

Feature-based Neural Face Detection

蔡賢亮
義守大學
資訊管理學系
助理教授

jim@isu.edu.tw

蔡佩君
義守大學
資訊管理學系

m9522005@
stmail.isu.edu.tw

周煜書
義守大學
資訊管理學系

m9522021@
stmail.isu.edu.tw

摘要

本研究旨在改善 Rowley 於 1998 年提出 neural network-based face detection(NNFD)類神經網路應用於人臉偵測的演算法，並發展新的人臉偵測演算法[11]。NNFD 對於偵測垂直、正向的人臉有很好的表現，但是對於複雜度高的人臉，週遭雜訊去除不完全的人臉，偵測效果不佳。本論文中，我們提出二種改良(FNFD1, FNFD2)的人臉偵測演算法。我們改良 NNFD 隱藏層類神經元的偵測區塊，藉由重疊偵測區塊，提高偵測因表情或者動作產生位移的臉部特徵位置，並加入新的特徵擷取隱藏層，使我們的演算法比 NNFD 多了對於臉部特徵的敏感度。另外，從實驗數據中，我們再刪除 FNFD1 架構中冗餘且不影響整體辨識效能的部分。從實驗數據來分析，我們的演算法有較佳容錯力、辨識效能，且訓練時間較短。

關鍵詞：倒傳遞類神經網路、特徵擷取隱藏層、人臉偵測、直方圖等化。

Abstract

The purpose of this paper is to improve the framework of neural network-based face detection (NNFD) [11] proposed by Rowley (1998) and develop two new feature-based neural face detecting algorithms. Despite the experiment results of NNFD have good performance to detect upright, frontal views of face, but the results of detecting complex and noisy face images should be improved. In this paper, we propose the following two improving algorithms (FNFD1 and FNFD2). We improve the detecting area of NNFD's hidden layer first. Our algorithms detect specific features from shifted face image by overlapping the detecting area to increase detecting ability. Furthermore, we add a new hidden layer to collect specific features of face (e.g. eyes, nose and mouth). This

can increase the sensitivity in detecting specific features from shifted face image. Experimental results show our algorithms have better efficiency of the face detection and less training time of neural networks.

Keywords: back propagation neural networks, feature extraction layer, face detection, histogram equalization.

1. 前言

由於利用人工智慧處理圖形辨識的應用越來越蓬勃，辨識技術中的人臉辨識系統，其發展也有二十幾年了，人臉辨識系統的架構主要可以分為：人臉偵測與定位、人臉特徵的擷取與人臉辨識這三部份。

人臉偵測主要目的，偵測一張影像中是否有人臉存在，以及人臉的大略位置。然而要判斷目標影像是否有人臉的時候，會因為複雜的背景，以及影像中人臉的大小、角度、方向及膚色等因素而增加影像偵測的困難度。人臉偵測方面主要可以區分下列幾種方法：(1)邊緣 (edges)：最早將邊緣描繪 (edge representation) 用在人臉偵測的技術是 Sakai。他用照片分析出人臉的線條來找出特徵。Craw 提出了一種階層式架構 (hierarchical frame work) 的方法來追蹤人臉的輪廓。此方法包含了一個線跟隨器 (line-follower) 用曲線限制防止在有雜訊邊緣時無法集中的問題。而最常用的方法是 Sobel 濾波器，尚包括 Marr-Hildreth 邊緣方法。而廣為人知的 Gaussians 模型常被用在許多方面，如大規模的 Laplacian 運算來獲得線條和能轉向性能、經尺度方面濾波器等。Govindaraju 透過把邊緣標明為臉正視圖的左側面，細線或者是右側面來達到邊緣偵測的基準，使用黃金比例作為一種理想的臉形，使得邊緣符合臉部模型。(2)膚色：由於顏色有較多維的資訊，二個相似的灰色形狀看起來會不同。當比較不同種族的人臉時，在色彩空間中，不同種族膚色會引起一

種密集叢集 (tight cluster)。皮膚外觀上的主要變化大部分是亮度的變化。(3)灰階 (gray-levels): 臉部灰色的變化或特徵也可用來作為偵測臉部位置的依據, 如眉毛、眼睛的瞳孔仁、嘴唇通常比他們周遭的臉部區域在灰階影像中較黑。這種性質可以用來區別各種臉部區塊。Wong 從顏色分析間接的獲得臉部候選者, 並從其中自動的尋找臉部。這種演算法使用一種權重人眼模板 (weighted human eye template) 來決定雙眼的可能位置。(4)類神經網路 (neural networks): Rowley 以倒傳遞類神經網路來偵測人臉, 也有其他研究運用模糊類神經網路、convolution 類神經網[1,2,3,4,9]。

Rowley 提出 neural network-based face detection(NNFD)類神經網路人臉偵測演算法, 對於正向垂直人臉有很好的偵測能力。但是當人臉的角度、轉動變化較大, 偵測能力就沒有那麼出色, 針對這些問題本研究提出二個改良之演算法(FNFD1, FNFD2)來改善其效能, 在本論文中, 我們將以 FNFD2 演算法為主, 所以之後的章節也以此演算法來做介紹, 但實驗部份, 我們會以這三個演算法共同比較、分析與探討。

2. 系統描述

本章節中, 我們首先介紹 Rowley 提出之 NNFD 演算法, 並探討其優缺點, 接著介紹我們所提出的二個改良演算法 (FNFD1, FNFD2), 並對這三個演算法做深入分析與探討。

2.1 Neural Network-Based Face Detection (NNFD)

Rowley 於 1998 年提出這個演算法, 應用類神經網路偵測一張 20×20 灰階影像區塊, 判斷這張 20×20 輸入影像是否有人臉存在。當偵測的人臉影像大於影像區塊, 便使用影像金字塔調整大小, 透過影像金字塔可以偵測到灰階影像的每個位置。

影像區塊輸入到類神經網路, 來判斷是否有人臉存在時, 必須先經過影像前置處理。影像區塊選定後, 先通過一個橢圓形遮罩, 影像在這個遮罩之外的部分將會被視為背景, 這樣可以不用計算臉部週遭的亮度變化, 再使用線性方程式調整通過橢圓形遮罩的人臉影像, 使整體影像亮度變化不會太劇烈。經過前面步驟接著使用直方圖等化, 使灰階值非線性分佈到影像區塊中, 透過直方圖等化改善影像區塊的對比, 影像區塊經過處理後再輸入到類神經網

路。

類神經網路由一層輸入層、一層隱藏層、一層輸出層組成, 隱藏層中的類神經元有三種型態: 4 個 H1 隱藏層類神經元, 負責處理及偵測輸入影像中 10×10 大小的不同位置之子影像區塊、16 個 H2 隱藏層類神經元, 負責處理及偵測輸入影像中 5×5 大小的不同位置之子影像區塊、6 個 H3 隱藏層類神經元, 負責處理及偵測輸入影像中 5×20 大小的不同水平位置之子影像區塊。這三種型態的類神經元被用來偵測局部臉部特徵, 水平類神經元用來偵測水平臉部特徵, 例如: 一對眼睛、嘴巴, 正方形類神經元用來偵測單獨臉部特徵, 例如: 眼睛、鼻子、嘴角, 這個類神經網路的輸出層會輸出一個數值, 來表示影像區塊是否有人臉存在, 類神經網路架構如圖 1 所示。




圖 1 NNFD 類神經網路架構

類神經網路的訓練方式, 收集大量的人臉與非人臉樣本, 從 CMU 人臉資料庫、Harvard、World Wide Web 收集大約 1050 人臉樣本, 這些人臉樣本的大小、角度、位置、亮度都有不同, 用手動去標記每張人臉的特徵如眼睛、鼻子、嘴巴。這些用來對每張臉正規化成相同大小、方向、位置。將 1050 張先前標記的人臉樣本特徵平均, 將這些平均值當成初始值 $\bar{F}$, 從第一張人臉樣本 F_1 開始做調整, 透過線性方程式算出 F_1 和 $\bar{F}$ 的最小平方解, 產生最佳的調整參數 F_1' , 更新 $\bar{F}$ 透過平均每張臉最佳的調整參數 F_i' , $i=1 \sim n$ 。非人臉的訓練方式, 先隨機選取 1000 張不包含人臉,

經過前置處理的影像當作初始訓練樣本，網路輸出值1為人臉、-1為非人臉。類神經網路初始權重隨機產生，使用誤差倒傳遞來訓練類神經網路，將訓練完成的類神經網路，使用1張不包含人臉的風景影像來做測試，當中有誤判為人臉的影像收集起來，再放入類神經網路訓練。

NNFD 對於偵測垂直、正向的人臉有很好的表現，但是當輸入影像亮度變化沒辦法去除的很乾淨時，NNFD 偵測效果便會下降。當設0.5為門檻值來決定是否為人臉，NNFD 對於週遭雜訊去除不完全以及角度、轉動變化較大的人臉，NNFD 類神經網路偵測結果會有模糊判定的狀況。NNFD 類神經網路在非人臉樣本的收集部分，從訓練期間收集誤判的非人臉影像，將這些誤判影像加入類神經網路中訓練，這樣的方式當非人臉訓練數量超過人臉時，會造成 NNFD 類神經網路對於人臉與非人臉的判定變模糊。

2.2 FNFD1 演算法

FNFD1 想要改善類神經網路對於高複雜度人臉的偵測能力，NNFD 使用的三種類神經元型態當中，負責處理及偵測正方形子影像區塊的類神經元，都沒有重疊偵測區塊。這樣偵測人臉特徵的準確度不夠高，所以當人因表情、動作改變臉部位置時，便容易偵測不完全。

FNFD1 修改 NNFD 的 H1 類神經元型態來應對這種狀況，雖然人因為動作使得臉部位置變化，但輸入到類神經網路的影像都經過前置處理，影像區塊的影像變化程度已經減少許多。在影像區塊當中的人臉，臉部特徵位移只有幾個像素，FNFD1 的 H1 類神經元型態有9個 H1 隱藏層類神經元，負責處理及偵測輸入影像中8×8大小的不同位置之子影像區塊，每個子影像偵測區塊重疊2個像素值，透過對於同一個特徵的重複偵測，來提高人臉特徵位置的準確度。

FNFD1 的 H2 類神經元型態有25個 H2 隱藏層類神經元，負責處理及偵測輸入影像中4×4大小的不同位置之子影像區塊，每個子影像偵測區塊並沒有重疊，透過將偵測範圍縮小來增加同一個臉部特徵的偵測次數，當臉部特徵位移時，小範圍和多次的偵測來提高準確度。FNFD1 第一層隱藏層各個區塊的輸出值，將提供給新增的特徵擷取隱藏層，當作輸入值來訓練類神經網路。

在使用臉部特徵模版來尋找臉部位置的研究中，有使用眼睛特徵模版來比對。另外有研究藉由先找眼睛範圍，經由眼睛範圍來定出人臉位置，這些相關研究可以發現眼睛在人臉偵測中的重要性[7,12]。所以 FNFD1 將眼睛特徵擷取出來訓練，但要是只加強對於眼睛特徵的訓練，當非人臉影像有類似眼睛的區塊時，便容易造成誤判。所以在特徵擷取隱藏層中另外加入鼻子、嘴巴、臉頰等特徵來訓練，FNFD1 的特徵擷取隱藏層 f1 代表眼睛特徵類神經元、f2 代表鼻子特徵類神經元、f3 代表嘴巴特徵類神經元、f4 代表臉頰特徵類神經元，FNFD1 的類神經網路架構，如圖2所示。




圖 2 FNFD1 類神經網路架構

類神經網路的訓練方式，從 ORL 人臉資料庫中收集人臉訓練樣本，非人臉樣本從 World Wide Web 中收集。人臉樣本的大小、位置、角度、亮度都不同，FNFD1 的訓練樣本由25張人臉和25張非人臉隨機穿插組成。FNFD1 類神經網路訓練時，採用監督式學習的訓練方法。類神經網路期望值0代表非人臉、1代表人臉，透過網路真實輸出值的誤差，採用誤差導傳遞來訓練類神經網路。FNFD1 增加非人臉訓練樣本的方法，不採用大量增加誤判的非人臉測試樣本，避免人臉訓練樣本數量比非人臉樣本少，造成收斂後的類神經網路對於人臉和非人臉的判定變模糊。FNFD1 在實驗過程中，對於臉部特徵的敏感度，造成臉部影像特徵位移較大時容易造成誤判，使得偵測能力提升有限。FNFD1 的 H2 類神經元偵測範圍小、次數多，使用了大量的計算，對於類神經網路的收斂速度造成不良影響。

2.3 FNFD2 演算法

為了改善 FNFD1 在實驗中發現的問題，所以將 FNFD1 類神經網路的架構再調整，產生了 FNFD2。想要改善類神經網路收斂速度，觀察了 FNFD1 類神經元的收斂權重，發現 H2 類神經元因為偵測範圍小、次數多，反而造成臉部特徵的重要性被削減。FNFD1 第一層隱藏層、第二層隱藏層的收斂權重中，H2 類神經元收斂權重值與 H1、H3 類神經元相比，對於整體辨識效能影響不大，並且因為使用大量權重，對訓練時間造成不良影響。

FNFD2 的類神經網路架構，是將 FNFD1 中的 25 個 4×4 正方形區塊拿掉。在實驗中發現這樣可以降低 FNFD1 對於特徵位移過於敏感的問題，誤判的狀況也有減少，收斂速度明顯增加，FNFD2 的類神經網路架構，如圖 3 所示。




圖 3 FNFD2 類神經網路架構

FNFD2 類神經網路的訓練方式和訓練樣本的收集，都與 FNFD1 相同。FNFD2 對於角度、轉動、週遭雜訊去除不完全的複雜人臉，在偵測上有不錯的效果。

2.4 系統架構

NNFD、FNFD1、FNFD2 這三種人臉偵測系統，都使用相同架構。將尺寸大小不一的影像，輸入影像金字塔調整大小，調整後影像經過前置處理，再輸入人臉偵測系統，偵測影像中是否有人臉存在，如圖 4 所示。




圖 4 人臉偵測系統架構

3. 影像前置處理

當灰階影像輸入到類神經網路前，會先經過一些前置處理，之後才將經過處理的灰階影像輸入類神經網路。對於灰階影像並不是全部都處理，只對影像區塊進行前置處理，被選取的 20×20 區塊才是要輸入到類神經網路的影像，如圖 5 所示。




圖 5 影像前置處理

3.1 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法可使影像中大小不一的人臉更容易的被偵測到，如圖 6 所示。




圖 6 影像金字塔

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 7 所示。




圖 7 選取視窗

3.2 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，使灰階度的直方圖盡可能呈現均勻分佈，如此可提高影像的對比度，得到較清晰的影像，如圖 8 所示。



圖 8 直方圖等化

4 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，用來偵測臉部水平的特徵例如：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 9 所示。




圖 9 特徵擷取

4.1 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 10 所示。




圖 10 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 11。




圖 11 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：

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

$k = 1, \dots, 4$

Out_z 代表輸出層 Z 的輸出值， Out_{fk} 代表特徵擷取隱藏層的輸出值， w_{zk} 代表輸出層權重值， b_z 代表輸出層偏權值，如圖 12。




圖 12 第二層隱藏層到輸出層

整個 FNFD2 系統架構，如圖 13 所示。




圖 13 FNFD2

倒傳遞階段網路的權重值修正量，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：

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

$$i = 0, 1, 2$$

$\Delta w_{H1,i}^{f1}$ 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：

$$\Delta w_{H1,i}^{f1}(n) = \alpha \Delta w_{H1,i}^{f1}(n-1) + \eta \delta_{f1}(n) y_{H1,i}(n), \quad (5)$$

$$i = 0, 1, 2$$

α 代表一個大於零的常數，稱為慣性常數，用來控制 $\Delta w_{H1,i}^{f1}(n)$ 的修正量，通常網路為了收斂，慣性常數的大小會限制為： $0 \leq \alpha < 1$ 。

FNFD2 倒傳遞推導，有三個倒傳遞部分：介於輸出層與第二層隱藏層的權重部分、介於第二層隱藏層與第一層隱藏層的權重部分、介於第一層隱藏層與輸入層的權重部分。

輸出層與第二層隱藏層的倒傳遞推導：

$$\begin{aligned} \frac{\partial E}{\partial w_{z_1}} &= \frac{\partial \frac{1}{2}(y-d)^2}{\partial w_{z_1}} \\ &= \frac{\partial \frac{1}{2}(y-d)^2}{\partial y} \frac{\partial y}{\partial w_{z_1}} \\ &= (y-d) \frac{\partial g(v)}{\partial v} \frac{\partial v}{\partial w_{z_1}} \\ &= (y-d)g(v)(1-g(v))Out_{f1} \end{aligned} \quad (6)$$

y 代表真實輸出， d 代表樣本期望值， w_{z_1} 代表第二層隱藏層的 f1 特徵擷取類神經元與輸出層的 z 類神經元的連接權重值， $g(v)$ 代表 z 類神經元輸出值， Out_{f1} 代表第二層隱藏層的 f1 特徵擷取類神經元輸出值，如圖 14 所示。




圖 14 輸出層倒傳遞回第二層隱藏層

第二層隱藏層與第一層隱藏層的倒傳遞推導：

$$\begin{aligned} \frac{\partial E}{\partial w_{f1}^{(0,0)}} &= \frac{\partial E}{\partial Out_{f1}} \frac{\partial Out_{f1}}{\partial w_{f1}^{(0,0)}} \\ &= \frac{\partial E}{\partial y} \frac{\partial y}{\partial Out_{f1}} \frac{\partial Out_{f1}}{\partial w_{f1}^{(0,0)}} \\ &= (y-d) \frac{\partial g(v)}{\partial v} \frac{\partial v}{\partial Out_{f1}} \frac{\partial Out_{f1}}{\partial w_{f1}^{(0,0)}} \\ &= (y-d)g(v)(1-g(v))w_{z_1} Out_{H1}^{(0,0)} \end{aligned} \quad (7)$$

Out_{f1} 代表第二層隱藏層的 f1 特徵擷取類神經元輸出值， $w_{f1}^{(0,0)}$ 代表第二層隱藏層的 f1 特徵擷取類神經元與第一層隱藏層的 H1 類神經元 (0,0) 偵測區塊的連接權重值， $Out_{H1}^{(0,0)}$ 代表第一層隱藏層的 H1 類神經元 (0,0) 偵測區塊輸出值， $g(v)$ 代表 z 類神經元輸出值， w_{z_1} 代表第二層隱藏層的 f1 特徵擷取類神經元與輸出層的 z 類神經元的連接權重值， y 代表真實輸出， d 代表樣本期望值，如圖 15 所示。




圖 15 第二層隱藏層倒傳回第一層隱藏層

第一層隱藏層與輸入層的倒傳遞推導：

$$\begin{aligned}
 \frac{\partial E}{\partial w_k^{(0,0)}} &= \frac{\partial E}{\partial Out_{H1}^{(0,0)}} \frac{\partial Out_{H1}^{(0,0)}}{\partial w_k^{(0,0)}} \\
 &= \frac{\partial E}{\partial Out_{f1}^{(0,0)}} \frac{\partial Out_{f1}^{(0,0)}}{\partial Out_{H1}^{(0,0)}} \frac{\partial Out_{H1}^{(0,0)}}{\partial w_k^{(0,0)}} \\
 &= \frac{\partial E}{\partial y} \frac{\partial y}{\partial Out_{f1}^{(0,0)}} \frac{\partial Out_{f1}^{(0,0)}}{\partial Out_{H1}^{(0,0)}} \frac{\partial Out_{H1}^{(0,0)}}{\partial w_k^{(0,0)}} \\
 &= \frac{\partial \frac{1}{2}(y-d)^2}{\partial y} \frac{\partial y}{\partial Out_{f1}^{(0,0)}} \frac{\partial Out_{f1}^{(0,0)}}{\partial Out_{H1}^{(0,0)}} \frac{\partial Out_{H1}^{(0,0)}}{\partial w_k^{(0,0)}} \\
 &= (y-d) \frac{\partial g(v)}{\partial v} \frac{\partial v}{\partial Out_{f1}^{(0,0)}} \frac{\partial Out_{f1}^{(0,0)}}{\partial Out_{H1}^{(0,0)}} \frac{\partial Out_{H1}^{(0,0)}}{\partial w_k^{(0,0)}} \\
 &= (y-d)g(v)(1-g(v))w_{z_1} \times \\
 &\quad \frac{\partial f(v)}{\partial v} \frac{\partial v}{\partial Out_{H1}^{(0,0)}} \frac{\partial Out_{H1}^{(0,0)}}{\partial w_k^{(0,0)}} \\
 &= (y-d)g(v)(1-g(v))w_{z_1} \times \\
 &\quad f(v)(1-f(v))w_{f1}^{(0,0)} Input_k \quad (8) \\
 &\quad k = 0, \dots, 63
 \end{aligned}$$

$w_k^{(0,0)}$ 代表第一層隱藏層的 H_1 類神經元 (0,0) 區塊權重值， $Out_{H1}^{(0,0)}$ 代表第一層隱藏層的 H_1 類神經元 (0,0) 區塊輸出值， Out_{f1} 代表第二層隱藏層的 $f1$ 眼睛特徵類神經元輸出值， $Input_k$ 是從 20×20 輸入影像中從左至右，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， $w_{f1}^{(0,0)}$ 代表第二層隱藏層的 $f1$ 特徵擷取類神經元與第一層隱藏層的 $H1$ 類

神經元 (0,0) 偵測區塊的連接權重值， w_{z_1} 代表第二層隱藏層的 $f1$ 特徵擷取類神經元與輸出層的 z 類神經元的連接權重值， $g(v)$ 代表 z 類神經元輸出值， $f(v)$ 代表代表第二層隱藏層的 $f1$ 特徵擷取類神經元輸出值， y 代表真實輸出， d 代表樣本期望值，如圖 16 所示。




圖 16 第一層隱藏層倒傳回輸入層

5. 實驗結果

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 17。




圖 17 人臉訓練樣本

5.1 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，這些測試影像的雜訊、傾斜方向、表情變化程度比較小，資料庫的人臉影像，經過前置處理之後

的對比效果較佳，如表 1 所示。

表 1 ORL 人臉資料庫測試實驗

人臉 演算法	1	2	3	4	5
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 演算法	6	7	8	9	10
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 演算法	11	12	13	14	15
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 演算法	16	17	18	19	20
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 演算法	21	22	23	24	25
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。

5.2 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，這次測試樣本的雜訊、傾斜角度、表情的變化，相較於 ORL 人臉資料庫中選取的樣本有比較明顯的變化，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

人臉 演算法	1	2	3	4	5
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
人臉 演算法	6	7	8	9	10
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	11	12	13	14	15
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
人臉 演算法	16	17	18	19	20
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	21	22	23	24	25
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 5.2 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，這種狀況在後端處理上會增加許多複雜度。FNFD1 誤判 3 張人臉影像，但對於沒有誤判的人臉影像，與 NNFD 相比較起來確定性較高。FNFD1 對於判定通過的人臉有高的確定性，可以降低後端處理的複雜度，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。

在 5.2 測試實驗中 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 NNFD 對許多判定通過的人臉，存在著不明確的偵測結果，當門檻值設定較嚴謹時，NNFD 演算法的偵測能力就有待加強。

FNFD1 對於輸入影像的局部偵測區塊複雜度，在 3 種演算法中是最高的。FNFD1 由於臉部特徵的高敏感度，對於臉部特徵位移劇烈的影像，容易造成誤判。

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，但是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。

5.3 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

5.3 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度。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。

5.4 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

演算法 \ 人臉	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
演算法 \ 人臉	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
演算法 \ 人臉	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
演算法 \ 人臉	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
演算法 \ 人臉	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。訓練 40 萬次非人臉測試實驗，如表 9。

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

人臉 演算法	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
人臉 演算法	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
人臉 演算法	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
人臉 演算法	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
人臉 演算法	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。

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

6. 結論

本研究意在發展偵測複雜人臉影像的演算法，實驗結果證明 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。重疊偵測區塊，提高人臉特徵位移的偵測準確度，透過特徵擷取隱藏層，對於週遭雜訊去除不完全所造成的偵測率下降，可以得到明顯改善。

實驗結果證明 NNFD 與 FNFD2 相較之下，在訓練次數與偵測效果上有不穩定的現象，NNFD 增加訓練次數對於複雜度高的人臉

沒辦法提升偵測效果，誤判張數還增加，相同訓練次數實驗中，FNFD2 也比 NNFD 使用較少訓練時間。本研究的 FNFD2 經過實驗證明，對於複雜人臉影像有不錯的偵測能力，與臉部定位演算法結合，將 FNFD2 所造成的誤判排除，便可以發展更有效率的人臉辨識系統。

在實驗過程中發現 FNFD2 的缺點，提升訓練次數不能減少誤判，非人臉的測試實驗容易誤判，這些缺點造成 FNFD2 無法更有效提升偵測效果。未來研究方向希望透過使用新型態類神經元，改善 FNFD2 的偵測效果。對於 FNFD2 的結構進一步修改，發展新的人臉定位演算法，將兩者結合使系統更加完善。

7. 未來研究

近來有研究使用 generalized shunting neuron (GSN)類神經元，將 GSN 類神經元應用在人臉偵測[5,6,13]。GSN 類神經元是由傳統感知器與分流抑制類神經元所組成，對於複雜的辨識問題，有不錯的解決能力。可以使用較少的 GSN 類神經元，解決複雜的辨識問題。在未來研究上，FNFD2 使用 GSN 類神經元建構類神經網路架構，減少類神經網路較大時，類神經元連結數量多，所造成 overfitting 的情況，來提升辨識效果。

基因演算法在自動選取最佳化，有不錯的效果[10]。透過這個優點，最近的研究廣泛應用到樣本辨識，也使用基因演算法去尋找影像中人臉位置[8]。未來本研究希望藉由基因演算法，發展人臉定位演算法，配合 FNFD2 應用到人臉辨識的研究。

8. 致謝

本論文承蒙九十五年度國科會研究計畫 NSC95-2221-E-214-065-經費補助，特此致謝。

參考文獻

- [1] A. Z. Kouzani, F. He and K. Sammut, "Towards Invariant Face Recognition," *Information Sciences*, Vol. 123, pp. 75-101, 2000.
- [2] F. H. C. Tivive and A. Bouzerdoun, "Efficient training algorithms for a class of shunting inhibitory convolutional neural networks," *IEEE*, Vol. 16, No. 3, pp. 541-556, 2005.
- [3] Frank Chung-Hoon Rhee, Changsu Lee, "Region based fuzzy neural networks for face detection," *IFSA World Congress and NAFIPS*, Vol. 2, pp. 25-28, July. 2001.
- [4] F. Tivive and A. Bouzerdoun, "A new class of convolutional neural network (siconnets) and their application to face detection," *Proc. of the International Joint Conference on Neural Networks*, Vol. 3, pp. 2157-2162, 2003.
- [5] G. Arulampalam and A. Bouzerdoun, "A Generalized Feedforward Neural Network Classifier," *Neural Networks*, Vol. 16, pp. 561-568, 2003.
- [6] G. Arulampalam and A. Bouzerdoun, "Expanding the structure of shunting inhibitory artificial neural network classifier," *Proc. Int. Joint Conf. on Neural Network*, pp. 2855-5860, 2002.
- [7] Kun Peng, Liming Chen, Su Ruan, Georgy Kukharev, "A Robust Algorithm for Eye Detection on Gray Intensity Face without Spectacles," *JCS&T*, Vol. 5, No. 3, 2005.
- [8] Kanan, H. R., Faez, K., Ezoji, M., "An Efficient Face Recognition System Using a New Optimized Localization Method," *IEEE*, 2006.
- [9] M. Delakis and C. Garcia, "Robust face detection based on convolutional neural networks," in *Proc. of the Second Hellenic Conference on Artificial Intelligence*, Thessalonique, Greece, pp.367-378, 2002.
- [10] M. Srinivas, Lalit M. Patnik, "Genetic Algorithm: A Survey," *IEEE*, 1994.
- [11] Rowley, H. A., Baluja, S., Kanade, T, "Neural Network-Based Face Detection," *IEEE Trans. PAMI*, Vol. 20, No. 1, Jan. 1998.
- [12] Stathopoulou, I. -O., Tsihrintzis, G. A., "An improved neural-network-based face detection and facial expression classification system," *IEEE*, 2004.
- [13] Tivive, F. H. C., Bouzerdoun, A., "A Gender Recognition System using Shunting Inhibitory Convolutional Neural Networks," *IEEE*, 2006.