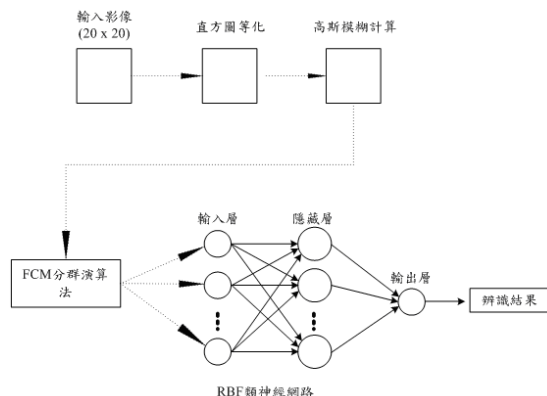


圖 5 影像辨識流程

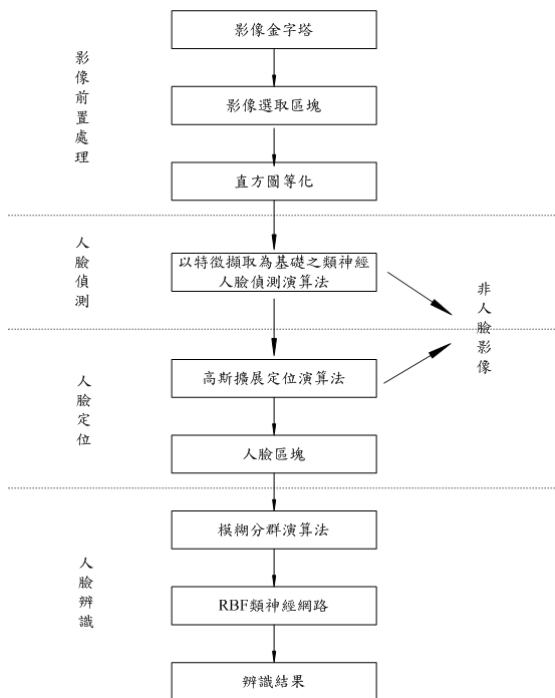


圖 6 本研究系統架構

3. 研究架構

本研究主要分成人臉偵測、人臉定位、人臉辨識三大部分，其系統架構如圖 6 所示。

3.1 影像前置處理

當灰階影像輸入到類神經網路前，會先將被選取的 20×20 區塊經過一些前置處理，之後才將經過處理的灰階影像輸入類神經網路，如圖 7 所示。

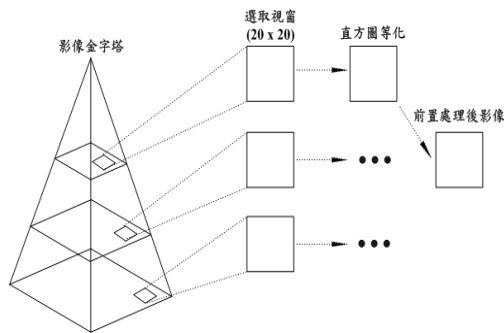


圖 7 影像前置處理

3.1.1 影像金字塔

輸入影像的尺寸大小不一，利用金字塔分解影像後將不同尺寸的影像利用選取視窗掃描，以滑動的模式由左至右做水平的掃描影像，金字塔影像分解的方式可使影像中大小不一的人臉更容易的被偵測到。

經過影像前置處理之後，輸入類神經網路的影像主要為臉部五官，儘管輸入的影像在角度、轉動都有一定程度的變化，透過選取視窗可以降低這種狀況，如圖 8 所示。

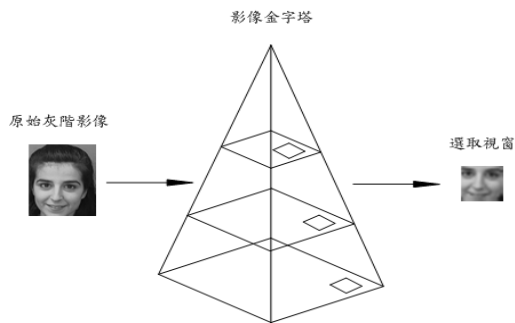


圖 8 選取視窗

3.1.2 直方圖等化

灰階影像的直方圖是灰階度的一種統計圖，直方圖等化是將原影像中所有像素的灰階值分配到各個像素點，使灰階度的直方圖儘可能呈現均勻分佈，如此可提高影像的對比，得到較清晰的影像，如圖 9 所示。



圖 9 直方圖等化

3.2 人臉偵測演算法

本研究先前提出的 FNFD1[11] H2 類神經元偵測範圍小、次數多，容易因臉部特徵位移過大而造成誤判，使用大量計算，對於類神經網路的收斂速度造成不良影響。因此，再將 FNFD1 的架構做調整，提出 FNFD2。

3.2.1 FNFD2 演算法及訓練法則

本研究希望藉由改良 NNFD 類神經網路架構，來改善對於角度、轉動較有變化的人臉偵測能力，使 FNFD2 的訓練時間減少，對於複雜人臉的辨識效能可以更好。

第一層隱藏層使用兩種型態類神經元：9 個 8×8 的正方形重疊偵測區塊，利用重疊偵測臉部特徵來提高準確度。6 個 5×20 的水平重疊偵測區塊，用來偵測面部水平的特徵例如：一對眼睛、嘴巴，這些偵測區塊所產生的結果，對於第二層隱藏層的特徵擷取類神經元是很重要的，將各個臉部特徵偵測區塊的輸出值，當成第二層隱藏層訓練所需要的輸入值。第二層隱藏層的四個類神經元，用來接受第一層隱藏層的特徵輸出值，所接收的輸出值包含眼睛、鼻子、嘴巴、臉頰，如圖 10 所示。

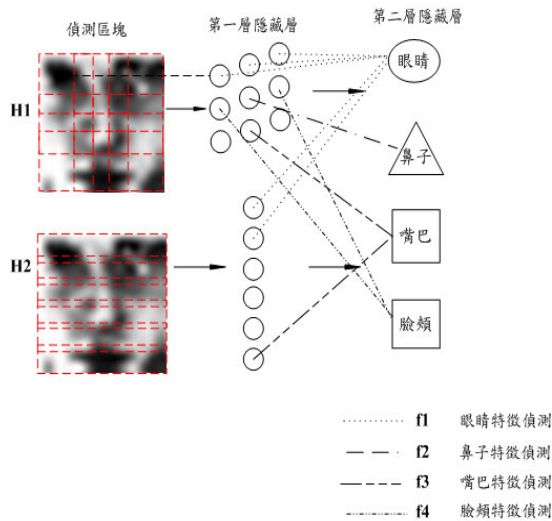


圖 10 特徵擷取

3.2.2 FNFD2 類神經網路

分為前饋階段與倒傳遞階段，經過前置處理之後的影像輸入類神經網路訓練，第一層隱藏層類神經元會對整張影像各個局部區域進行計算：

$$Out_{H1}^{(0,0)} = f \left(\sum_{k=0}^{63} Input_k \times w_k^{(0,0)} + b_{H1}^{(0,0)} \right), \quad (1)$$

$$k = 0, \dots, 63$$

$Out_{H1}^{(0,0)}$ 代表第一層隱藏層的 H_1 類神經元 (0,0) 區塊輸出值， $Input_k$ 是 20×20 選取視窗從左至右，由上到下掃描影像 8×8 區塊輸入到第一層隱藏層的 H_1 類神經元 (0,0) 位置， $w_k^{(0,0)}$ 代表第一層隱藏層的 H_1 類神經元 (0,0) 權重值， $b_{H1}^{(0,0)}$ 代表第一層隱藏層的 H_1 類神經元 (0,0) 偏權值， f 代表 sigmoid 轉換函式，如圖 11 所示。




圖 11 輸入層到第一層隱藏層

各個臉部特徵位置輸出值，送到特定的臉部特徵類神經元計算：

$$Out_{f1} = f \left(\sum_{j=0}^2 Out_{H1}^{(0,j)} \times w_{f1}^{(0,j)} + \sum_{k=0}^1 Out_{H2}^k \times w_{f1}^k + b_{f1} \right), \quad (2)$$

$$j = 0, 1, 2 \quad k = 0, 1$$

Out_{f1} 代表第二層隱藏層的 f1 眼睛特徵類神經元輸出值， $Out_{H1}^{(0,j)}$ 代表第一層隱藏層的 H1 區塊輸出值， Out_{H2}^k 代表第一層隱藏層的 H2 區塊輸出值， $w_{f1}^{(0,j)}$ 代表第一層隱藏層的 H1 區塊與 f1 之間的權重值， w_{f1}^k 代表第一層隱藏層的

H2 區塊與 f1 之間的權重值， b_{f1} 代表第二層隱藏層的 f1 眼睛特徵類神經元偏權值， f 代表 sigmoid 轉換函式，如圖 12。

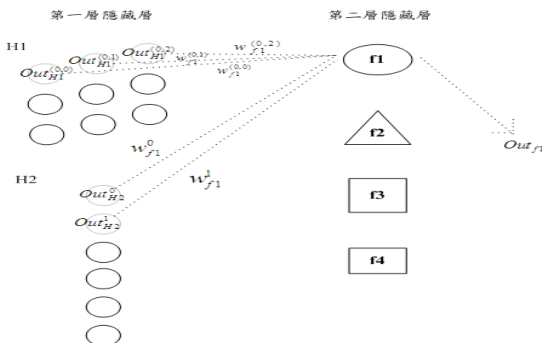


圖 12 第一層隱藏層到第二層隱藏層

將四個特徵類神經元輸出值再輸入到輸出層訓練：

$$Out_z = f\left(\sum_{k=1}^4 Out_{f_k} \times w_{z_k} + b_z\right), \quad (3)$$

$$k = 1, \dots, 4$$

Out_z 代表輸出層 z 的輸出值， Out_{f_k} 代表特徵擷取隱藏層的輸出值， w_{z_k} 代表輸出層權重值， b_z 代表輸出層偏權值，如圖 13。




圖 13 第二層隱藏層到輸出層

整個 FNFD2 系統架構，如圖 14 所示。

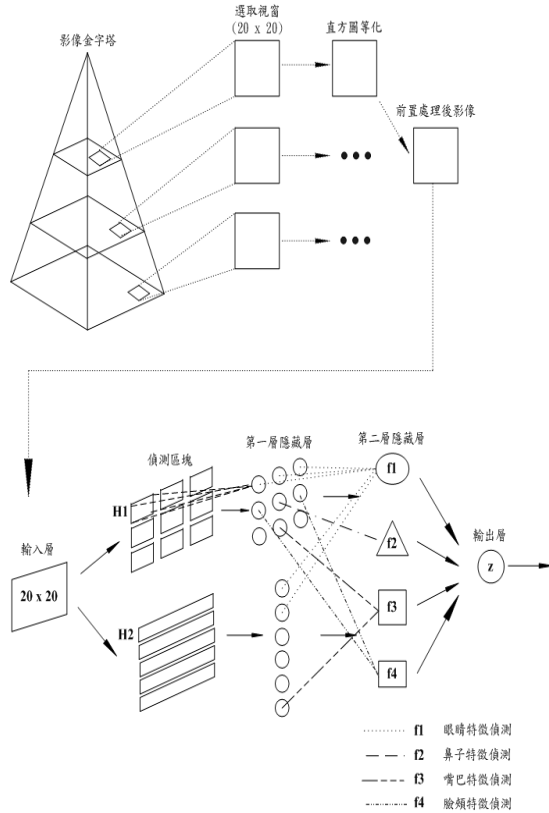


圖 14 FNFD2 系統架構

倒傳遞階段網路的權重修正量，根據網路的真實輸出值與期望值來調整，計算輸出層誤差，然後將 δ 計算出來。隱藏層類神經元無法直接計算出誤差值，但可以藉由網路的最後輸出所產生的誤差來調整，因此 δ 的計算可以將誤差倒傳遞回網路來達成調整目的。H1 類神經元連結至 f1 特徵擷取類神經元的權重修正量，可以用 δ 來定義：

$$\square w_{H1,i}^{f1}(n) = \eta \times \delta_{f1}(n) \times y_{H1,i}(n), \quad (4)$$

$$i = 0, 1, 2$$

$\square w_{H1,i}^{f1}$ 代表 H1 類神經元連結至 f1 特徵擷取類神經元的權重修正量， η 代表學習速率參數， $\delta_{f1}(n)$ 代表 f1 特徵擷取類神經元區域函數， $y_{H1,i}(n)$ 代表 f1 特徵擷取類神經元的輸入值。

學習速率參數的設定影響很大，參數設的越小，修正量的改變越小，收斂的時間也需要更久。設的較大可以增加學習速度，但產生的修正量變動較大，可能會使得網路不穩而無法收斂。加入一個慣性項 (momentum)，可以增快學習速率又能避免網路不穩定：

$$\square w_{H_{1,i}}^{f1}(n) = \alpha \square w_{H_{1,i}}^{f1}(n-1) + \eta \delta_{f1}(n) y_{H_{1,i}}(n), \quad (5)$$

$$i = 0, 1, 2$$

α 代表一個大於零的常數，稱為慣性常數，用來控制 $\square w_{H_{1,i}}^{f1}(n)$ 的修正量，通常網路為了收斂，慣性常數的大小會限制為： $0 \leq \alpha < 1$ 。

3.3 人臉定位演算法

當影像經過偵測後，我們利用高斯擴展計算偵測後的影像區塊，並使用閾值進行篩選，找出人臉影像區塊的位置，以便進行人臉辨識。

3.3.1 高斯擴展定位法

透過高斯空間濾波對指定像素以及其鄰域部份藉由權重進行加乘運算，該影像新的數值經由進行線性函數運算而來。為使其高斯函數適用於本研究的定位計算，設計一個 3×3 二維高斯濾波器，如圖 15 所示。

0.05 (-1,1)	0.075 (0,1)	0.05 (1,1)
0.075 (-1,0)	0.5 (0,0)	0.075 (1,0)
0.05 (-1,-1)	0.075 (0,-1)	0.05 (1,-1)

圖 15 高斯擴展遮罩

用類神經網路偵測後的網路輸出值，透過高斯函數運算來修正輸出值，遮罩覆蓋於指定的區塊位置中由左而右、由上而下，一次平移一個位置，影像於遮罩下的相對位置，如圖 16 所示。

$p(i-2, j+1)$	$p(i-1, j+1)$	$p(i, j+1)$	$p(i+1, j+1)$	$p(i+2, j+1)$
$p(i-2, j)$	$p(i-1, j)$	$p(i, j)$	$p(i+1, j)$	$p(i+2, j)$
$p(i-2, j-1)$	$p(i-1, j-1)$	$p(i, j-1)$	$p(i+1, j-1)$	$p(i+2, j-1)$

圖 16 影像與遮罩相對應位置

進行相加計算

$$value(i+s, j+t) = filter(s, t) + value(i+s, j+t), \quad (6)$$

$$s, t = -1, 0, 1$$

$filter(s, t)$ 代表遮罩權重， $value(i, j)$ 代表類神經網路偵測結果的輸出值。整個高斯擴展的運算流程，如圖 17 所示。




圖 17 高斯擴展運算

3.4 人臉辨識演算法

人臉影像因具有高度複雜性，這個複雜性來自許多變因如表情、動作、光線的來源...等等。這些變因都是人臉辨識所要面臨的挑戰，本研究於人臉辨識演算法中使用徑向基底函數類神經網路 face recognition with radial basis function(RBF) neural networks，將經過人臉偵測以及人臉定位之後的影像，輸入到訓練完成 RBF 類神經網路中進行辨識，如圖 18 所示。RBF 類神經網路中的作用函數為高斯基底函數，即

$$f(x) = e^{-\alpha x^2} \quad (7)$$

此函數值在輸入空間中有線範圍內為非零值。所以 RBF 類神經網路是一種局部逼近的類神經網路，RBF 類神經網路隱藏層中的神經元是採非線性輸出，而在輸出層中的神經元是採線性輸出，RBF 類神經網路的輸出值不是 0,1，而是任何值，RBF 類神經網路架構，如圖 19 所示。

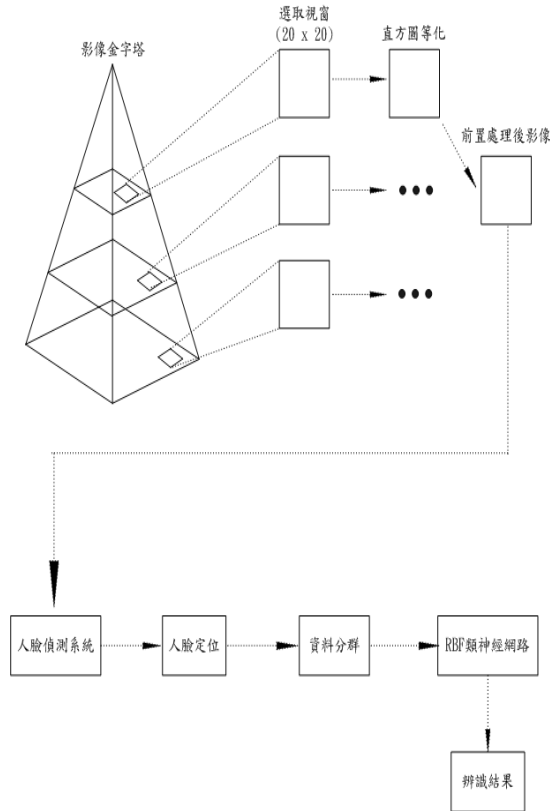


圖 18 人臉辨識流程




圖 19 RBF 類神經網路架構

3.4.1 人臉辨識演算法及訓練法則

本研究希望將訓練樣本藉由高斯模糊計算來降低訓練樣本的維度，透過將訓練樣本的維度降低，利用 FCM 分群演算法進行分群，可以減少各類別間的分類錯誤，提高分群的效過，再經由 RBF 類神經網路訓練，使人臉辨識系統對於人臉能產生不錯的辨識效果。

3.4.2 RBF 類神經網路訓練法則

分為前饋階段與倒傳遞階段，經過高斯模糊之後的影像輸入類神經網路訓練，RBF 類神經網路的輸入層到隱藏層的前饋階段，輸入層的輸入向量表示如下：

$$X = [x_1, x_2, \dots, x_n]^T$$

隱藏層接收來自輸入層的訊息，再經由非線性轉換後，得到隱藏層的輸出，公式如下：

$$h_j(x) = R(\|X - C_j\|), \quad (8)$$

$$j = 1, 2, \dots, m$$

其中 $R(\cdot)$ 表示幅狀基底函數，我們採用高斯函數， $R(\|X - C_j\|) = \exp\left(-\frac{\|X - C_j\|^2}{2\sigma_j^2}\right)$ (9)

$C_j = [c_{j1}, c_{j2}, \dots, c_{jn}]^T$ 表示隱藏層第 j 個神經元的中心點， $\|X - C_j\|$ 表示輸入向量 X 與 C_j 間的歐式距離，輸入層到隱藏層前饋階段如圖 20 所示。




圖 20 RBF 類神經網路輸入層到隱藏層前饋運算

輸出層會將隱藏層輸出經加權相加，最後得到 RBF 類神經網路輸出值，其公式如下：

$$y = \sum_{j=1}^m w_j h_j = \sum_{j=1}^m w_j R(\|X - C_j\|) \quad (10)$$

其中 y 為輸出層的輸出值， w_j 為隱藏層第 j 個神經元至輸出層的權重值， h_j 為隱藏層第 j 個神經元的輸出值，隱藏層到輸出層的前饋階段，如圖 21 所示。




圖 21 RBF 類神經網路隱藏層到輸出層前饋運算

RBF 類神經網路倒傳遞階段，利用分群演算法來取得 m 個隱藏層神經元的中心點，以下列公式作為高斯函數標準差的初始值：

$$\sigma_j^2 = \frac{d_{\max}^2}{m} \quad (11)$$

其中 m 為 RBF 類神經網路的隱藏層神經元的中心點個數， d_{\max} 為所有中心點間最大的距離值。計算類神經網路的輸出值 $y(k)$ 與目標輸出值 $d(k)$ 的誤差 $e(k)$ ：

$$e(k) = d(k) - y(k) \quad (12)$$

倒傳遞階段網路的權重值修正量及隱藏層神經元參數，根據網路的誤差來調整，公式如下：

$$\frac{\partial E}{\partial w_j} = -(d_j - y_j)h_j \quad (13)$$

y_j 代表輸入層的真实輸出值， d_j 代表期望輸出值， w_j 為 RBF 類神經網路隱藏層第 j 個神經元至輸出層的權重值， h_j 為 RBF 類神經網路隱藏層第 j 個神經元的輸出值，如圖 22 所示。




圖 22 依誤差倒傳遞調整隱藏層與輸出層間權重

藉由誤差倒傳遞來調整 RBF 類神經網路隱藏層中心點位置，公式如下：

$$\frac{\partial E}{\partial C_j} = (d_j - y_j)w_j \exp(-v) \frac{X_j - C_j}{\sigma_j^2} \quad (14)$$

y_j 代表輸出層的真实輸出值， d_j 代表期望輸出值， w_j 為 RBF 類神經網路隱藏層第 j 個神經元至輸出層的權重值， X_j 代表輸入層的輸入向量， C_j 代表 RBF 類神經網路隱藏層的中心點位置，如圖 23 所示。




圖 23 依誤差倒傳遞調整隱藏層參數

藉由誤差倒傳遞來調整 RBF 類神經網路隱藏層高斯標準差，推導如下：

$$\frac{\partial E}{\partial \sigma_j} = \frac{\partial E}{\partial y_j} \frac{\partial y_j}{\partial \sigma_j} = \frac{\partial \frac{1}{2}(d_j - y_j)^2}{\partial y_j} \frac{\partial y_j}{\partial \sigma_j}$$

$$\begin{aligned}
 &= -(d_j - y_j) \frac{\partial \sum_{m=1}^n w_j h_j}{\partial h_j} \frac{\partial h_j}{\partial \sigma_j} \\
 &= -(d_j - y_j) w_j \frac{\partial \exp(-v)}{\partial v} \frac{\partial v}{\partial \sigma_j} \\
 &= (d_j - y_j) w_j \exp(-v) \frac{\partial \frac{\|X_j - C_j\|^2}{2\sigma_j^2}}{\partial \sigma_j} \\
 &= (d_j - y_j) w_j \exp(-v) \frac{\|X_j - C_j\|^2}{\sigma_j^3} \quad (15)
 \end{aligned}$$

X_j 代表輸入層的輸入向量， C_j 代表 RBF 類神經網路隱藏層第 j 個神經元的中心點位置， σ_j 代表 RBF 類神經網路隱藏層第 j 個神經元的高斯標準差，如上圖所示。

4. 實驗結果

本章節中，我們將透過七個實驗來測試本研究所提出方法的效能和實作，將我們的方法應用到不同類型人臉樣本進行實驗。偵測部分人臉樣本有來自 ORL 人臉資料庫、網路隨機收集人臉樣本、非人臉樣本，以及訓練次數與偵測效果的探討。定位的實驗則使用 BioID-FaceDatabase-V1.2 人臉資料庫、網路隨機收集相片與多人合照進行測試。人臉辨識部分，採用大量的 ORL 人臉資料庫影像，將實驗樣本分成訓練和測試，每進行一次辨識實驗便改變其訓練和測試樣本的組成。

4.1 系統開發環境

本研究使用於 Microsoft Windows XP Professional Version 2002 Service Pack2 作業系統，處理器為 Pentium D CPU 3.40GHz，記憶體 1.00GB RAM，此實作系統使用 Microsoft Visual C++ 6.0 寫成。

4.2 人臉偵測實驗結果與分析

訓練類神經網路的人臉樣本，從 ORL 人臉資料庫中收集。選取固定數量的相同人臉樣本當中包含不同角度、轉動將這些當成一組，訓練樣本是由數個組別所建立，組別中的人臉都已經轉成灰階影像，如圖 24。



圖 24 人臉訓練樣本

4.2.1 ORL 人臉資料庫測試實驗

從 ORL 人臉資料庫中隨機選取 25 張人臉，經過影像前置處理過後，讓訓練完成的類神經網路作測試。類神經網路參數設定，訓練次數: 60 萬次、 η 學習速率: 0.3、 α 慣性參數: 0.5，測試樣本與訓練樣本來源相同，如表 1 所示。

表 1 ORL 人臉資料庫測試實驗

人臉	1	2	3	4	5
演算法					
NNFD	0.983333	0.900221	0.954599	0.871579	0.981276
FNFD1	0.996918	0.992937	0.99386	0.998634	0.999313
FNFD2	0.996321	0.996446	0.996637	0.996346	0.998375
人臉	6	7	8	9	10
演算法					
NNFD	0.999424	0.990577	0.99395	0.92604	0.993978
FNFD1	0.999808	0.997876	0.999781	0.999753	0.999742
FNFD2	0.998401	0.998392	0.998425	0.998416	0.998427
人臉	11	12	13	14	15
演算法					
NNFD	0.990966	0.995678	0.996189	0.996618	0.998218
FNFD1	0.99979	0.004321	0.999795	0.999797	0.999784
FNFD2	0.998422	0.99645	0.998428	0.998427	0.998348
人臉	16	17	18	19	20
演算法					
NNFD	0.995562	0.99602	0.978142	0.966352	0.970858
FNFD1	0.991292	0.992708	0.995319	0.993575	0.954795
FNFD2	0.996927	0.996666	0.9967	0.998374	0.997832
人臉	21	22	23	24	25
演算法					
NNFD	0.997571	0.999802	0.991102	0.957248	0.852257
FNFD1	0.999826	0.999827	0.999795	0.994518	0.996542
FNFD2	0.998286	0.998428	0.998425	0.997999	0.997813

表 1 中的數值，代表系統對於這些影像是人臉的判定程度。三種訓練演算法: NNFD、FNFD1、FNFD2 在 ORL 人臉資料庫測試實驗的探討，如表 2 所示。

表 2 ORL 人臉資料庫測試實驗探討

演算法	轉換函式			錯誤偵測 (張)	訓練時間 (秒)
	Hidden 1	Hidden 2	Output		
NNFD	sigmoid	無	sigmoid	0	2528.17
FNFD1	sigmoid	sigmoid	sigmoid	1	3311.19
FNFD2	sigmoid	sigmoid	sigmoid	0	2303.75

ORL 人臉資料庫 25 張測試樣本，FNFD1 在編號 12 出現誤判情形，這張圖的臉部特徵位移劇烈，左眼已經在影像視窗外，當中影像有戴眼鏡。這些干擾對於 FNFD1，在臉部特徵敏感度很高的特性下，容易造成誤判。

4.2.2 網路隨機收集測試實驗

隨機選取 25 張網路照片，選取當中人臉經過影像前置處理，讓訓練完成的類神經網路作測試，週遭雜訊去除的結果並不完全，經過前置處理之後的對比效果較差，類神經網路參數設定，訓練次數:60 萬次、 η 學習速率:0.3、 α 慣性參數:0.5，如表 3 所示。

表 3 網路隨機收集測試實驗

		1	2	3	4	5
人臉 演算法	NNFD	0.607664	0.930284	0.761214	0.782877	0.998726
	FNFD1	0.992598	0.966235	0.993709	0.995524	0.999818
	FNFD2	0.99831	0.996966	0.998304	0.99629	0.996525
	NNFD	0.359342	0.614345	0.955314	0.96849	0.23143
	FNFD1	0.993705	0.284281	0.987702	0.996674	0.990466
FNFD2	0.997128	0.998132	0.998145	0.996288	0.996293	
人臉 演算法	NNFD	0.992977	0.997119	0.286157	0.517406	0.996784
	FNFD1	0.992156	0.990133	0.9921	0.991524	0.994065
	FNFD2	0.998425	0.99642	0.996341	0.996349	0.996309
	NNFD	0.582337	0.982638	0.997771	0.995265	0.997992
	FNFD1	0.0039167	0.994887	0.999815	0.993779	0.994563
FNFD2	0.996287	0.997727	0.996348	0.996836	0.998425	
人臉 演算法	NNFD	0.616619	0.924308	0.955735	0.948003	0.586032
	FNFD1	0.0673161	0.989639	0.999806	0.995601	0.995436
	FNFD2	0.996103	0.996289	0.998039	0.996458	0.996298
	NNFD	0.616619	0.924308	0.955735	0.948003	0.586032
	FNFD1	0.0673161	0.989639	0.999806	0.995601	0.995436
FNFD2	0.996103	0.996289	0.998039	0.996458	0.996298	

表 3 中的數值，代表系統對於這些影像是人臉的判定程度。三種訓練演算法:NNFD、FNFD1、FNFD2 在網路隨機收集測試實驗的探討，如表 4 所示。

表 4 網路隨機收集測試實驗探討

演算法	轉換函式			錯誤偵測 (張)	訓練時間 (秒)
	Hidden 1	Hidden 2	Output		
NNFD	sigmoid	無	sigmoid	3	2528.17
FNFD1	sigmoid	sigmoid	sigmoid	3	3311.19
FNFD2	sigmoid	sigmoid	sigmoid	0	2303.75

在 4.2.2 測試實驗中 NNFD 的錯誤偵測數量與 FNFD1 相同，但是卻有編號 1、7、14、16、21、25，6 張人臉影像判定程度不高，在後端處理上會增加許多複雜度。FNFD1 對於判定通過的人臉有高的確定性，實驗中發現 FNFD1 有誤判情況的影像，都是臉部特徵位移劇烈的影像。

另外，NNFD 的錯誤偵測中，有 2 張人臉週遭雜訊沒有被去除的很乾淨。當中的人臉影像在角度、轉動方面的變化，造成 NNFD 誤判。實驗中 NNFD 對於影像偵測效果有不錯的成果，但實際上當門檻值設定較嚴謹時，其偵測能力就有待加強。

FNFD2 表現出色在於藉由重疊各偵測區塊來提高對於臉部特徵的準確性，將這些值再輸入臉部特徵擷取隱藏層訓練，這樣的效果比 NNFD 多了對於臉部特徵的敏感度，也因為選取的範圍不會太過瑣碎，所以比 FNFD1 有更好的辨識效能及容錯力。

4.2.3 非人臉測試實驗

非人臉選取 10 張測試樣本，主要都是從網路風景圖當中隨機選取，有些測試樣本與人臉相似度很高，來測試訓練完成的類神經網路誤判狀況，類神經網路參數設定，訓練次數:60 萬次、 η 學習速率:0.3、 α 慣性參數:0.5，如表 5 所示。

表 5 非人臉測試實驗











非人臉 演算法	1	2	3	4	5
					
NNFD	0.0115976	0.0096932	0.102201	0.0004808	0.928695
FNFD1	0.89306	0.0027722	0.008445	0.003331	0.990593
FNFD2	0.998372	0.001119	0.0023238	0.0020255	0.998426
非人臉 演算法	6	7	8	9	10
					
NNFD	0.158109	0.0162342	0.0049247	0.0026377	0.014029
FNFD1	0.0018021	0.0072028	0.0038217	0.0021629	0.0014973
FNFD2	0.0023965	0.0010819	0.730303	0.0010787	0.0012452

表 5 中的數值，代表系統對於這些影像是非人臉的判定程度。三種訓練演算法:NNFD、FNFD1、FNFD2 在網路隨機收集測試實驗的探討，如表 6 所示。

表 6 非人臉測試實驗探討

演算法	轉換函式			錯誤偵測 (張)	訓練時間 (秒)
	Hidden 1	Hidden 2	Output		
NNFD	sigmoid	無	sigmoid	1	2528.17
FNFD1	sigmoid	sigmoid	sigmoid	2	3311.19
FNFD2	sigmoid	sigmoid	sigmoid	3	2303.75

4.2.3 測試實驗中 NNFD 的錯誤偵測有 1 張，這張非人臉影像與人臉相似，但是這張影像對於其他 2 種訓練演算法也造成誤判。FNFD1 與 FNFD2 另外也有都誤判 1 張測試樣本，這張樣本也與人臉高度相似。非人臉的測試實驗中，FNFD2 的表現最差，雖然非人臉的影像較容易造成誤判，但是對於人臉影像的偵測能力相對表現較好，與其他兩種訓練演算法比較起來，進入到後端處理 FNFD2 要處理的問題比較沒有那麼複雜，對於通過篩選的非人臉可以透過進一步處理將誤判影像剔除。

NNFD 與 FNFD1 的問題在於前端篩選可能就容易遺失人臉，NNFD 對於一些複雜度高的人臉影像，不能夠明確偵測出來，當前端篩選就出現人臉遺失，到了後端處理的步驟也無法解決先前已經遺失的人臉，對於整體的辨識效能相對較差。

4.2.4 訓練次數與偵測效果實驗

測試 NNFD 與 FNFD2 在不同訓練次數，對於網路隨機收集測試樣本，非人臉測試樣本偵測效果的變化。將訓練次數調整為 40 萬次、80 萬次，對於誤判效果是否改善，以及收斂時間的比較。

類神經網路參數設定，訓練次數: 40 萬次、 η 學習速率: 0.3、 α 慣性參數: 0.5，訓練 40 萬次網路隨機收集測試實驗，如表 7 所示。

表 7 訓練 40 萬次網路隨機收集測試實驗


























人臉 演算法	1	2	3	4	5
					
NNFD	0.674286	0.914842	0.520138	0.684302	0.995756
FNFD2	0.997833	0.996296	0.997814	0.995509	0.995796
人臉 演算法	6	7	8	9	10
					
NNFD	0.474349	0.60952	0.961164	0.912062	0.334121
FNFD2	0.996428	0.997582	0.997622	0.995505	0.995514
人臉 演算法	11	12	13	14	15
					
NNFD	0.992977	0.997119	0.286157	0.517406	0.996784
FNFD2	0.997998	0.995673	0.995579	0.99559	0.995534
人臉 演算法	16	17	18	19	20
					
NNFD	0.582337	0.982638	0.997771	0.995265	0.997992
FNFD2	0.995505	0.997139	0.995585	0.996127	0.997999
人臉 演算法	21	22	23	24	25
					
NNFD	0.616619	0.924308	0.955735	0.948003	0.586032
FNFD2	0.995083	0.995508	0.997485	0.995732	0.995523

表 7 中的數值，代表系統對於這些影像是人臉的判定程度。二種訓練演算法:NNFD、FNFD2 在網路隨機收集測試實驗的探討，如表 8 所示。

表 8 訓練 40 萬次網路隨機收集測試實驗探討

演算法	轉換函式			錯誤偵測 (張)	訓練時間 (秒)
	Hidden 1	Hidden 2	Output		
NNFD	sigmoid	無	sigmoid	3	1675.92
FNFD2	sigmoid	sigmoid	sigmoid	0	1498.58

訓練 40 萬次的情況下，對於 FNFD2 的偵測效果沒有顯著差異，但是 NNFD 的測試結果雖然還是誤判 3 張影像，偵測結果判定模糊的影像卻增加兩張，收斂時間也需要較多。

類神經網路參數設定，訓練次數: 40 萬次、 η 學習速率:0.3、 α 慣性參數:0.5，訓練 40 萬次非人臉測試實驗，如表 9 所示。

表 9 訓練 40 萬次非人臉測試實驗

演算法	非人臉				
	1	2	3	4	5
NNFD	0.0126424	0.0217561	0.0562004	0.0004684	0.804689
FNFD2	0.997916	0.0013625	0.0026513	0.0025638	0.998001
演算法	非人臉				
	6	7	8	9	10
NNFD	0.0501416	0.0061528	0.0053215	0.0022883	0.0091815
FNFD2	0.0027292	0.0013113	0.627433	0.0013064	0.0015065

表 9 中的數值，代表系統對於這些影像是非人臉的判定程度。二種訓練演算法:NNFD、FNFD2 在非人臉測試實驗的探討，如表 10 所示。

表 10 訓練 40 萬次非人臉測試實驗探討

演算法	轉換函式			錯誤偵測 (張)	訓練時間 (秒)
	Hidden 1	Hidden 2	Output		
NNFD	sigmoid	無	sigmoid	1	1675.92
FNFD2	sigmoid	sigmoid	sigmoid	3	1498.58

類神經網路參數設定，訓練次數: 80 萬次、 η 學習速率:0.3、 α 慣性參數:0.5，80 萬次網路隨機收集測試實驗如表 11 所示。

表 11 訓練 80 萬次網路隨機收集測試實驗

演算法	人臉				
	1	2	3	4	5
NNFD	0.937475	0.975594	0.647764	0.840759	0.999169
FNFD2	0.998577	0.997365	0.998578	0.996748	0.996958
演算法	人臉				
	6	7	8	9	10
NNFD	0.566602	0.703094	0.99359	0.97904	0.490558
FNFD2	0.99755	0.998443	0.998442	0.996746	0.99675
演算法	人臉				
	11	12	13	14	15
NNFD	0.990255	0.998525	0.385031	0.877474	0.996883
FNFD2	0.998665	0.99686	0.996789	0.996796	0.996794
演算法	人臉				
	16	17	18	19	20
NNFD	0.47024	0.996839	0.998886	0.998364	0.993724
FNFD2	0.996746	0.998071	0.996796	0.99726	0.998665
演算法	人臉				
	21	22	23	24	25
NNFD	0.465618	0.851816	0.961853	0.985919	0.530494
FNFD2	0.996643	0.996747	0.998355	0.996887	0.996754

表 11 中的數值，代表系統對於這些影像是人臉的判定程度。二種訓練演算法:NNFD、FNFD2 在網路隨機收集測試實驗的探討，如表 12 所示。

表 12 訓練 80 萬次網路隨機收集測試實驗探討

演算法	轉換函式			錯誤偵測 (張)	訓練時間 (秒)
	Hidden 1	Hidden 2	Output		
NNFD	sigmoid	無	sigmoid	4	3345.34
FNFD2	sigmoid	sigmoid	sigmoid	0	3020.73

訓練 80 萬次之後作測試，NNFD 誤判增加編號 21，模糊判定的情況減少到只剩編號 3、6、7，訓練次數的增加改善了 NNFD 對於人臉判定的準確度，但是對於複雜度高的人臉影像增加誤判。

類神經網路參數設定，訓練次數: 80 萬次、 η 學習速率: 0.3、 α 慣性參數: 0.5，訓練 80 萬次非人臉測試結果，如表 13。

表 13 訓練 80 萬次非人臉測試實驗











非人臉 演算法	1	2	3	4	5
					
NNFD	0.0187543	0.0224312	0.102614	0.0005208	0.818809
FNFD2	0.998627	0.0009734	0.0021163	0.0017177	0.998665
非人臉 演算法	6	7	8	9	10
					
NNFD	0.0794554	0.0030125	0.0082415	0.0039635	0.0211534
FNFD2	0.0021834	0.0009435	0.794109	0.0009411	0.0010891

表 13 中的數值，代表系統對於這些影像是非人臉的判定程度。二種訓練演算法: NNFD、FNFD2 在非人臉測試實驗的探討，如表 14 所示。

表 14 訓練 80 萬次非人臉測試實驗探討

演算法	轉換函式			錯誤偵測 (張)	訓練時間 (秒)
	Hidden 1	Hidden 2	Output		
NNFD	sigmoid	無	sigmoid	1	3345.34
FNFD2	sigmoid	sigmoid	sigmoid	3	3020.73

NNFD 當訓練次數增加時，對於偵測效果的提升有限，但是卻需要較多的訓練時間。在這些實驗當中可以發現，本研究 FNFD2 所需要的訓練時間最短，並且能夠產生不錯的偵測效果。

4.3 人臉定位實驗結果與分析

4.3.1 BioID-FaceDatabase-V1.2 人臉資料庫測試

實驗樣本使用 BioID 人臉資料庫影像 [3]，採用含有背景與人臉的影像，資料庫影像尺寸為 286x384 pixels，進行人臉定位實驗。實驗樣本每張影像由 20x20 選取視窗進行偵測，將偵測結果經由高斯擴展後以閾值作界定，僅留下大於閾值的座標區塊，找出了人臉在影像

中的位置，如圖 25(左)所示。

實驗結果可以發現對於單一人臉的相片，可以有效的找出人臉的位置且不容易產生誤判，但單一女性人臉有重複找到相同人臉位置。




圖 25 BioID 人臉資料庫實驗結果(左)
網路隨機收集照片實驗結果(右)

4.3.2 網路隨機收集照片測試

網路隨機收集的相片，一張照片中有包含較多人臉，照片背景可能有比較極端的顏色出現，照片中的人臉可能會出現有大有小的狀況，如圖 25(右)所示。實驗照片包含三個人臉的測試照片，沒有產生誤判，但是對於包含兩張人臉的測試照片，除了遺失人臉外，還有同一張人臉重複框到的情形。

將金字塔擴展結果進行 OR 合併，可以減少人臉遺失的可能，誤判的區塊透過多次高斯擴展給予以排除。使用多人合照照片進行偵測與定位，此實驗使用二層金字塔進行偵測。原照片大小為 480x640 pixels，如圖 26 所示。

偵測結果遺失二張人臉，其中一張人臉因為頭部轉動角度過大造成偵測結果不佳，透過高斯擴展過後被閾值排除造成誤判，另一張人臉偵測結果略低於高斯擴展閾值，因而被排除而造成誤判，非人臉的誤判可能與本研究對非人臉區塊較為敏感所產生。



圖 26 多人合照實驗結果



圖 27 人臉辨識類神經網路影像樣本

4.4 人臉辨識實驗結果與分析

人臉辨識實驗的實驗人臉是從 ORL 人臉資料庫中收集而來，收集 20 個人各 10 張人臉影像總共 200 張人臉影像。這些人臉影像包含一些光線的變化，以及臉部表情變化例如眼睛的張開或閉合，有沒有笑，是否有戴眼鏡。這些人臉影像的大小縮放大約 10%，偏移以及旋轉的角度大約到 20 度，這些人臉影像如圖 27 所示。

實驗中會將 160 張人臉影像放入到類神經網路訓練，40 張人臉影像測試。將 20 個人編號 1~10，每次實驗一個人選取八個編號訓練，剩下兩個編號當作測試，平均誤差率[2]的計算使用這個公式計算：

$$E_{ave} = \frac{\sum_{i=1}^q n_{mis}^i}{q \times n_{tot}} \quad (16)$$

n_{mis}^i 代表每次測試所產生的誤判次數， n_{tot} 每次測試的人臉影像數量， q 代表測試次數。本研究將 200 張人臉影像分成 5 組實驗，每組實驗結果如下表 15 所示。

表 15 人臉辨識每組實驗結果

實驗組別	辨識錯誤人臉類別	誤判張數
第一組 (測試編號9 10)	5 15	2張
第二組 (測試編號7 8)	10 11 13	5張
第三組 (測試編號5 6)	12 13 19	3張
第四組 (測試編號3 4)	10 13 14 17	7張
第五組 (測試編號1 2)	12 15	2張

五組實驗總共誤判 19 張，透過平均誤差率公式算出平均誤差率為 0.095。

本實驗的 RBF 類神經網路的隱藏層神經元使用 50 個，輸出層神經元使用 20 個，第一組測試實驗採用每張人臉編號 1~8 放入類神經網路訓練，編號 9 以及編號 10 的人臉進行測試，以下實驗以第幾組測試實驗稱之。

第一組測試實驗

5 號人臉在編號 10 測試影像誤判成 6 號人臉，可能在 FCM 初步分群時分群錯誤，造成後續 RBF 訓練結果較差形成誤判。15 號人臉在編號 10 測試影像誤判成 18 號人臉，由於兩者人臉的訓練樣本相似度較高，造成 RBF 類神

經網路的誤判。總測試張數 40 張，Y 代表辨識正確，誤判 2 張實驗結果如附表一。

第二組測試實驗

11 號人臉編號 7、8 測試影像，都誤判成 16 號人臉，11 號和 16 號人臉的臉部特徵上都有鬍子，以及 11 號人臉的臉部變化較劇烈，這些影像容易造成誤判。13 號人臉在編號 7、編號 8，誤判成 6 號人臉以及 20 號人臉，這三組編號的人臉都有戴眼鏡，並且在訓練樣本中的人臉包含有戴眼鏡和沒戴眼鏡，對於監督式學習的類神經網路，在具有期望值的訓練過程中會造成收斂效果不佳產生誤判。總測試張數 40 張，誤判 5 張實驗結果如附表一。

第三組測試實驗

12 號人臉在編號 6 測試影像，誤判成 13 號人臉。12 號人臉的樣本中可以發現，臉部附近顏色較深，13 號人臉的影像包含有戴眼鏡的影像，人臉有戴眼鏡經過直方圖等化，眼睛附近的區塊顏色會較深，造成 12 號人臉與 13 號人臉可能相似度較高形成誤判。13 號人臉與 19 號人臉誤判情況，可能受到影像中的人臉有戴眼鏡的影響，造成辨識效果不佳。總測試張數 40 張，誤判 3 張實驗結果如附表一。

第四組測試實驗

13 號人臉編號 3、編號 4 都產生誤判，與訓練樣本的組成有關，這組實驗中 13 號人臉訓練樣本都是包含有戴眼鏡的人臉影像，測試樣本兩張剛好都沒有戴眼鏡。10 號人臉編號 3、編號 4 誤判成 8 號以及 12 號人臉，以及 17 號人臉編號 3、編號 4 都誤判成 3 號人臉，從這些人臉樣本中發現人臉影像具有一定程度的相似度，因此 FCM 初步分群容易造成分群錯誤。總測試張數 40 張，誤判 2 張實驗結果如附表一。

第五組測試實驗

12 號人臉在編號 1 測試影像，誤判成 3 號人臉，可能在 FCM 初步分群時分群錯誤，造成後續 RBF 訓練結果較差形成誤判。15 號人臉在編號 2 測試影像誤判成 18 號人臉，由於兩者人臉的訓練樣本相似度較高，造成 RBF 類神經網路的誤判。總測試張數 40 張，誤判 2 張實驗結果如附表一。

觀察這五組實驗結果可以發現，人臉影像中有無戴眼鏡、表情以及臉部特徵位移較大時容易造成誤判，訓練樣本與測試樣本互相參雜差異性較大的人臉影像，會對辨識效能產生影響。

4.5 實作實驗結果與分析

4.5.1 實作樣本

實作測試樣本圖片分為兩類型：1. 低複雜度背景人臉影像。2. 高複雜度人臉影像。這兩種圖片類型的人臉影像，包含有無戴眼鏡以及臉部轉動較劇烈，原影像圖片大小尺寸為 480×640 pixels，實作樣本如圖 28 所示。



圖 28 影像前置處理過後實作樣本

將樣本中出現的 6 張人臉進行編號由 $f_1 \sim f_6$ 代表，每個人臉編號收集 5 張生活照，來當作系統中人臉辨識類神經網路的訓練樣本。將經過偵測與定位找出的人臉影像區塊，使用訓練完成人臉辨識類神經網路進行辨識。

4.5.2 實驗結果與分析

利用四張實作樣本偵測結果進行高斯擴展定位，並對四張實作樣本定位結果進行辨識。在實驗過程發現高斯擴展定位會發生誤判的現象，故我們在高斯擴展定位的閾值部分作三種設定做測試，分別為 1.7、1.75、1.8，希望找出最能減少人臉遺失以及誤判的閾值，以達到最佳的定位效果。每種不同閾值對於通過人臉偵測的影像區塊篩選結果皆有些微的差異，而這些些微的差異皆會造成不同的定位結果，四張實驗用不同閾值定位結果，如圖 29、30、31、32 所示。

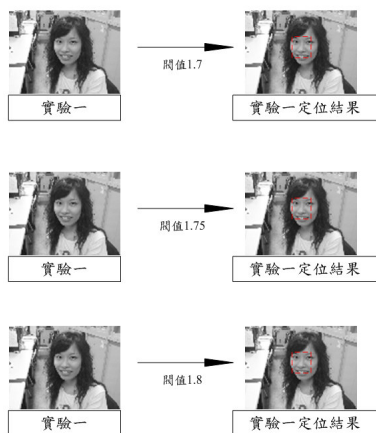


圖 29 實驗一偵測結果使用不同閾值進行高斯擴展定位

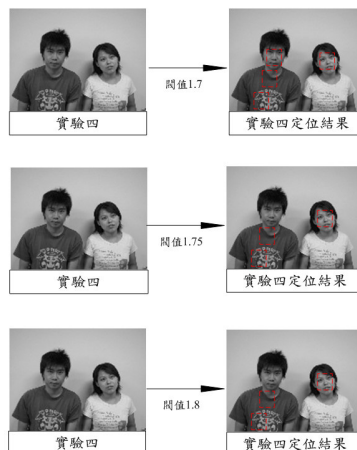


圖 32 實驗四偵測結果使用不同閾值進行高斯擴展定位




圖 30 實驗二偵測結果使用不同閾值進行高斯擴展定位



圖 31 實驗三偵測結果使用不同閾值進行高斯擴展定位

結果分析：

從四個實驗中可以發現當閾值使用 1.7 時能夠不遺漏人臉影像，並且誤判情況也不會太嚴重。

5. 結論與未來研究

本研究意在發展能偵測複雜人臉影像以及週遭雜訊去除不完全的人臉和識別人臉影像身分的系統，偵測實驗結果證明本研究提出的 FNFD2，對於週遭雜訊去除不完全人臉影像，以及人臉因為表情、動作產生位移的人臉影像，偵測效果明顯比 NNFD 好。FNFD2 將輸入影像透過重疊偵測區塊，將臉部特徵偵測出來，經由特徵擷取隱藏層訓練，使 FNFD2 比 NNFD 對於臉部特徵擁有更好的敏感度。

在人臉辨識上，本研究使用模糊邏輯概念的 FCM 分群演算法，降低分群錯誤的機率，透過 RBF 類神經網路訓練並進行辨識，從測試實驗中也能達到不錯的辨識效果。

在人臉辨識的研究中，雖然能提高人臉偵測效能，但對於非人臉的誤判增加，會連帶降低辨識效能，這個部份仍待解決，也是我們未來研究的方向之一。

另外，在人臉辨識的方法中初步分群的好壞，將會影響到後續 RBF 類神經網路的效能，對於如何改善分群的效果並且降低分群錯誤也是相當重要的，所以我們未來的研究也想朝這個方向進一步的探討與改善，並且將我們的人臉辨識系統發展更完善，提升對於應用到實務上的效果。

6. 致謝

本論文承蒙義守大學校內專題研究計畫 ISU98-01-12 經費補助，特此致謝。

參考文獻

[1]Delakis, M. and Garcia, C., “Robust face detection based on convolutional neural networks,” *in Proc. of the Second Hellenic Conference on Artificial Intelligence*, Thessalonique, Greece, pp.367-378, 2002.

[2]Er, M. J., Wu, S. and Lu, J., “Face recognition With Radial Basis Function(RBF) Neural Networks,” *IEEE TRANSACTIONS ON NEURAL NETWORKS*, vol.13, no.3, pp.697-710, May 2002.

[3]Frischolz, R. W. and Dieckmanu, U., “BioID: A multimodal biometric identification system,” *IEEE Compute*, 33(2), 2000.

[4]Lu, J., Yuan, X. and Takashi Yahagi., “A Method of Face Recognition Based on Fuzzy c-Means Clustering and Associated Sub-NNs,” *IEEE TRANSACTIONS ON NEURAL NETWORKS*, vol. 18, no. 1, Jan. 2007.

[5]Lu, J., Yuan, X. and Yahagi, T., “A Method of Face Recognition Based on Fuzzy c-Means Clustering and Associated Sub-NNs,” *Neural Networks, IEEE*, vol.18, Issue 1, pp.150-160, Jan. 2007.

[6]Peng, K., Chen, L., Ruan, S. and Kukharev, G., “A Robust Algorithm for Eye Detection on Gray Intensity Face without Spectacles,” *JCS&T*, Vol. 5, No. 3, 2005.

[7]Rowley, H. A., Baluja, S. and Kanade, T., “Neural Network-Based Face Detection,” *IEEE Trans. PAMI*, Vol. 20, No. 1, Jan. 1998.

[8]Rhee, F. C. and Lee, C., “Region based fuzzy neural networks for face detection,” *IFSA World Congress and NAFIPS*, Vol. 2, pp. 25-28, July. 2001.

[9]Stathopoulou, I. O. and Tsihrantzis, G. A., “An improved neural-network-based face detection and facial expression classification system,” *IEEE*, 2004.

[10] Yang, K., Zhu, H. and Pan, Y. J., “Human Face Detection Based on SOFM Neural Network,” *Proceedings of the 2006 IEEE International Conference on Information Acquisition*, August 20-23, 2006.

[11] 蔡賢亮、蔡佩君、周煜書，“Feature-based Neural Face Detection,” *2008 資訊科技國際研討會論文集*，2008。

附表一

人臉編號 9、10 辨識結果

人臉 辨識結果	1	2	3	4	5
編號9	Y	Y	Y	Y	Y
人臉 辨識結果	6	7	8	9	10
編號9	Y	Y	Y	Y	Y
人臉 辨識結果	11	12	13	14	15
編號9	Y	Y	Y	Y	Y
人臉 辨識結果	16	17	18	19	20
編號9	Y	Y	Y	Y	Y
人臉 辨識結果	1	2	3	4	5
編號10	Y	Y	Y	Y	列成6號人臉
人臉 辨識結果	6	7	8	9	10
編號10	Y	Y	Y	Y	Y
人臉 辨識結果	11	12	13	14	15
編號10	Y	Y	Y	Y	列成18號人臉
人臉 辨識結果	16	17	18	19	20
編號10	Y	Y	Y	Y	Y

附表一

人臉編號 7、8 辨識結果

人臉	1	2	3	4	5
辨識結果					
編號7	Y	Y	Y	Y	Y
人臉	6	7	8	9	10
辨識結果					
編號7	Y	Y	Y	Y	判成17號人臉
人臉	11	12	13	14	15
辨識結果					
編號7	判成16號人臉	Y	判成6號人臉	Y	Y
人臉	16	17	18	19	20
辨識結果					
編號7	Y	Y	Y	Y	Y
人臉	1	2	3	4	5
辨識結果					
編號8	Y	Y	Y	Y	Y
人臉	6	7	8	9	10
辨識結果					
編號8	Y	Y	Y	Y	Y
人臉	11	12	13	14	15
辨識結果					
編號8	判成16號人臉	Y	判成20號人臉	Y	Y
人臉	16	17	18	19	20
辨識結果					
編號8	Y	Y	Y	Y	Y

人臉編號 3、4 辨識結果

人臉	1	2	3	4	5
辨識結果					
編號3	Y	Y	Y	Y	Y
人臉	6	7	8	9	10
辨識結果					
編號3	Y	Y	Y	Y	判成8號人臉
人臉	11	12	13	14	15
辨識結果					
編號3	Y	Y	判成12號人臉	判成7號人臉	Y
人臉	16	17	18	19	20
辨識結果					
編號3	Y	判成3號人臉	Y	Y	Y
人臉	1	2	3	4	5
辨識結果					
編號4	Y	Y	Y	Y	Y
人臉	6	7	8	9	10
辨識結果					
編號4	Y	Y	Y	Y	判成12號人臉
人臉	11	12	13	14	15
辨識結果					
編號4	Y	Y	判成12號人臉	Y	Y
人臉	16	17	18	19	20
辨識結果					
編號4	Y	判成3號人臉	Y	Y	Y

人臉編號 5、6 辨識結果

人臉	1	2	3	4	5
辨識結果					
編號5	Y	Y	Y	Y	Y
人臉	6	7	8	9	10
辨識結果					
編號5	Y	Y	Y	Y	Y
人臉	11	12	13	14	15
辨識結果					
編號5	Y	Y	Y	Y	Y
人臉	16	17	18	19	20
辨識結果					
編號5	Y	Y	Y	Y	Y
人臉	1	2	3	4	5
辨識結果					
編號6	Y	Y	Y	Y	Y
人臉	6	7	8	9	10
辨識結果					
編號6	Y	Y	Y	Y	Y
人臉	11	12	13	14	15
辨識結果					
編號6	Y	判成13號人臉	判成20號人臉	Y	Y
人臉	16	17	18	19	20
辨識結果					
編號6	Y	Y	Y	判成4號人臉	Y

人臉編號 1、2 辨識結果

人臉	1	2	3	4	5
辨識結果					
編號1	Y	Y	Y	Y	Y
人臉	6	7	8	9	10
辨識結果					
編號1	Y	Y	Y	Y	Y
人臉	11	12	13	14	15
辨識結果					
編號1	Y	判成3號人臉	Y	Y	Y
人臉	16	17	18	19	20
辨識結果					
編號1	Y	Y	Y	Y	Y
人臉	1	2	3	4	5
辨識結果					
編號2	Y	Y	Y	Y	Y
人臉	6	7	8	9	10
辨識結果					
編號2	Y	Y	Y	Y	Y
人臉	11	12	13	14	15
辨識結果					
編號2	Y	Y	Y	Y	判成18號人臉
人臉	16	17	18	19	20
辨識結果					
編號2	Y	Y	Y	Y	Y