


### 第三章 方法與步驟

本研究之人臉偵測系統架構如圖八所示，第一階段以影像之梯度分佈資訊偵測人臉於影像中之可能位置，藉以過濾影像中無用的資訊。此步驟需以最大期望法推算人臉及非人臉之梯度分佈之高斯混合模型(Mixture of Gaussian)參數後，計算每個視窗之梯度分佈資訊。進行人臉偵測時，如圖九所示，以  $32 \times 32$  的視窗等比放大掃瞄影像，並利用貝氏定理計算視窗之梯度資訊與人臉相似度，若此視窗與人臉之高斯混合模型較為相似，代表此視窗可能為人臉。過去的研究中，為偵測精確人臉位置，常需掃瞄整張影像，本研究為了減少掃瞄數目並增加偵測速度，以動態間隔偵測法，先將較大視窗間隔掃瞄影像後，將可能為人臉的視窗位置群集化，再以群集中心點附近之區域以較小視窗間隔掃瞄，以此法有效減少視窗掃瞄的數量。

上階段推算出可能為人臉之視窗後，第二階段本研究提出以梯度空間相關性模型，將可能之人臉視窗進一步掃瞄，人臉之梯度空間相關性由數個區塊配對及其權重組合而成，每個區塊配對可能為正或負相關性，本研究定義區塊之正相關性為此區塊配對中之影像的梯度分佈相似，負相關性代表兩區塊不相似，並將每個區塊配對視為粗糙分類器(Weak Learner)。從人臉及非人臉訓練資料推算



圖八：人臉偵測系統架構


步驟一：計算整張影像之梯度資訊



步驟二：以32×32大小之視窗等比放大掃描



步驟三：以人臉及非人臉之高斯混合模型推算可能為人臉之視窗



圖九：本研究以梯度分佈模型偵測人臉步驟。

M 個粗糙分類器後，以 AdaBoost 演算法計算每個粗糙分類器的權重(Weight)，分類時計算人臉視窗中 M 個區塊配對的相似度，並計算區塊之相似度權重乘積後累加，藉此推算人臉在梯度空間上的相關性，並利用串連式分類器移除誤判視窗，若計算結果大於預設門檻值，則判斷此視窗為人臉。以下各節將介紹本研究所提出之人臉偵測方法，3.1 節介紹梯度分佈資訊；3.2 節介紹最大期望法；3.3 節介紹動態間隔偵測法；3.4 節介紹梯度空間相關性模型；3.5 節介紹 AdaBoost 演算法；3.6 節介紹串連式分類器。

### 3.1 梯度分佈資訊

在本研究所提出的第一階段中，需計算影像之梯度分佈，以減少資料量及偵測影像中可能為人臉之視窗。假設  $f$  為輸入影像，則  $f$  的梯度  $g(x, y) = [g_x, g_y]^T$  如

下所示：

$$g_x(x, y) = f(x+1, y-1) + 2f(x+1, y) + f(x+1, y+1) - f(x-1, y-1) - 2f(x-1, y) - f(x-1, y+1) \quad (1)$$

$$g_y(x, y) = f(x-1, y+1) + 2f(x, y+1) + f(x+1, y+1) - f(x-1, y-1) - 2f(x, y-1) - f(x+1, y-1) \quad (2)$$

其中  $g_x(x, y)$  代表著梯度圖上  $(x, y)$  的水平分量，而  $g_y(x, y)$  代表著梯度圖上  $(x, y)$

的垂直分量，將梯度圖上每一點  $g(x, y)$  轉換為角度  $\theta(x, y)$  為：

$$\theta(x, y) = \frac{\text{atan}(g_y/g_x)}{2\pi} \cdot 360^\circ \quad (3)$$

為了充分利用邊緣資訊，針對每個角度  $\theta(x, y)$  以 45 度作為區間，將  $\theta(x, y)$  對應的邊緣強度值  $m(x, y)$  以八個邊緣圖儲存  $f_i(x, y) \forall i=1..8$ ，而邊緣強度值計算

如下：

$$m(x, y) = (g_x^2 + g_y^2)^{\frac{1}{2}} \quad (4)$$

判斷  $m(x, y)$  屬於邊緣圖  $f_i(x, y)$  的方法為：

$$f_i(x, y) = m(x, y) \text{ if } i = 1 + \lfloor \theta(x, y) / 45^\circ \rfloor \bmod 8 \quad (5)$$

由(5)可知將梯度從 0 度至 360 度分為八個區間，定義  $f(x, y, w, h)$  為  $f$  從  $(x, y)$  到  $(x+w, y+h)$  之子影像，欲計算  $f(x, y, w, h)$  的梯度分佈，需對各個邊緣圖  $f_1, f_2, \dots, f_8$  從位置  $(x, y)$  累加至  $(x+w, y+h)$ ，但此階段需掃瞄大量視窗，累加計算每個區間之分佈非常緩慢，因此本研究改採完整影像(Integral Image)法之概念[36]，完整影像法改變像素之儲存方式，使得計算影像某區域的像素總和時間僅需四個運算，將邊緣圖  $f_i$  以完整影像法儲存：

$$I_i(x, y) = \sum_{x' \leq x, y' \leq y} f_i(x', y') \quad (6)$$

其中  $I_i$  為  $f_i$  的完整影像， $I_i(x, y)$  之值為  $f_i$  從  $(0,0)$  至  $(x,y)$  之像素值總和，若計

算  $f_i$  從  $(x,y)$  至  $(x+w, y+h)$  之總和：

$$\sum_{x \leq x' \leq x+w, y \leq y' \leq y+h} f_i(x', y') = I_i(x+w, y+h) - I_i(x+w, y) - I_i(x, y+h) + I_i(x, y) \quad (7)$$

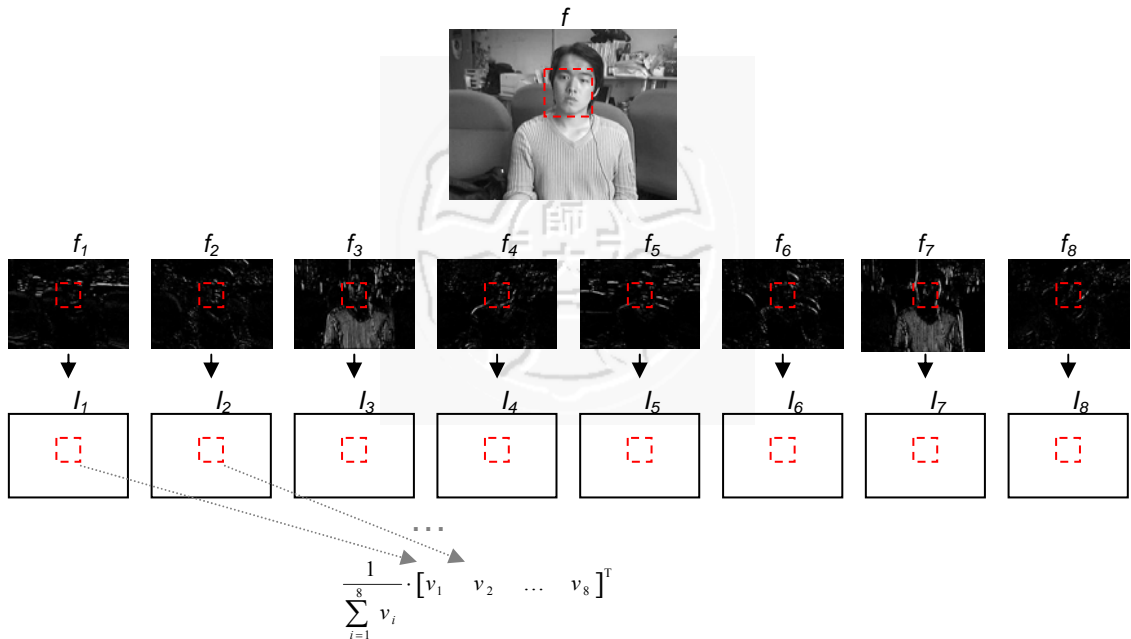
由上式可知計算  $f_i$  中任一視窗總和僅需四個運算。如圖十所示，以完整影像

法可快速計算  $f(x, y, w, h)$  之梯度分佈  $d(f(x, y, w, h))$ ：

$$d(f(x, y, w, h)) = \frac{1}{8} \cdot [v_1 \quad v_2 \quad \dots \quad v_8]^T \quad (8)$$

$$\sum_{i=1}^8 v_i$$

where  $v_i = I_i(x+w, y+h) - I_i(x+w, y) - I_i(x, y+h) + I_i(x, y)$



圖十：假設欲計算輸入影像  $f$  中虛線方框的梯度分佈，先計算邊緣圖  $f_1, f_2, \dots, f_8$  後，以完整影像法計算每個邊緣圖之完整影像圖  $I_1, I_2, \dots, I_8$ ，則  $v_1, v_2, \dots, v_8$  之值可利用(8)式快速計算結果。

### 3.2 最大期望法(Expectation Maximization, EM)

最大期望法為最大相似估計(Maximum Likelihood Estimation, MLE)問題中尋

找不完整資料(Incomplete data)可能分佈的方法，在最大期望法的應用中，通常被

使用來估計不完整資料分佈的參數以及最佳化相似函數(Likelihood function)使得此函數的分佈更逼近於完整資料(Complete Data)[34]，在本研究中，將人臉以及非人臉之梯度分佈資料視為缺漏資料，而完整資料視為數個高斯分佈的混合，因此若給定觀測資料  $\lambda$ ，則  $\lambda$  與完整資料之分佈函數的相似度計算如下：

$$p(\lambda | \Theta) = \sum_{m=1}^M \pi_m p_m(\lambda | \Theta_m) \quad (9)$$

其中  $\pi_i$  為  $\Theta_i$  的在高斯分佈混合中的權重， $\Theta_i = N(\hat{u}_i, \hat{\sigma}_i^2)$  為一高斯分佈，假設以  $M$  個高斯分佈逼近訓練資料  $y_1, y_2, \dots, y_N$ ，最大期望法最佳化參數如下步驟所示[37]：

1. 初始：隨機給定  $M$  個高斯分佈參數  $(\hat{u}_1, \sigma_1^2, \pi_1), (\hat{u}_2, \sigma_2^2, \pi_2), \dots, (\hat{u}_M, \sigma_M^2, \pi_M)$ ，其中  $\sum_{m=1}^M \pi_m = 1$ 。
2. 期望步驟(E-Step)：計算訓練資料  $y_i$ ， $\forall i = 1 \dots N$  對於  $\Theta_m$ ， $\forall m = 1 \dots M$  的依賴度(responsibilities)  $\hat{r}_{i,m}$  為

$$\hat{r}_{i,m} = \frac{\pi_m p(y_i | \Theta_m)}{\sum_{j=1}^M \pi_j p(y_i | \Theta_j)} \quad (10)$$

3. 最大化步驟(M-Step)：最佳化參數  $\hat{u}_m, \sigma_m^2, \pi_m$   $\forall m = 1 \dots M$  各為

$$\hat{u}_m = \frac{\sum_{i=1}^N \hat{r}_{i,m} \cdot y_i}{\sum_{i=1}^N \hat{r}_{i,m}} \quad (11)$$

$$\hat{\sigma}_m^2 = \frac{\sum_{i=1}^N \hat{r}_{i,m} \cdot (y_i - \hat{u}_m)^2}{\sum_{i=1}^N \hat{r}_{i,m}} \quad (12)$$

$$\pi_m = \frac{1}{N} \cdot \sum_{i=1}^N \hat{r}_{i,m} \quad (13)$$

4. 回到步驟 2，直到參數收斂

假設人臉和非人臉之梯度分佈訓練資料之高斯混合模型為  $\Theta_{\text{face}}$  及  $\Theta_{\text{nonface}}$ ，利用最大期望法訓練至收斂後，以貝氏定理預測梯度分佈資料  $d(f(x, y, w, h))$  屬於臉部或非臉部，若屬於臉部：

$$\frac{p(\Theta_{\text{face}}) \cdot p(\lambda | \Theta_{\text{face}})}{p(\lambda)} > \frac{p(\Theta_{\text{nonface}}) \cdot p(\lambda | \Theta_{\text{nonface}})}{p(\lambda)} \quad \text{where } \lambda = d(f(x, y, w, h)) \quad (14)$$

其中  $p(\lambda) = p(\Theta_{\text{face}}) \cdot p(\lambda | \Theta_{\text{face}}) + p(\Theta_{\text{nonface}}) \cdot p(\lambda | \Theta_{\text{nonface}})$ ， $\Theta_{\text{face}}$  及  $\Theta_{\text{nonface}}$  本身機率不考慮的情況下，(14)可以化簡為：

$$p(\lambda | \Theta_{\text{face}}) > p(\lambda | \Theta_{\text{nonface}}) \quad (15)$$

以圖十為例，計算虛線視窗之梯度分佈後，欲判斷此視窗是否為人臉，可將其梯度分佈以(14)式計算  $\lambda$  在  $\Theta_{\text{face}}$  及  $\Theta_{\text{nonface}}$  發生之機率，若符合(15)式則代表此視窗可能為人臉。

因梯度分佈不具有空間特性，故本研究將第一階段所推算出可能之人臉視窗，以梯度空間相關性模型，將此階段可能為人臉視窗進一步分類，節 3.4 將討論其分類方法。

### 3.3 動態間隔偵測法

過去許多人臉偵測相關研究中，常需掃瞄整張影像以定位人臉視窗，若以  $w \times h$  的視窗掃瞄一張  $320 \times 240$  影像，共有  $(320 - w) \times (240 - h)$  個視窗需進行分類，如：

若  $w = h = 32$ ，則有 59,904 個視窗需被進行分類。本方法之目的在於減少需被分類之視窗數目，以節省運算時間，先以較大間隔掃瞄影像，將可能為人臉之視窗集群化後，再以集群中心點四周區域，用較小間隔掃瞄，以減少需分類的視窗數目，方法如下：

輸入：

$f$ ：欲偵測之影像，大小為  $W \times H$

$w, h$ ：視窗大小

$sx, sy$ ：掃瞄起始點，初值皆為 0

$dx, dy$ ：掃瞄終點，初值各為  $W-w$  和  $H-h$

$\varepsilon$ ：掃瞄間隔

$\Theta_{\text{face}}, \Theta_{\text{nonface}}$ ：人臉和非人臉之高斯混合模型

輸出：

$R$ ：可能為人臉視窗之集合，初始值為空集合

function dynamic\_interval( $f, w, h, sx, sy, dx, dy, \varepsilon, \Theta_{\text{face}}, \Theta_{\text{nonface}}$ )

if  $\varepsilon < 1$  then

return  $R$

for  $x = sx; x < dx; x += \varepsilon$

for  $y = sy; y < dy; y += \varepsilon$

if  $p(\lambda | \Theta_{\text{face}}) > p(\lambda | \Theta_{\text{nonface}})$  其中  $\lambda = d(f(x, y, w, h))$  then  $R = R \cup f(x, y, w, h)$



將  $R$  中所有視窗之左上角座標以距離  $d$  集群化，產生  $C = \{C_1, C_2, \dots, C_L\}$  共  $L$  個集群，其

中  $d = (w^2 + h^2)^{\frac{1}{2}} / 4$

for each  $C_i \in \{C_1, \dots, C_L\}$

計算屬於集群  $C_i$  中視窗  $f(x, y, w, h) \in C_i$  的  $x_{\min}, y_{\min}, x_{\max}$  和  $y_{\max}$

$R = R \cup \text{dynamic\_interval}(f, w, h, x_{\min} - d/2, y_{\min} - d/2, x_{\max} + 3d/2, y_{\max} + 3d/2, \varepsilon/2, \Theta_{\text{face}}, \Theta_{\text{nonface}})$

end for

$\varepsilon$  為掃瞄間隔之起始值，以間隔  $\varepsilon$  掃瞄  $f$  之所有視窗後，將滿足(15)式之

視窗加入集合  $\mathbf{R}$ ，並將  $\mathbf{R}$  中所有視窗左上角座標群集化後，計算每個集群所形成的矩形區域 ( $x_{min}, y_{min}, x_{max}$  和  $y_{max}$ )，以  $\varepsilon/2$  之間隔掃瞄每個集群所形成的區域，直到當掃瞄間隔小於 1 時，則停止掃瞄並跳出函式。 $\mathbf{R}$  中每一個視窗皆可能為人臉，將再以梯度空間相關性模型進行分類。

### 3.4 梯度空間相關性模型

一個梯度空間相關性模型由數個粗糙分類器組成，又稱強分類器 (Strong Classifier, SC)，每個粗糙分類器計算視窗中兩區塊的相似程度，若以單一粗糙分類器  $G_m$  將  $\mathbf{R}$  中每一個視窗  $f(x, y, w, h)$  進行分類：

$$G_m(f_s) = \text{mark}(m) \cdot d_n(f_s(x_m, y_m, w_m, h_m))^T \cdot d_n(f_s(x'_m, y'_m, w_m, h_m)) \quad (16)$$

其中  $f_s = f(x, y, w, h)$  且  $\text{mark}(m) \in \{-1, 1\}$ ，代表粗糙分類器的性質， $d_n$  為正規化後的梯度分佈：

$$d_n(f_s(x_m, y_m, w_m, h_m)) = \frac{1}{\sqrt{v_s}} [v_1 - \bar{v} \quad v_2 - \bar{v} \quad \dots \quad v_8 - \bar{v}]^T \quad (17)$$

其中

$$v_i = I_i(x + x_m + w_m, y + y_m + h_m) - I_i(x + x_m + w_m, y + y_m) - I_i(x + x_m, y + y_m + h_m) + I_i(x + x_m, y + y_m) \quad \forall i = 1 \dots 8 \quad (18)$$

$$\bar{v} = \frac{1}{8} \sum_{i=1}^8 v_i \quad (19)$$

$$v_s = \sum_{i=1}^8 (v_i - \bar{v})^2 \quad (20)$$

$f_s(x_m, y_m, w_m, h_m)$  及  $f_s(x'_m, y'_m, w_m, h_m)$  為視窗  $f_s$  中的兩個區塊。以單一粗糙分類器將  $f_s$  進行分類，若  $G_m(f_s)$  大於零代表  $f_s$  為人臉，反之為非人臉。若以  $M$  個粗糙分類器組成的強分類器將  $f_s$  進行分類：



$$SC(f_s) = \sum_{m=1}^M \alpha_m G_m(f_s) \quad (21)$$

其中  $\alpha_m$  為粗糙分類器  $G_m$  的權重，如同單一粗糙分類器，若  $SC(f_s)$  大於門檻值表  $f_s$  為人臉，反之為非人臉，門檻值之選擇將在第四章討論。

(16)式中，一個粗糙分類器為之分類結果為兩個區塊梯度分佈的內積，並乘以  $\text{mark}(m)$  作為分類結果， $\text{mark}(m)$  為粗糙分類器  $G_m$  之性質，若  $\text{mark}(m)$  為 1 代表  $G_m$  為正粗糙分類器，反之  $\text{mark}(m)$  為 -1 代表  $G_m$  為負粗糙分類器。假設人臉資料庫  $\mathbf{Y}_{\text{face}}$  及  $\mathbf{Y}_{\text{nonface}}$ ，且  $f_s \in \mathbf{Y}_{\text{face}}$  及  $f'_s \in \mathbf{Y}_{\text{nonface}}$ ，若  $f_s(x_m, y_m, w_m, h_m)$  和  $f_s(x'_m, y'_m, w_m, h_m)$  之正規化梯度分佈各為  $d_n(f_s(x_m, y_m, w_m, h_m))$  和  $d_n(f_s(x'_m, y'_m, w_m, h_m))$ ，則  $G_m$  為正粗糙分類器需同時滿足：

$$p\left(d_n(f_s(x_m, y_m, w_m, h_m))^T \cdot d_n(f_s(x'_m, y'_m, w_m, h_m)) > 0 \mid \forall f_s \in \mathbf{Y}_{\text{face}}\right) > 0.5 \quad (22)$$

$$p\left(d_n(f'_s(x_m, y_m, w_m, h_m))^T \cdot d_n(f'_s(x'_m, y'_m, w_m, h_m)) \leq 0 \mid \forall f'_s \in \mathbf{Y}_{\text{nonface}}\right) > 0.5 \quad (23)$$

若  $G_m$  為負粗糙分類器需同時滿足：

$$p\left(d_n(f_s(x_m, y_m, w_m, h_m))^T \cdot d_n(f_s(x'_m, y'_m, w_m, h_m)) \leq 0 \mid \forall f_s \in \mathbf{Y}_{\text{face}}\right) > 0.5 \quad (24)$$

$$p\left(d_n(f'_s(x_m, y_m, w_m, h_m))^T \cdot d_n(f'_s(x'_m, y'_m, w_m, h_m)) > 0 \mid \forall f'_s \in \mathbf{Y}_{\text{nonface}}\right) > 0.5 \quad (25)$$

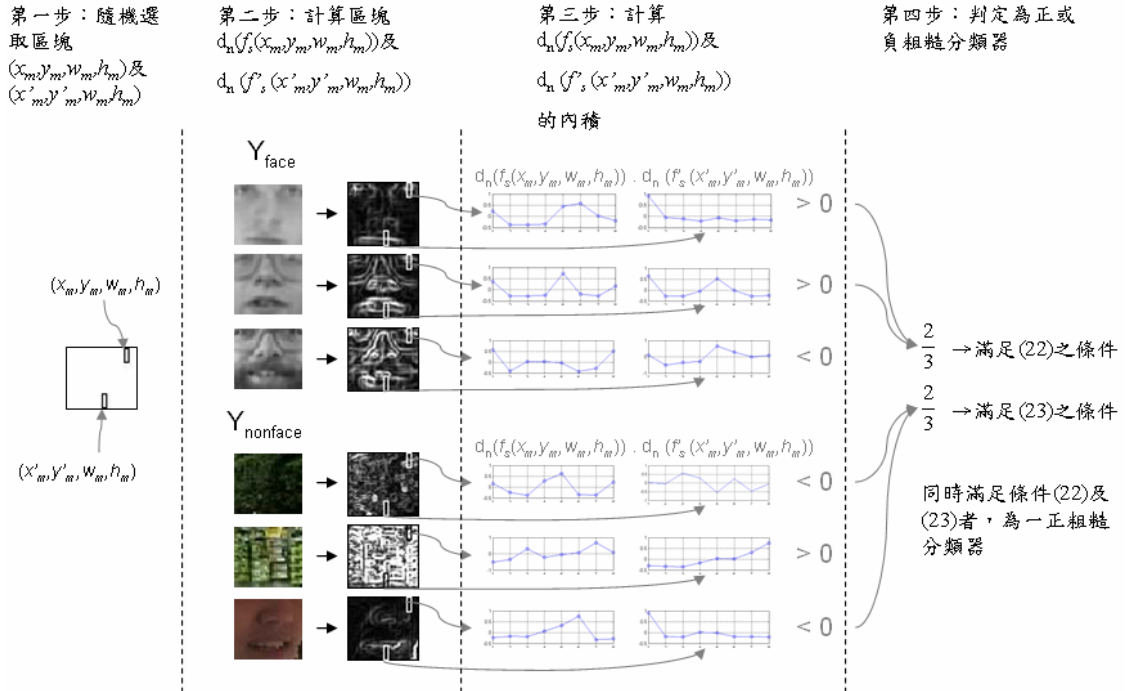
正和負粗糙分類器兩者皆須滿足：

$$x_m \neq x'_m \text{ and } y_m \neq y'_m \quad \forall m = 1 \dots M \quad (26)$$

(22)和(23)中，說明了若  $G_m$  為正粗糙分類器，其區塊  $f_s(x_m, y_m, w_m, h_m)$  和  $f_s(x'_m, y'_m, w_m, h_m)$  之梯度分佈內積值，在訓練資料  $\mathbf{Y}_{\text{face}}$  中有超過五成機率為正，且  $\mathbf{Y}_{\text{nonface}}$  中有超過五成的機率為負，以空間的觀點來說，任兩正規化後之向量內

積為正代表兩者同方向，且較為相似，為負則較不相似，因此(22)和(23)之目的在於從  $Y_{\text{face}}$  和  $Y_{\text{nonface}}$  中找出一組區塊，以內積結果之正負判定測試影像為人臉或非人臉，而(24)和(25)之意義與(22)和(23)相似，目的在從  $Y_{\text{face}}$  和  $Y_{\text{nonface}}$  中找出一組區塊在  $Y_{\text{face}}$  中有超過五成機率內積為負，且  $Y_{\text{nonface}}$  中有超過五成的機率內積為正，因此以負粗糙分類器進行分類時，其內積結果為負代表  $f_s$  為人臉，而(16)定義一個粗糙分類器之分類結果大於零為人臉，因此負粗糙分類器之內積需乘以 -1 以產生與正粗糙分類器一致的分類結果。

粗糙分類器之選擇以圖十一說明，假設  $Y_{\text{face}}$  和  $Y_{\text{nonface}}$  各有三張訓練影像，隨機選取區塊  $x_m, y_m, w_m, h_m$  及  $x'_m, y'_m, w'_m, h'_m$  後，對資料庫中每張影像計算區塊之梯度分佈，可知人臉資料庫  $Y_{\text{face}}$  中，第一和第二張影像區塊之梯度分佈內積皆為正，代表  $Y_{\text{face}}$  中有 2/3 之訓練資料滿足(22)式，而非人臉資料庫  $Y_{\text{nonface}}$  中，第一和第三張影像區塊之梯度分佈內積皆為負，代表  $Y_{\text{nonface}}$  有 2/3 之訓練資料滿足(23)式，因此區塊  $x_m, y_m, w_m, h_m$  及  $x'_m, y'_m, w'_m, h'_m$  為一正粗糙分類器，而負粗糙分類器之選擇方式亦然。



圖十一：選擇正粗糙分類器之步驟。

### 3.5 AdaBoost 演算法

每個粗糙分類器的權重決定了其分類值結果的重要性，本研究提出以 AdaBoost 演算法決定每個粗糙分類器的權重，AdaBoost 以兩類訓練資料的錯誤率進行權重之調整，達到每個粗糙分類器權重的最佳化。假設強分類器 SC 有  $M$  個粗糙分類器  $G_1, G_2, \dots, G_M$ ，而每個分類器權重為  $\alpha_1, \alpha_2, \dots, \alpha_M$ ，AdaBoost 演算法訓練權重步驟如下[37]：

1. 初始：假設  $N$  筆訓練資料為  $(x_1, y_1), (x_2, y_2), \dots, (x_N, y_N)$ ，其中  $x_i$  為訓練資料，並且  $y_i \in \{1, -1\}$  代表訓練資料的分類，則初始每筆訓練資料的權重為  $w_i = 1/N$ 。
2. 計算每個粗糙分類器的權重  $\alpha_m, \forall m = 1 \dots M$ ，計算下列：
  - (a) 計算  $G_m$  的錯誤率加權：

$$err_m = \frac{\sum_{i=1}^N w_i \cdot I(y_i \neq \text{sign}(G_m(x_i)))}{\sum_{i=1}^N w_i} \quad (27)$$

$$\text{其中 } I(y_i \neq \text{sign}(G_m(x_i))) = \begin{cases} 1 & \text{if } y_i \neq \text{sign}(G_m(x_i)) \\ 0 & \text{if } y_i = \text{sign}(G_m(x_i)) \end{cases} \quad (28)$$

(b) 則  $G_m$  分類器的權重即為：

$$\alpha_m = \log((1 - err_m)/err_m) \quad (29)$$

(c) 而調整後的  $\alpha_m$  對於訓練資料權重影響為：

$$w_i \leftarrow \exp[\alpha_m \cdot I(y_i \neq \text{sign}(G_m(x_i)))] \quad \forall i = 1 \dots N \quad (30)$$


以(a)、(b)以及(c)即可得到每個分類器以及訓練資料的權重。

3. 計算錯誤率  $err$ ：

$$err = \frac{1}{N} \cdot \sum_{i=1}^N I(y_i \neq \text{sign}(SC(x_i))) \quad (31)$$

回到步驟 2，直到錯誤率無法下降為止。

其中  $\alpha_m = \log((1 - err_m)/err_m)$  之  $G_m$  分類器的權重  $\alpha_m$  調整原則基於  $err_m$  值的大小，如圖十二所示，若  $G_m$  的分類錯誤率較高(接近 1)時，則此分類器的權重  $\alpha_m$  會被壓抑，若  $G_m$  的分類錯誤率較低(接近 0)時，則此分類器的權重  $\alpha_m$  值會被提升，而  $w_i$  為訓練資料之權重可視對於分類器  $G_m$  的重要性，若某訓練資料  $x_i$  在  $G_m$  中的測試結果與分類結果不合，也就是  $y_i \neq \text{sign}(G_m(x_i))$ ，則  $x_i$  的權重  $w_i$  會以指數函數提升，意即  $x_i$  對於  $G_m$  的重要性的提升，AdaBoost 藉著不斷的更新測試資料之權重以產生較精確之粗糙分類器權重，進而得到最佳的分類結果。



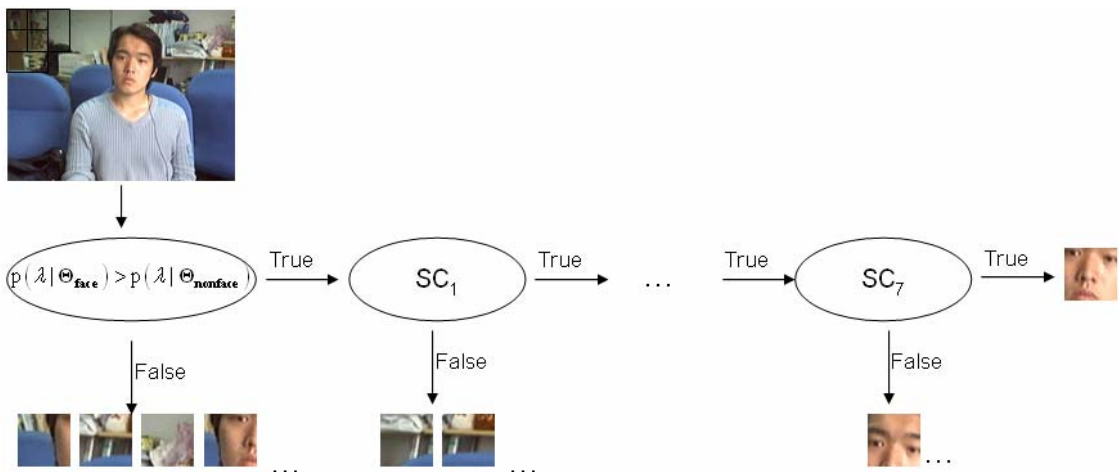
圖十二：此圖表示(29)中的調整曲線  $\log\left(\frac{1-err_m}{err_m}\right)$ ，其中  $err_m$  為橫軸，介於 0 到 1 之間，而縱軸為調整結果，介於正無限大到負無限大之間。

### 3.6 串連式分類器(Cascades of Classifier)

為了加速人臉偵測，本研究以串連式分類器[38]進行偵測，以圖十三為例，

若串連七個梯度空間相關性模型( $SC_1, SC_2, \dots, SC_7$ )，將可能為臉部之區塊經過第一個模型判斷後，若大於預設門檻值，則再以第二個模型加以判斷，依此類推。

串連式分類器設計上，每個分類器需選擇適合的門檻值，保留人臉視窗並將移除誤判視窗，因此分類器需具有高偵測率，且經過每階段的分類後，誤判率會逐漸降低，以達到正確偵測人臉之目標。



圖十三：若串連七個梯度空間相關性模型( $SC_1, \dots, SC_7$ )， $SC_1$  將(15)式誤判之視窗進行分類，若大於某預設門檻值再以  $SC_2$  進行分類，依此類推，每個分類器保留人臉視窗並移除誤判視窗。