

以主成分分析為主之負樣本篩選法應用於 AdaBoost 人臉偵測之研究

張循鏗* 虞台文**

大同大學資訊工程學系博士候選人*

大同大學資訊工程學系副教授**

摘要

人臉偵測(Face Detection)為自動化人臉辨識系統(Automatic Face Recognition System, AFRS)之重要前置處理步驟。自 Viola 與 Jones 於 2004 年成功將 AdaBoost 演算法應用於人臉偵測並獲得顯著的改善後，近年來，相關研究皆著重於探討應用不同類型的特徵或改良 AdaBoost 演算法，對於訓練集卻鮮少探討。有別於目前多以隨機方式於背景影像中取樣，本文提出一個以主成分分析(Principal Component Analysis, PCA)為主之負樣本(Negative Examples)篩選演算法，首先利用訓練集中的正樣本(Positive Examples)，亦即人臉影像，以 PCA 建立出人臉空間之模型，在對背景影像隨機取樣時，首先先將取得之非人臉影像投影至人臉空間中並求算與人臉空間中心點之距離，接著依據其距離求算出該負樣本屬於人臉空間之機率值，如該機率值小於閾值(threshold)則此負樣本予以丟棄，否則將之納入為訓練集之負樣本中。透過本文所提方法取得支付樣本集，皆為易誤判為人臉之非人臉影像。實驗證明，本文所提之方法可有效降低 AdaBoost 之負樣本誤判率(False Positive Rate, FPR)，並可使用較少數量之訓練集，進而達到加速學習過程之目的。

關鍵詞：人臉偵測、主要成分分析、AdaBoost

The Research of Negative Examples Selection Algorithm of AdaBoost Face Detection Based on Principal Component Analysis

Hsun-Li Chang* Tai-Wen Yue**

**PhD. Student, Department of Computer Science and Engineering,
Tatung University**

**Associate Professor, Department of Computer Science and
Engineering,
Tatung University**

ABSTRACT

Face Detection is a critical processing step for automatic face recognition system(AFRS). Since the Viola and Jones successfully applied the AdaBoost algorithm on face detection and got promising results in 2004. Recently, a lot of methods have been proposed to improve the AdaBoost by different feature types or modified the learning algorithm. But the discussions of training data are very rarely. Distinct from the randomly generating negative examples, in this paper, an approach for negative selection which is based on principal component analysis (PCA) has been proposed. The positive examples, i.e. the face images, will be used to model the face space by PCA. When randomly select negative examples, i.e. the non-face image, the selected image will be projected to the face space and calculate the distance from the center of face space. Then the probability of the image belong to face space can be calculated. If the probability is less than the threshold, the image will be dropped and selects new one. Otherwise, the image can be included in the negative examples of the training set. By the proposed approach, the negative examples in the training set can be seen as images that will be thought as faces more likely. Experiment results show that the proposed method can reduce the false positive rate effectively and the Adabbost algorithm can also be boosted by using fewer training examples.

Keywords : Face Detection, Principal Component Analysis, AdaBoost

壹、緒論

隨著電腦硬體與感測裝置的速度與效能顯著提升，電腦視覺於人機互動之應用愈來愈受到關注，在眾多相關應用中，自動化人臉辨識(Automatic Face Recognition, AFR)相關技術一直是研究的熱門主題。人臉偵測(Face Detection)為自動化人臉辨識系統(Automatic Face Recognition System, AFRS)之重要前置處理步驟。人臉偵測的問題可描述為給定一張任意影像，理想的人臉偵測器於影像中能正確標記出所有人臉(E Hjelmås., 2001)(MH Yang, D Kriegman, N Ahuja., 2002)。

近年來，已有許多關於人臉偵測的技術研究被發表，其中使用的方法約略可分為樣板比對(Template Matching)、類神經網路(Neural Network)、顏色偵測(Color-Based Approach)、移動偵測(Motion-Based Approach)、基因演算法(GA)等。由於人臉是種差異性很大的圖形，偵測過程中充滿了複雜且不確定的因素，例如光線明亮、背景顏色、人臉位置、人臉大小、人臉角度的差異、臉部是否有裝飾品(耳環、眼鏡、鬍鬚)等，皆影響到偵測的正確率。更遑論影像中將同時偵測多位人臉，每個人臉若稍有遮蔽將會影響到最後結果。

自 Viola 與 Jones(P Viola, MJ Jones., 2004)(H Jin, Q Liu, X Tang, H Lu., 2005)成功將 AdaBoost 演算法應用於人臉偵測並獲得顯著的改善後，近年來，相關研究皆著重於探討應用不同類型的特徵(T Mita, T Kaneko, Osamu Hori., 2005)或改良 AdaBoost 演算法(C Zhang, Z Zhang., 2010)，但對於學習時所採用的訓練集優劣卻鮮少探討。有別於目前多以隨機方式於背景影像中取樣，本文提出一個以主成分分析(Principal Component Analysis, PCA)為主之負樣本(Negative Examples)篩選演算法，首先利用訓練集中的正樣本(Positive Examples)，亦即人臉影像，以 PCA 建立出人臉空間之模型，在對背景影像隨機取樣時，首先先將取樣後之非人臉影像投影至人臉空間中並求算與人臉空間中心點之距離，接著依據其距離算出該負樣本屬於人臉空間之機率值，如該機率值小於閾值(threshold)則此負樣本予以丟棄，否則將之納入為訓練集之負樣本中。透過本文所提方法取得之負樣本集，皆為易誤判為人臉之非人臉影像。實驗證明，本文所提之方法可有效降低 AdaBoost 之負樣本誤判率(False Positive Rate, FPR)，並可使用較少數量之訓練集，進而達到加速學習過程之目的。

貳、文獻探討

一、主成分分析

在統計學中，主成分分析(principal components analysis, PCA)是一種線性變換簡化數據的技術，把數據轉換到一個新的坐標系統中，它藉助於一個正交變換(orthogonal transform)，將其分量相關的原向量轉化成與其分量不相關的一個新向量，這在代數上表示為將向量的協方差矩陣(covariance matrix)變換成對角矩陣，在幾何上表示為將原坐標系變換成新的正交坐標系統，常用在資料分析、資料壓縮、影像語音等。

經過正規化後的人臉影像，若直接拿去做辨識的運算，會花費相當多的時間，且在原影像中的資訊是散佈在每一個像素裡，所以必須先將影像做降低維度(dimension reduction)的動作，再從這些較低的維度，即所謂的特徵空間(feature space)，取出適當的特徵參數以代表大量的資訊。藉由 PCA 的方法可以將一筆資料中許多的變異項減少，用少數幾個互相獨立的線性組合來代替原資料，經線性組合留下來的變異項的差異就是資料中影響較大的部份，能使一筆資料顯現出最大的個別差異。PCA 應用於人臉識別相關領域最早是由 Sirovitch 和 Kirby (L. Sirovich, M. Kirby., 1987)所提出，而後續由 Turk 和 Pentland (M. Turk, A. Pentland., 1991)提出的特徵臉(Eigenfaces)則成為最具代表性與最廣為使用的方法。

假設有 M 張正規化後的人臉訓練樣本，把每個樣本當成大小為 $m \times n$ 的矩陣，將每一張樣本以列串接(row concatenate)的方式排列成大小為 $N \times 1$ 的向量 Γ ， $N = m \times n$ ，以重新描述人臉樣本，如圖 2-1 所示。




圖 2-1、將人臉影像轉換成一維向量。

在訓練集中的每一張人臉樣本都會對應到一個 Γ ，利用 M 個 Γ 計算出平均向量 Ψ ：

$$\Psi = \frac{1}{M} \sum_{i=1}^M \Gamma_i \quad (1)$$

平均向量 Ψ 也就是平均臉(mean face)，表示所有人臉共有的部份，如圖 2-2。




圖 2-2、(a)訓練集、(b)平均臉。

接著將 M 張人臉中共有的部份刪除，以突顯人臉間不同的部份，計算出每一張人臉與平均臉之差異影像(difference image)向量為：

$$\Phi_i = \Gamma_i - \Psi \quad (2)$$

假設矩陣 $A = [\Phi_1, \Phi_2, \dots, \Phi_M]$ ，該矩陣大小為 $N^2 \times M$ ，則訓練集中所有人臉影像的共變異矩陣(covariance matrix) C 為：

$$C = \frac{1}{M} \sum_{i=1}^M \Phi_i \Phi_i^T = AA^T \quad (3)$$

對矩陣 C 求解特徵值(eigenvalue) λ 與特徵向量(eigenvector) u 表示為：

$$Cu_i = \lambda_i u_i \quad (4)$$

由於 A 是一個維度大小為 $N^2 \times M$ 的矩陣，所以矩陣 C 為一個 $N^2 \times N^2$ 的矩陣，以每張影像大小為 128×128 為例，則矩陣 C 之維度為 16384×16384 ，對於如此龐大的矩陣，要計算出其特徵值與特徵向量是相當耗時的工作，依據 Turk 和 Pentland() 所提出的方法，先行計算矩陣 $A^T A$ ，將矩陣維度降至 $M \times M$ 並求其特徵向量 v_i ：

$$A^T A v_i = \mu_i v_i \quad (5)$$

因為 $C = AA^T$ ，所以將上式等號兩邊同乘以矩陣 A 可得到：

$$(AA^T) A v_i = \mu_i A v_i \quad (6)$$

$$C A v_i = \mu_i A v_i \quad (7)$$

比較式(4)與式(7)可得知：

$$\begin{cases} \mathbf{u}_i = \mathbf{A}\mathbf{v}_i \\ \lambda_i = \mu_i \end{cases} \quad (8)$$

因此先利用式(5)求出特徵向量 \mathbf{v}_i ，再依照式(8)換算成特徵向量 \mathbf{u}_i ，所求出的 \mathbf{u}_i 即為特徵臉(eigenface)，如式(9)所示。

$$\mathbf{u}_i = \sum_{j=1}^M \Phi_j \mathbf{v}_{ij} \quad (9)$$

將每個人臉樣本向量，依照計算得到的特徵值由大到小做排序，將所對應的特徵向量組合而成特徵空間(feature space)，求其在特徵空間的權重向量 \mathbf{W} ，如(9)式所示：

$$\begin{cases} \Omega_i = \mathbf{u}_i^T (\Gamma - \Psi) = \mathbf{u}_i^T \Phi \\ \mathbf{W} = [\Omega_1, \Omega_2, \dots, \Omega_M] \end{cases} \quad (10)$$

最後將每個人臉訓練樣本 Γ_i ， $i = 1, \dots, M$ ，分別帶入式(10)中的 Γ ，以求出人臉在特徵空間裡的權重向量 \mathbf{W}_i ，所求即為訓練完成的人臉影像資料庫。

二、人臉偵測與定位

人臉偵測及定位是行之多年的研究，在不同的環境下有不同的偵測方法，希望能達到在複雜環境下偵測並定位人臉，因此採用灰階影像來偵測出人臉的部份，除了能減少額外色彩資訊以加速計算過程之外，同時也可減少因顏色差異及變化造成的誤判。

本文採用 Viola 與 Jones 所提出的方法，使用 Haar-like 的矩形來當作特徵值。為了快速計算矩形特徵值，運用所謂的積分影像(Integral Image)以快速計算影像中任意矩形的積分值，以簡單的矩形特徵加快偵測的速度。並用運用 Adaboost 的訓練方法訓練出偵測人臉的分類器以達到能在複雜環境下偵測並定位人臉的目的。

應用矩形特徵是因為對人臉結構分析時，臉部的明暗陰影是一項重要的判別因素，而在人的臉部，眼睛部份會比額頭部分還要暗些，雙眼間的部份也會比兩眼還亮些。這些特徵可以用矩形的特徵來表示，如圖 2-3 所示，人的雙眼部分比下面鼻子附近的部份還暗，因此利用這種特徵，除了能把臉部的大概特徵區分出來以外，矩形特徵也對簡單結構的線條(line)、邊(edge)、角(corner)等特徵有較高的敏感度且容易靠矩形特徵偵測出來。矩形特徵的計算相對於像素的計算，有著快速的優點，Viola 與 Jones 使用了幾種簡單的矩形特徵如圖 2-4。




圖 2-3、用矩形的特徵來表示臉部的明暗陰影。




圖 2-4、簡單的矩形特徵。

爲了能快速求出影像中的矩形特徵，Viola 與 Jones 提出了積分影像的觀念，積分影像的定義爲：

$$ii(x, y) = \sum_{x' \leq x, y' \leq y} i(x', y') \quad (11)$$

其中 $ii(x, y)$ 爲積分影像， $i(x, y)$ 爲原始影像中的灰階像素值。使用式(12)和(13)即可快速求出影像中任意位置 (x, y) 之累積像素值。

$$s(x, y) = s(x, y-1) + i(x, y) \quad (12)$$

$$ii(x, y) = ii(x-1, y) + s(x, y) \quad (13)$$

$$s(x, -1) = 0 \quad (14)$$

$$ii(-1, y) = 0 \quad (15)$$

其中 $s(x, y)$ 是原始影像 (x, y) 點的列累積和(cumulative row sum)。

假設影像的大小爲 $m \times n$ ，計算其積分影像只要掃描一次，計算 $2mn$ 次便可求出整張影像的積分影像值。求出整張影像的積分圖後，影像中的任何矩形和可以用 4 個參考值計算出來，如圖 2-5，點 1 爲矩形 A 的像素總值，點 2 爲 A+B 的像素總值，點 3 爲 A+C 的像素總值，點 4 爲 A+B+C+D 的像素總值。因此欲求出 D 的像素總值，只要計算 $4 + 1 - (2+3)$ 即可。




圖 2-5、利用積分影像快速求算 D 像素值。

假設影像大小為 24×24 ，則總共有超過 160,000 個矩形特徵，面對數量如此龐大的特徵，要如何找出對辨識是否為人臉有所幫助的特徵，Adaboost()是個很適合的方法。

在欲分類的空間中，假定得到一個線性分類函數 h ，使得 h 的錯誤率最小，此為分類的目的。假如 h 的分類效果不甚理想，僅僅只比隨機猜測還要好一點，則我們稱 h 為一個弱分類器(weak classifier)。Boosting 演算法為一種分類演算法的通稱，主要精神是在透過對很多個弱分類器的組合，來形成一個強分類器(strong classifier)。Adaboost 是所提出的一種自適性(Adaptive) Boosting 演算法，Adaboost 演算法在整合出強分類器時不需要事先確定好構成強分類器的規則，而是由構成強分類器中的弱分類器性能來決定規則，因此 Adaboost 有著比 Boosting 演算法更好的性能。

一個弱分類 $h(x, f, p, \theta)$ 是由特徵函數 f 、閾值 θ 以及控制不等號方向的 p 所組成，其函式定義如下：

$$h(x, f, \theta, p) = \begin{cases} 1 & \text{if } pf(x) < p\theta \\ 0 & \text{otherwise} \end{cases} \quad (16)$$

以下為 Adaboost 的演算法：

- 給予一連串的訓練影像 $(x_1, y_1), \dots, (x_n, y_n)$ ，其中 $y_i = 1$ 表示為正樣本(人臉)反之 $y_i = 0$ 則為負樣本(非人臉)。
- 初始化權重

$$w_{1,i} = \frac{1}{2m}, \frac{1}{2l} \quad (17)$$

分別對應 $y_i = 0$ 與 1 的情況，其中 m 及 l 分別是負樣本及正樣本的個數。

- For $t=1$ to T :
 1. 將權重正規劃:

$$w_{t,i} \leftarrow \frac{w_{t,i}}{\sum_{j=1}^n w_{t,j}} \quad (18)$$

這樣 w_i 即為正負樣本之機率分佈。

2. 對每個特徵 j ，訓練一個分類器 h_j ，此分類器對應一個特徵，而此分類器的錯誤是根據 w_i 計算所得到的

$$\varepsilon_j = \sum_i w_i |h_j(x_i) - y_i| \quad (19)$$

3. 選擇有最小錯誤率 ε 的分類器 h 。
4. 依下式更新權重：

$$w_{t+1,i} = w_{t,i} \beta_t^{1-e_i} \quad (20)$$

當 $e_i = 0$ 表示樣本 x_i 被正確的分類，否則 $e_i = 1$ ，且

$$\beta_t = \frac{\varepsilon_t}{1 - \varepsilon_t} \quad (21)$$

- 最終的強分類器如下：

$$C(x) = \begin{cases} 1 & \sum_{i=1}^T \alpha_i h_i(x) \geq \frac{1}{2} \sum_{i=1}^T \alpha_i \\ 0 & \text{otherwise} \end{cases} \quad (22)$$

其中

$$\alpha_i = \log \frac{1}{\beta_i} \quad (23)$$

叁、研究方法

本文提出一個以主成分分析(Principal Component Analysis, PCA)為主之負樣本(Negative Examples)篩選演算法，首先利用訓練集中的正樣本(Positive Examples)，亦即人臉影像，以 PCA 建立出人臉空間之模型，在對背景影像隨機取樣時，首先先將取樣後之非人臉影像投影至人臉空間中並求算與人臉空間中心點之距離，接著依據其距離算出該負樣本屬於人臉空間之機率值，如該機率值小於閾值(threshold)則此負樣本予以丟棄，否則將之納入為訓練集之負樣本中。透過本文所提方法取得之負樣本集，皆為易誤判為人臉之非人臉影像。

假設訓練集中影像大小皆為 $w \times h$ 且 $w = h$ ，其中共有 m 張負樣本與 l 張正樣本。令 X 表示為所有正樣本(人臉)所形成之集合， $X = \{x_1, x_2, \dots, x_l\}$ ，而 x_i 為影像像素以列串接(row concatenate)的方式所排列成大小為 $N \times 1$ 的向量， $N = w \times h$ 。所有正樣本之平均向量 Ψ 可由下式求算：

$$\Psi = \frac{1}{l} \sum_{i=1}^l \mathbf{x}_i \quad (24)$$

接著將 1 張人臉中共有的部份刪除，以突顯人臉間不同的部份，計算出每一張人臉與平均臉之差異影像(difference image)向量為：

$$\Phi_i = \mathbf{x}_i - \Psi \quad (25)$$

假設矩陣 $\mathbf{A} = [\Phi_1, \Phi_2, \dots, \Phi_l]$ ，該矩陣大小為 $N \times l$ ，則訓練集中所有人臉影像的共變異矩陣(covariance matrix) \mathbf{C} 為：

$$\mathbf{C} = \frac{1}{M} \sum_{i=1}^M \Phi_i \Phi_i^T = \mathbf{A} \mathbf{A}^T \quad (26)$$

對 \mathbf{C} 進行 PCA 分析後，人臉的特徵空間(face space)則由所對應前 d 個特徵值最大之特徵向量 \mathbf{u} 所形成，將所有人臉影像投影到特徵空間後，可取得對應於各特徵軸之分量大小 Ω ，其定義如下：

$$\begin{aligned} \Omega_i &= \mathbf{u}_i^T (\mathbf{x}_i - \Psi) = \mathbf{u}_i^T \Phi_i \\ \Omega_i &= [\omega_1, \omega_2, \dots, \omega_d]^T \end{aligned} \quad (27)$$

為能將易被誤判為人臉之負樣本能有效的篩選出來，將所有正樣本投影至人臉特徵空間所形成對應於各特徵軸之分量大小 Ω 視為於該空間中的一個點，則所有點至其平均點的距離分佈，依據中心極限定理可形成一高斯(Gaussian)模型。正樣本於人臉特徵空間中之平均點座標(為維度 d 之向量)可由下式求算：

$$\mathbf{Z} = \frac{1}{l} \sum_{i=1}^l \Omega_i \quad (28)$$

接著依式(29)求算出所有正樣本於人臉特徵空間中距離平均點之歐式距離。

$$d_i = \|\Omega_i - \mathbf{Z}\|_2, \quad i = 1, \dots, l \quad (29)$$

則所有點至其平均點的距離所形成的高斯模型可定義為 $N \sim (\mu, \sigma)$ ， μ 及 σ 定義如下：

$$\mu = \frac{1}{l} \sum_{i=1}^l d_i \quad (30)$$

$$\sigma = \sqrt{\frac{1}{l-1} \left(\sum_{i=1}^l d_i^2 \right) - \mu^2} \quad (31)$$

求得距離所形成的高斯模型參數後，可定義出兩個閾值， d_{\min} 與 d_{\max} ，此兩閾值可定為以 μ 為中心，其左右給定一個標準差所對應之機率密度值。

給定一任意大小為 $W \times H$ 背景影像，以隨機產生之 $p \times q$ 的擷取視窗擷取，將所擷取影像大小變更為 $w \times h$ 後，令為 T ，投影至人臉特徵後求得其座標向量 Ω_T ，並求算與 Z 之間的距離 d_T ，如 d_T 介於 d_{\min} 與 d_{\max} 之間，則將之納入訓練集的負樣本中，否則予以丟棄，重複於背景影像集中隨機選取至共有 m 張負樣本為止，見圖 3-1，如此，取得之負樣本集，皆為易誤判為人臉之非人臉影像。接著將訓練集中的所有影像以 AdaBoost 訓練出一強分類器，以供人臉檢測使用。




圖 3-1、將隨機擷取之負樣本投影至人臉特徵空間。

肆、實驗結果

本實驗以個人電腦進行，CPU 為 Intel Core2 Quad CPU Q9300 2.5GHz，記憶體為 2GB，作業系統為 Microsoft Windows 7 Ultimate Edition。開發工具使用 MATLAB 2010b。

實驗所使用之訓練集，於人臉影像部分皆針對 LFW(Labeled Faces in the Wild) 資料庫中的影像，以人工的方式進行擷取並改變大小為 18×18 之影像。擷取時以人臉眉心至下嘴唇中心之長度產生一正方形，並擷取將此正方形放大 25% 後之影像，見圖 4-1。



圖 4-1、(a)LFW 資料庫中部份影像、(b)擷取之人臉影像。

非人臉影像皆由 bigfoto 所提供之背景影像，以隨機方式擷取及以本文所提之方法擷取，產生兩組負樣本集，見圖 4-2。

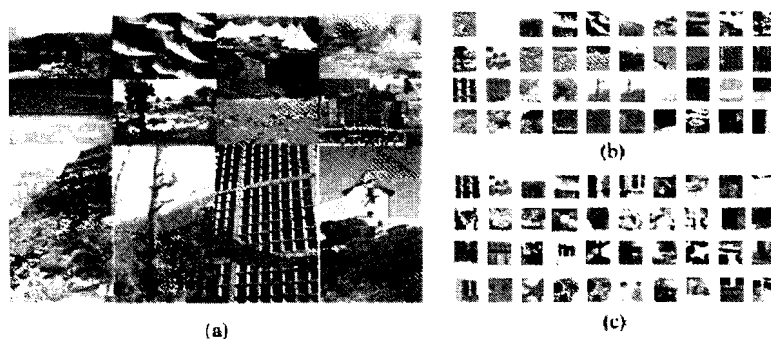


圖 4-2、(a)bigfoto 背景影像、(b)以隨機擷取所產生之負樣本集、(c)以本文所提出之方法所產的負樣本集。

分別使用隨機產生之負樣本集與本文所提方法產生的負樣本集，以 AdaBoost 進行訓練，訓練所得由 200 個弱分類器組合而成之強分類器的 ROC 圖如圖 4-3 與圖 4-4，可知本文所提之方法所產生之負樣本及相較於以隨機方式產生之負樣本集較具代表性，可有效降低 AdaBoost 之負樣本誤判率。

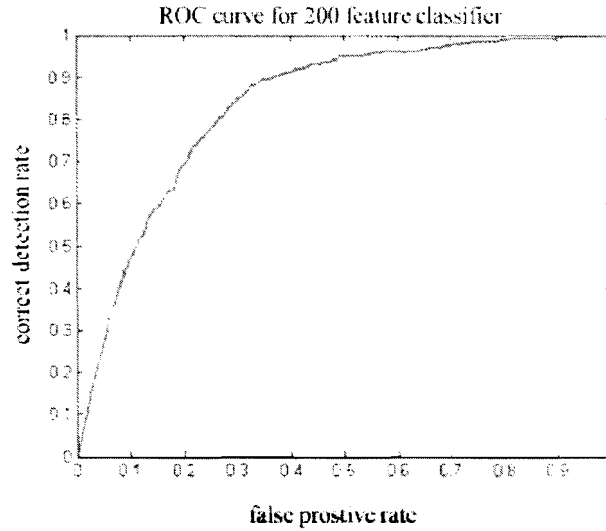


圖 4-3、訓練集採用以隨機產生之負樣本所得之強分類器 ROC 圖。

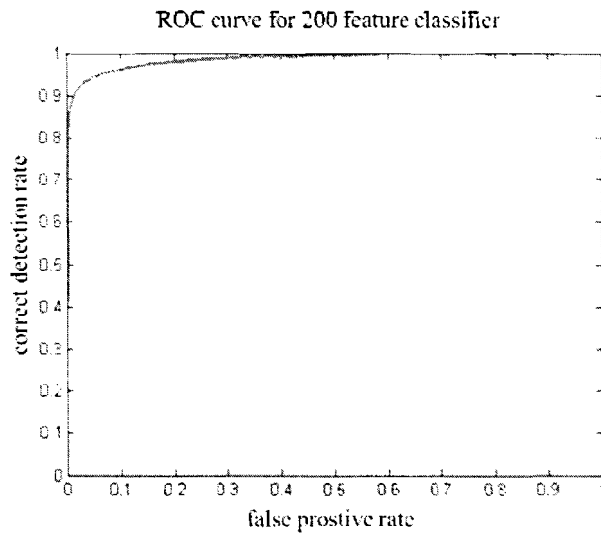


圖 4-4、訓練集採用本文所提方法產生的負樣本集得之強分類器 ROC 圖。

伍、結論

近年來，已有許多關於人臉偵測的技術研究被發表，自 Viola 與 Jones 成功將 AdaBoost 演算法應用於人臉偵測並獲得顯著的改善後，近年來，相關研究的重點皆著重於探討應用不同類型的特徵或改良 AdaBoost 演算法，但對於學習時所採用的訓練集優劣卻鮮少探討。

本文提出一個以主成分分析(Principal Component Analysis, PCA)為主之負樣本(Negative Examples)篩選演算法，首先利用訓練集中的正樣本(Positive Examples)，亦

即人臉影像，以 PCA 建立出人臉空間之模型，在對背景影像隨機取樣時，首先先將取樣後之非人臉影像投影至人臉空間中並求算與人臉空間中心點之距離，接著依據其距離算出該負樣本屬於人臉空間之機率值，如該機率值小於閾值(threshold)則此負樣本予以丟棄，否則將之納入為訓練集之負樣本中。

透過本文所提方法產生之負樣本集，皆為易誤判為人臉之非人臉影像。實驗證明，本文所提之方法所產生之負樣本及相較於以隨機方式產生之負樣本集較具代表性，可有效降低 AdaBoost 之負樣本誤判率(False Positive Rate, FPR)，並可使用較少數量之訓練集，進而達到加速學習過程之目的。

參考文獻

E Hjelmås. (2001). *Face Detection: A Survey*. Computer Vision and Image Understanding 83, Pages: 236 - 274.

MH Yang, D Kriegman, N Ahuja. (2002). *Detecting Faces in Images: A Survey*. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, Vol. 24, NO. 1, Pages: 34-58.

P Viola, MJ Jones. (2004). *Robust Real-Time Face Detection*. International Journal of Computer Vision 57(2), Pages: 137-154.

T Mita, T Kaneko, Osamu Hori. (2005). *Joint Haar-like Features for Face Detection*. Proceedings of the Tenth IEEE International Conference on Computer Vision (ICCV' 05).

H Jin, Q Liu, X Tang, H Lu. (2005). *Learning Local Descriptors for Face Detection*. IEEE International Conference on Multimedia and Expo, Pages 928-931.

C Zhang, Z Zhang. (2010). *A Survey of Recent Advances in Face Detection*. Microsoft Research Microsoft Corporation Technical Report MSR-TR-2010-66.

L. Sirovich, M. Kirby. (1987). *Low-Dimensional Procedure for the Characterization of Human Faces*. JOSA A, Vol. 4, Issue 3, Pages: 519-524.

M. Turk , A. Pentland. (1991). *Eigenface for Recognition*. J. Cognitive Neuroscience, Vol. 3, No. 1, Pages: 71 - 86.