

# Sistema de reconocimiento facial basado en imágenes con color

---

**BEATRIZ OMAIRA PEDRAZA PICO**

*Ingeniera de Sistemas  
Universidad Industrial de Santander  
beatriz.pedraza.pico@gmail.com  
bpedraza@corrosion.uis.edu.co*

**PAOLA RONDÓN**

*Magister en Ingeniería de Sistemas e Informática  
Universidad Industrial de Santander  
paitorv@gmail.com*

**HENRY ARGUELLO**

*Magister en Potencia Eléctrica  
Universidad Industrial de Santander  
Profesor Asistente UIS  
henarfu@udel.edu*

*Fecha de recibido: 29/09/2011  
Fecha de aprobación: 15/12/2011*

## RESUMEN

En este trabajo se desarrolla un sistema algorítmico con el fin de comprobar si el papel del color puede ser un atributo importante en los sistemas de reconocimiento facial en dos dimensiones (2-D), con orientación frontal y pequeñas variaciones en los gestos de los individuos. La primera fase consiste en la detección y localización del rostro humano para la cual se emplea el algoritmo de aprendizaje AdaBoost y una combinación de clasificadores en cascada, con el fin de aumentar las tasas de detección. En una segunda fase se aplica el enfoque de eigenfaces y se implementa un sistema clasificador para reconocer e identificar el sujeto de entrada a un individuo específico, utilizando la distancia euclidiana y de mahalanobis. Se ilustran los resultados obtenidos del sistema propuesto tanto para imágenes en color como en grises, contrastando que la información del color en el plano HSV puede mejorar las tasas de reconocimiento cuando se compara con el plano RGB.

**PALABRAS CLAVE:** Análisis de Componentes Principales (PCA), Eigenfaces, AdaBoost, Distancia Euclidiana, Distancia Mahalanobis.

## ABSTRACT

This paper develops an algorithm system to check whether the role of color can be an important attribute in facial recognition systems in two dimensions (2-D), with frontal orientation and small variations in the gestures of individuals. The first phase involves the detection and localization of the human face for which the learning algorithm uses a combination of AdaBoost and cascade classifiers to increase detection rates. In a second phase the eigenfaces approach is applied and a classification system is implemented, to recognize and identify the subject of entry to a specific individual, using the Euclidean and Mahalanobis distance. We illustrate the results of the proposed system for both color images as gray, finding that the color information at the HSV plane can improve recognition rates when compared with the RGB plane.

**KEYWORDS:** Principal Component Analysis (PCA), Eigenfaces, AdaBoost, Euclidean Distance, Mahalanobis Distance.

## 1. INTRODUCCIÓN

Las técnicas de detección y reconocimiento de rostros han sido investigadas ampliamente en los últimos años [1] [2] [3] [4] [13]. Estas técnicas han sido aplicadas en una amplia variedad de problemas, incluyendo: la identificación biométrica para clasificación de individuos [5] [6] [7] [8] [9], sistemas de seguridad para reconocimiento [10] y procesamiento de imágenes y video para mejorar la calidad y facilitar la búsqueda de información [11] [12], entre otras.

La mayoría de las investigaciones en detección y reconocimiento de rostros se han basado en el uso de imágenes en escala de grises. Este trabajo involucra imágenes en color para detectar y reconocer rostros [24] [25] [26] [28] [33], debido a que el color juega un papel importante para el estudio del rostro humano. Estas técnicas tienen en cuenta las variaciones de iluminación [27] de la imagen captada, que representa el individuo a evaluar y reconocer.

A su vez existen grandes números de investigaciones y desarrollos para solucionar problemas de detección de rostros [1] [2] [14] [21] y de reconocimiento facial [29] [30] [31] [32] [34] [35] [36] con el fin de construir un esquema de detección y reconocimiento robusto, eficaz y versátil. El método de detección de rostros de este trabajo se basó en el modelo de Viola-Jones [14], más conocido como el algoritmo de aprendizaje de AdaBoost [15] [16] [17] [18], el cual consiste en detectar y localizar la posición de un número indefinido de caras en una imagen captada, teniendo en cuenta que el individuo debe ubicarse de forma frontal y la imagen puede diferir en sus colores, expresiones, condiciones de iluminación o resolución. Por lo tanto, este método es apropiado para cualquier aplicación donde se necesite detectar objetos [15] [21] con variabilidad sin tener que limitarse sólo a caras.

Por otra parte, la etapa de reconocimiento facial se fundamentó en el enfoque de Eigenfaces [37] [38], también conocido como el método de Análisis de Componentes Principales (PCA) [35] [36] [39]; el cual consiste en descomponer un grupo de imágenes de rostros en un pequeño conjunto de vectores denominados Eigenfaces, que poseen la información principal de un grupo inicial de caras de entrenamiento. De esta manera, se logra cambiar el espacio original de la imagen, por otro espacio generado a partir de las imágenes originales haciendo uso de la transformada de Karthunen-Loeve también conocida como PCA.

Finalmente se realiza la clasificación del rostro de la persona, comparando la similitud entre el espacio generado por el nuevo individuo y el espacio generado por el individuo conocido.

## 2. METODOLOGÍA

### 2.1 Procesamiento de Imágenes

Las diferentes etapas involucradas en un sistema de detección y reconocimiento de rostros son mostradas en la Figura 1. Las técnicas de Procesamiento Digital de Imágenes (PDI) basadas en color permiten representar adecuadamente la información de una imagen por medio de la computadora.

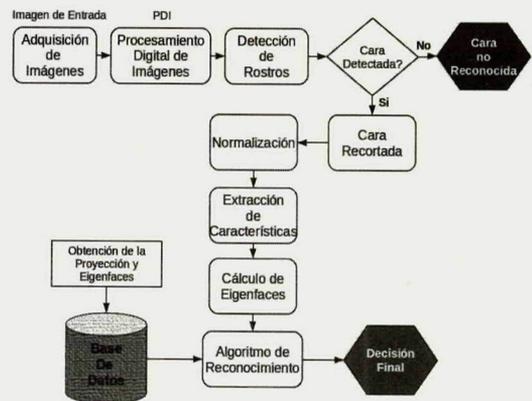


Figura 1. Estructura del Sistema de Detección y Reconocimiento de Rostros.

Se define entonces el PDI como un conjunto de técnicas de pre-procesamiento que se aplican a las imágenes digitales para mejorar la calidad y facilitar la interpretación humana y el tratamiento de los datos mediante la percepción autónoma de la máquina. Dicho conjunto de técnicas se ilustran en la Figura 2, en donde se hace uso de las técnicas de mejoramiento de imágenes digitales.

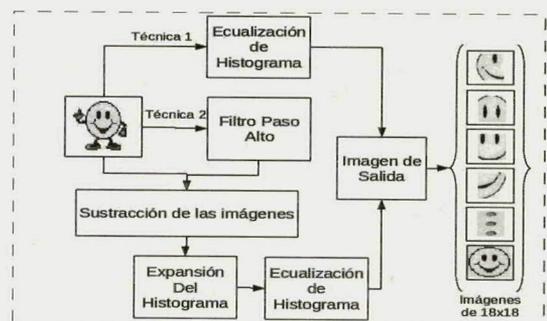


Figura 2. Modelo de las Técnicas de Pre-Procesamiento Digital de Imágenes.

Los métodos de mejoramiento de imágenes digitales se pueden dividir en dos campos diferentes: Métodos en el dominio frecuencial y métodos en el dominio espacial. Los primeros se basan en la transformada de Fourier de la imagen, mientras que los segundos se basan en manipulaciones directas sobre los píxeles de la imagen.

Para este trabajo se emplearon dos tipos de técnicas de mejoramiento de imagen digital en el dominio espacial. La primera técnica radica en efectuar una ecualización del histograma, siendo éste la representación gráfica y estadística que relaciona los Niveles de Intensidad (NI) del color de una imagen digital y el número de píxeles que poseen, permitiendo percibir cualquier incremento o disminución de su brillo, contraste y tonalidad.

La ecualización del histograma se basa en lograr una distribución más uniforme entre el número de píxeles referido con respecto a los diferentes NI que presenta en la imagen. Su función radica en aumentar y disminuir al mismo tiempo el contraste de la imagen, mediante el incremento y reducción de los NI que se encuentran más cercanos al valor máximo y mínimo del histograma respectivamente. Matemáticamente la ecualización del histograma  $H(Q)$  se define como:

$$H(Q) = \frac{L-1}{n * m} \sum_{j=0}^Q h_f(j) \quad (1)$$

Donde  $L$  es el valor máximo del conjunto  $Q = \{0, \dots, Q-1\}$  que representa los  $q$  Niveles de Intensidad (NI) de la imagen  $f: n \times m \rightarrow Q \times Q$  con dimensión de  $(n \times m)$  y donde  $h_f$  es el histograma de la imagen  $f$ .

La segunda técnica contempla una combinación de algunas de las operaciones de manipulación del histograma definidas anteriormente con la técnica de filtrado de la imagen de tipo *unsarp masking* [11]. Este tipo de filtrado se caracteriza por ser un filtro paso alto, ya que permite a cada uno de los píxeles de la imagen pasar las componentes de altas frecuencias y diluir las de bajas frecuencias pertenecientes al histograma; con el fin de lograr un mejor realce al momento de aplicar la sustracción de imágenes  $f_s$  definida por:

$$f_s = f * (\alpha - 1) + f_a \quad (2)$$

Donde  $f$  es una imagen bajo análisis,  $\alpha$  es un factor de escala y  $f_a$  es la imagen  $f$  filtrada con un filtro paso alto.

El factor  $\alpha$  es un factor de amplificación para obtener un mejor realce de la imagen y determina la naturaleza del filtro:

- Si  $\alpha = 1$  es un filtro de alta frecuencia pura.
- Si  $\alpha < 1$  la imagen resultante aparece como un negativo de la imagen original.
- Si  $\alpha > 1$  el realzado es notable.

Una vez sustraída la imagen, el paso siguiente es la expansión del histograma definida como:

$$g(a,b) = \frac{f(a,b) * f_{\min}}{f_{\max} * f_{\min}} * 255 \quad (3)$$

La expansión entre dos puntos  $(a,b)$  del histograma de la imagen  $f$  y hacer que estos valores se correspondan con el mínimo  $f_{\min}$  y el máximo  $f_{\max}$  de los NI de la imagen  $f$ ; con el fin de incrementar el contraste de la imagen  $f$  dada. Finalmente se realiza la ecualización del histograma de la imagen expandida.

## 2.2 Detección de Rostros



Figura 3. Estructura del sistema clasificador en cascada.

Una vez realizada la técnica de mejoramiento de imágenes se obtiene como salida la imagen pre-procesada, para luego ser detectada la cara en el algoritmo de AdaBoost. Este algoritmo utiliza un clasificador con la arquitectura en cascada como se observa en la figura 3, el cual contiene un conjunto de  $n$  clasificadores fuertes [14] y un sub-conjunto de  $n$  clasificadores débiles. Donde por cada clasificador débil (ver figura 4) se usan: una de las características de tipo Haar [19] [23], la imagen de entrada evaluada en dichas características sobre la Imagen Integral [14] y una máquina de aprendizaje [20], como las Máquinas de Soporte Vectorial (SVM) [22]. Las SVM construyen un modelo o función de clasificación el cual permite aumentar el rendimiento de discriminación entre una serie de imágenes que contienen el conjunto de las Caras e imágenes que incluyen cualquier otro elemento que representan al conjunto de las No Caras como se observa en la figura 4.

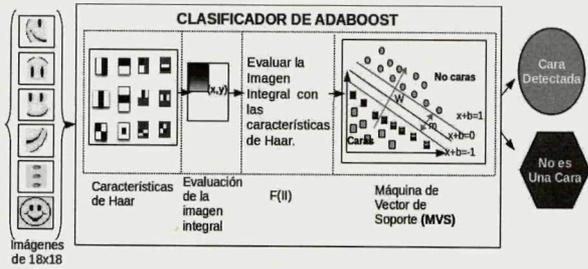


Figura 4. Estructura del sistema de clasificación débil para detectar rostros.

Las salidas que genera cada uno de los clasificadores débiles sirven como criterios de decisión en cada uno de los  $n$  clasificadores fuertes permitiendo eliminar las posibles No Caras del conjunto de Imágenes de píxeles, o clasificarlas como posibles Caras en el menor tiempo posible. Finalmente el algoritmo AdaBoost obtiene de estas operaciones una Cara detectada o una No Cara según corresponda el caso en el sistema de clasificador en cascada de la figura 3.

### 2.3 Reconocimiento Facial

Finalmente obtenido el rostro detectado se procede a realizar su reconocimiento aplicando el enfoque de Eigenfaces; por ello, es necesario dividir el sistema de reconocimiento de rostros en dos fases: Entrenamiento y Prueba [24] [25] [33] como se observa en la figura 5.

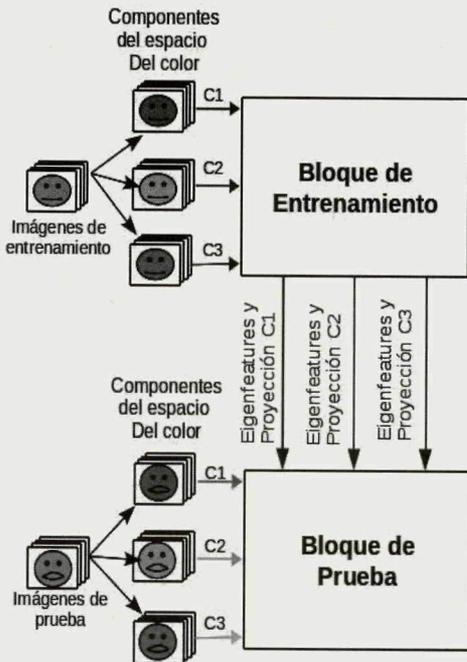


Figura 5. Estructura del sistema de reconocimiento facial.

En la figura 5 se contempla que se trabajan en las fases de entrenamiento y prueba por separado cada componente del color del rostro detectado. Posteriormente las imágenes, son normalizadas y halladas sus Eigenfaces y sus proyecciones respectivamente.

La normalización de estas imágenes es necesaria para corregir las dependencias de las propiedades de las mismas como lo son el brillo, el contraste, entre otros. La normalización de la imagen se define como la división entre el número de niveles  $nv$  y la sustracción entre los valores máximos  $I_{max}$  y mínimos  $I_{min}$  de niveles de grises en la imagen detectada  $I$  por el valor de grises de dicha imagen  $I$  en el punto  $(x,y)$ :

$$Norm(x,y) = \frac{nv}{I_{max} - I_{min}} * (I(x,y) - I_{min}) \quad (4)$$

#### 2.3.1 Fase de Entrenamiento

En la fase de entrenamiento (ver figura 6) cada componente del color de la imagen separada será evaluada en el algoritmo de PCA, con el fin de obtener los componentes principales (Eigenfaces) y la proyección de la imagen para ser almacenadas y posteriormente comparadas en la etapa de prueba.

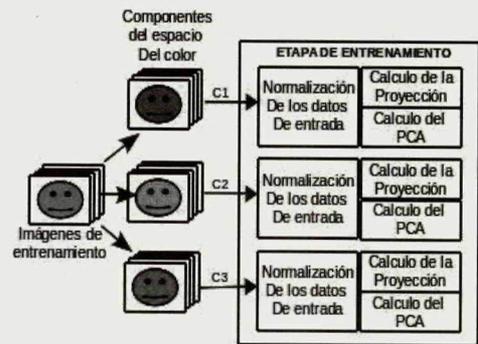


Figura 6. Bloque de Entrenamiento.

En el algoritmo de *Análisis de Componentes Principales* (PCA) un rostro es visto como un vector de imágenes, donde cada columna representa un vector de  $(N \times M, 1)$ ; es decir, que dicho vector es el resultado de una simple concatenación entre filas de un rostro de tamaño de  $(N \times M)$ ; cuyo vector de rostros resultante pertenece a un espacio denominado Espacios de Caras y es allí, donde se encuentran todas las imágenes de dimensión  $(N \times M)$  píxeles.

Al principio este *Espacio de Caras* no es el más óptimo y se recomienda construir un nuevo espacio llamado

Componentes Principales o *Eigenfaces*; el cual se encarga de describir mejor las imágenes de los rostros. Por esta razón, se emplea el método de Análisis de Componentes Principales (PCA) cuyo objetivo es reducir la dimensión de un conjunto de espacio de caras de modo que la nueva base describa mejor el conjunto de rostros, tal como se explica en el algoritmo 1.

**Algoritmo 1** Entrenamiento de PCA

**Entrada:** Sea  $I$  el conjunto de imágenes de entrenamiento

$$I = \{\Gamma_1, \Gamma_2, \dots, \Gamma_M\} \quad \text{Donde } I \in R^{N \times M}$$

Donde  $N$  es el número de individuos a entrenar y  $M$  es la dimensión en píxeles de la imagen a entrenar. El siguiente paso es calcular los eigenfaces desde el conjunto de las imágenes de entrenamiento:

- a) Evaluar la imagen promedio del conjunto de caras a entrenar:

$$\psi = \frac{(\Gamma_1 + \Gamma_2 + \dots + \Gamma_M)}{M} \quad \text{Donde } \psi \in Z^{N \times 1}$$

- b) Ajustar cada imagen  $I$  con respecto a  $\psi$

**Para**  $j=1, \dots, M$  **hacer**

$$\phi_j = \Gamma_j - \psi \quad \text{Donde } \phi \in R^{N \times M}$$

**Fin para**

- c) Determinar la matriz de covarianza  $C$

$$C = \frac{1}{M} \sum_{j=1}^M \phi_j \phi_j^t = AA^t \quad \text{Donde } C \in R^{M \times M}$$

$$A = \frac{(\phi_1, \phi_2, \dots, \phi_M)}{\sqrt{M}}$$

- d) Computar el vector y el escalar que son los eigenvectores y eigenvalores respectivamente de la matriz de covarianza

$$Cu_k = \lambda_k u_k \quad \text{Donde } u_k \in R^{M \times 1}$$

- e) Ordenar descendientemente los  $\lambda_k$  con el fin de hallar los  $M'$  componentes principales, nombrados también como eigenfaces  $\vec{e}$  Donde  $\vec{e} \in R^{M \times M'}$

$$\lambda_1 \geq \lambda_2 \geq \lambda_3 \geq \dots \geq \lambda_{M'}$$

$$\vec{e} = [u_1, u_2, u_3, \dots, u_{M'}]$$

- f) Finalmente proyectar los datos mediante el uso del producto escalar:

$$\omega_k \vec{e}_k^T * \phi \quad \text{Donde } \omega_k \in R^{M' \times 1}$$

- 1. Para después obtener un vector de pesos:

$$\phi_k^T = [\omega_1, \omega_2, \omega_3, \dots, \omega_{M'}]$$

- 2. Y una matriz de pesos:

$$\Omega^T = [\phi_1^T, \phi_2^T, \phi_3^T, \dots, \phi_{M'}^T]$$

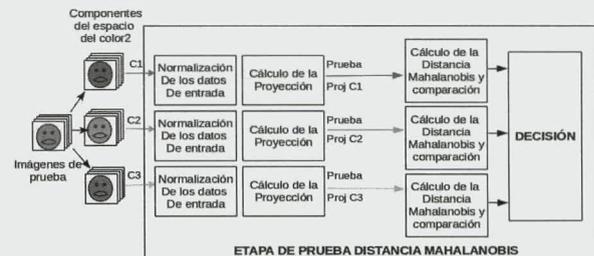
$$\text{Donde } \Omega^T \in R^{M' \times M}$$

**Salida:** Los Eigenfaces  $\vec{e}$  la Proyección de todo el conjunto de datos de entrenamiento

De esta manera se obtiene las variables necesarias y menos redundantes generando un ahorro de consumo en memoria y tiempo de procesamiento tanto para la etapa de entrenamiento como de prueba.

**2.3.2 Fase de Prueba**

La fase de prueba se ilustra en las figuras 7 y 8; cuyo proceso comienza con la normalización de la imagen de entrada y luego se realiza para cada componente del espacio de color el producto escalar, una operación básica que permite determinar la proyección de la imagen de prueba con respecto a los eigenfaces calculados en la fase anterior. Finalmente se realiza el criterio de decisión de clasificación de rostros. El algoritmo 2 muestra los casos más importantes para reconocer e identificar el individuo mediante el uso del argumento mínimo del cálculo de las distancias entre el conjunto de imágenes proyectadas en la fase de entrenamiento y la imagen de prueba.



**Figura 7.** Etapa de Prueba aplicando la Distancia de Mahalanobis.

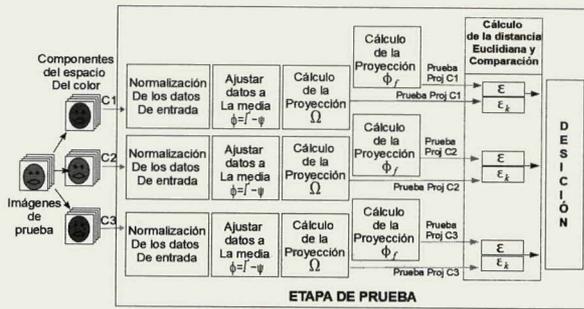


Figura 8. Etapa de Prueba aplicando la Distancia de Euclidiana.

**Algoritmo 2** Clasificación del Rostro

**Entrada:**

- Distancia de Mahalanobis  $d_{EM}$
- Distancia Euclidiana entre  $k$  clases  $\varepsilon_k$
- Distancia Euclidiana Espacial  $\varepsilon$
- Umbrales máximos predefinidos para cada  $k$  clase de las respectivas distancias  $\theta_{ek}, \theta_{em}$  que pertenecen a una base de datos de entrenamiento

**Hacer:**

**Paso 1: Inicialización de Variables**

$Index = \arg \min(d_{EM})$   
 $ID = \arg \min(\varepsilon_k)$   
 $k = 1$

**Paso 2: Reconocimiento del Rostro**

Realizar fase iterativa hasta encontrar a que clase de individuo pertenece:

**Mientras** ( $d_{EM(k)} \geq \theta_{em(Index)}$ ) **hacer**

$k \leftarrow k + 1$

**Fin mientras**

**Si** ( $k == Index$ ) **entonces**

**Paso 3: Identificación del Rostro**

Asumiendo que el  $ID=k$  existen cuatro posibilidades para que el individuo sea identificado:

1. **Si** ( $\varepsilon_k \leq \theta_{ek}$ )  $\cap$  ( $\varepsilon \leq \theta_{ek}$ ) **entonces:**  
El individuo es identificado.
2. **Si** ( $\varepsilon_k \leq \theta_{ek}$ )  $\cap$  ( $\varepsilon \geq \theta_{ek}$ ) **entonces:**  
El individuo es rechazado.
3. **Si** ( $\varepsilon_k \geq \theta_{ek}$ )  $\cap$  ( $\varepsilon \leq \theta_{ek}$ ) **entonces:**  
El individuo es desconocido.
4. **Si** ( $\varepsilon_k \geq \theta_{ek}$ )  $\cap$  ( $\varepsilon \geq \theta_{ek}$ ) **entonces:**  
No es una Cara.

**Si No**

Rostro no Reconocido.

**Fin Si**

**Salida:** Rostro reconocido e identificado, o Rostro reconocido pero rechazado o desconocido, o Rostro no reconocido.

**Algoritmo 3** Reconocimiento Facial

**Entrada:**  $\{f, \psi, \Omega, \vec{e}, \lambda, k\}$

- Donde  $f \in R^{(n*m)*1}$  es la imagen de prueba concatenada como un vector de dimensión  $(n*m)$
- $\psi = \frac{(\Gamma_1 + \Gamma_2 + \dots + \Gamma_M)}{M}$  Donde la media de los datos
  - o Sea  $I = \{\Gamma_1, \Gamma_2, \dots, \Gamma_M\}$  Donde  $I \in R^{N*M} \forall (N \in k) \text{ y } \forall (M \in (n*m))$
  - o y sea  $k$  el número de individuos que existe en la base de datos de entrenamiento, conocido también como número de clases de personas
- Sea  $\Omega_k = [\omega_1, \omega_2, \dots, \omega_{M'}]$  el vector de proyección de las  $k$  clases de individuos que existe en el conjunto de la base de datos de entrenamiento. Donde  $\Omega_k \in R^{1*M'}$  y donde  $\omega_i$  es la proyección del sub- $i$  individuo conocido con respecto a los  $\vec{e}$  eigenfaces.
- $\vec{e} = [u_1, u_2, \dots, u_{M'}]$  Donde  $\vec{e} \in R^{M*M'}$ 
  - o Y donde  $u_i$  son los eigenvalores calculados de la matriz de covarianza  $C$  en la etapa de entrenamiento.

**Paso 1:** Ajustar los datos a la media

**Para**  $i = 1, \dots, M$  **hacer**

$\Phi_i = f_i - \psi_i$  Donde  $\Phi \in R^{M*1}$

**Fin para**

**Paso 2:** Proyección de la imagen de entrada

$\Omega = \vec{e}^T * \Phi$  Donde  $\Omega \in R^{M*1}$

$\Phi_f = \sum_{i=1}^M \Omega_i^t * \vec{e}_i^t$  Donde  $\Phi_f \in R^{1*M}$

**Paso 3:** Cálculo de la Distancia Euclidiana

- Sea  $\Omega$  la proyección del espacio del individuo desconocido se calcula la distancia euclidiana  $\varepsilon_k$  por cada individuo  $\Omega_k$  conocido, comúnmente llamado distancia euclidiana entre  $k$  clases

$$\varepsilon_k^2 = \|(\Omega - \Omega_k)\|^2$$

- Sea  $\Phi_f$  la proyección del espacio de caras de la imagen desconocida se calcula entonces, la distancia euclidiana  $\varepsilon$  entre la imagen  $\Phi$  de prueba y el espacio proyectado, éste tipo de distancia se denomina distancia euclidiana espacial

$$\varepsilon^2 = \|(\Phi - \Phi_f)\|^2$$

#### Paso 4: Cálculo de la Distancia Mahalanobis

- Sea  $(v_1, v_2)$  dos puntos cuya distancia de mahalanobis está dado por:

$$d_{EM}(v_1, v_2) = \|(v_1 - v_2)\|_M$$

$$d_{EM} = \sqrt{(v_1 - v_2)^T * inv(M) * (v_1 - v_2)}$$

Donde  $M \in R^{N*N}$  es una matriz diagonal positiva

- Usando la definición de la distancia de mahalanobis, la distancia entre la proyección de los datos original  $\Omega_k$  y la proyección de los datos de prueba  $\Omega$  es:

$$d_{EM} = \sqrt{(\Omega_k - \Omega)^T * inv(M) * (\Omega_k - \Omega)}$$

Donde  $M$  es la matriz diagonal de pesos  $\Lambda$  así:

$$\Lambda = \sum_{i=1}^{M'} \left( \frac{\lambda_i}{\sum \lambda} \right)$$

**Salida:** Tomar el argumento y el valor mínimo de cada una de las distancias evaluadas.

Las medidas  $(\varepsilon_k, \varepsilon, d_{EM})$  utilizadas en el paso 2 del algoritmo de clasificación del rostro mencionado, se obtienen mediante los procedimientos indicados en el algoritmo 3. En este último algoritmo se presenta el pseudocódigo del sistema de reconocimiento facial implementado en este trabajo, donde se muestran los 4 pasos teniendo en cuenta las variables de entrada para ajustar los datos, la proyección de la imagen y el cálculo de la distancia euclidiana y de mahalanobis de la imagen de prueba; con el fin de encontrar el valor mínimo y su argumento de cada una de las distancias evaluadas. Al obtener estos valores se realiza la clasificación del algoritmo 2 para la imagen de prueba haciendo una comparación entre los valores mínimos obtenidos en el algoritmo 3 y los umbrales  $\theta_{ek}, \theta_{em}$  previamente pre-establecidos en la fase de entrenamiento.

### 3. RESULTADOS

En este trabajo se utilizó la base de datos en color llamada *Georgia Tech Face Database*<sup>1</sup>. Esta base de datos contiene 50 imágenes en total, donde cada individuo posee 15 capturas en imagen a color, tomadas en sesiones diferentes, con fondos no uniformes, con variación tanto en orientación como expresión facial y con alteración de iluminación en la imagen captada.

Se eligieron 6 individuos distintos, donde por cada uno de ellos se seleccionaron 3 imágenes con diferentes variaciones en la imagen para la fase de entrenamiento; mientras que para la fase de prueba se escogieron 9 individuos con 3 imágenes diferentes para cada uno. Las imágenes de prueba y de entrenamiento fueron redimensionadas a una resolución de píxeles, con el fin de ser procesadas fácilmente en la etapa de detección y reconocimiento facial.

En la tabla 1 y 2 se muestran los resultados obtenidos de las imágenes de prueba para el espacio de color *RGB*, *HSV* y el plano en *GRIS* aplicando cada una de las técnicas de pre-procesamiento plateadas al inicio de este artículo; con el propósito de determinar el número de rostros reconocidos correcta o incorrectamente.

**Tabla 1.** Resultados del Sistema de Reconocimiento Facial aplicando la Ecuación del histograma como técnica de pre-procesamiento.

Espacio de Color	Porcentaje (%)		
	Sensibilidad	Especificidad	VPP
RGB	83,33	6,67	41,67
HSV	75,00	20,00	42,86
GRIS	75,00	6,67	39,13

**Tabla 2.** Resultados del Sistema de Reconocimiento Facial aplicando la técnica de filtrado y ecuación del histograma como técnica de pre-procesamiento

Espacio de Color	Porcentaje (%)		
	Sensibilidad	Especificidad	VPP
RGB	83,33	6,67	41,67
HSV	66,67	33,33	44,40
GRIS	75,00	13,30	40,91

Por lo tanto, los resultados ilustrados en estas tablas establecen los criterios de efectividad para el modelo propuesto, calculando la sensibilidad, especificidad y valor predictivo positivo (VPP) expresado en las siguientes ecuaciones:

$$Sensibilidad = \frac{VP}{VP + FN} * 100 \quad (5)$$

Donde la *Sensibilidad* mide la capacidad de clasificar correctamente a una imagen como cara, teniendo en cuenta los Verdaderos Positivos (*VP*) y los Falsos Negativos (*FN*). Los *VP* cuentan las caras que son reconocidas perfectamente como caras y los *FN* cuentan las caras que han sido reconocidas incorrectamente; es decir que computa aquellas caras como correctas cuando estas son las incorrectas.

<sup>1</sup> Disponible en Web: [http://www.aneftan.com/research/face\\_reco.htm](http://www.aneftan.com/research/face_reco.htm)

$$\text{Especificidad} = \frac{VN}{VN + FP} * 100 \quad (6)$$

La *Especificidad* se refiere a la capacidad de clasificar correctamente una imagen como no cara y a un sujeto como no reconocido, el cual mide los Verdaderos Negativos (*VN*) y los Falsos Positivos (*FP*). Donde el primero cuenta las caras que no son reconocidas perfectamente como no caras; es decir que determina aquellas no caras como caras no reconocidas por el sistema cuando efectivamente estas son caras incorrectas; y por último los *FP* cuentan las caras que no han sido reconocidas siendo estas *VP*.

El Valor Predictivo Positivo (*VPP*), determina la probabilidad de que un rostro dado sea realmente reconocido correctamente:

$$\text{VPP} = \frac{VP}{VP + FP} * 100 \quad (7)$$

#### 4. DISCUSIÓN Y CONCLUSIÓN

Al comparar este trabajo de investigación con la literatura de *Karimi y Krzyzak* [24], tal como se ilustra en la tabla 3, se justificó la importancia del color en el sistema de reconocimiento facial, obteniendo aproximadamente los equivalentes resultados utilizando la misma base de datos para el plano de color RGB y para la escala de grises.

**Tabla 3.** Comparación de los resultados obtenidos con el artículo *A Study on Significance of Color in Face Recognition using Several Eigenfaces Algorithms*, pag. 1311, IEEE-2007. Los valores en negrilla son los obtenidos en este trabajo

Tasa de Reconocimiento (Sensibilidad)	Conjunto de Datos	
	En Grises	En Color
PCA	62%	87%
FLD	87%	87%
Discriminative Common Vector	100%	100%
Laplacianfaces	100%	100%
PCA+Gabor Filers	75%	87%
FLD+Gabor Filers	87%	100%
<b>PCA+AdaBoost+Tecn.1</b>	75%	83%
<b>PCA+AdaBoost+Tecn.2</b>	75%	83%

Sin embargo, este trabajo indica que el espacio de color **HSV** proporciona una mejor señal que el espacio de color **RGB** para el reconocimiento de rostros; tal como se observaron en las tablas 1 y 2, y como lo afirma el autor *L. Torres* [25] en su artículo titulado "*The importance of the color information in face recognition*" usando diferentes componentes de colores, donde la componente **H** del plano **HSV** ha sido descartada tanto para este trabajo como para el autor *L. Torres*, por su no linealidad a la transformación del espacio de color; ya que dicha componente proporciona una distorsión en la imagen y "disminuye la tasa de reconocimiento".

Por lo tanto, de las pruebas realizadas con su debido pre-procesamiento, detección y reconocimiento de la imagen, se infiere que; para las imágenes en color la probabilidad de que un rostro sea reconocido correctamente es de un promedio de **42,65%** mientras que para las imágenes en grises es de **40,02%**, indicando que el espacio de color utilizado proporciona mejores resultados para el reconocimiento facial; donde el plano **HSV** obtiene mayor rendimiento de reconocer un rostro al emplear la técnica número 2 como pre-procesamiento digital de imágenes, mientras que para el plano **RGB** se adquirieron los mismos resultados en ambas técnicas de pre-procesamiento.

#### 7. AGRADECIMIENTOS

Este trabajo es financiado por la Vicerrectoría de Investigación y Extensión de la Universidad Industrial de Santander, mediante el proyecto de investigación con código interno 5537.

#### 8. REFERENCIAS

- [1] E. Hjelmas and B.K. Low, "Face detection: A survey" Computer Vision and Image Understanding, September 2001 pp. 236-274.
- [2] M. H. Yang, D. J. Kriegman, and N. Ahuja, "Detecting faces in images: A survey." IEEE Transactions on pattern analysis and machine intelligence, Vol. 24, No. 1, 2002, pp.34-58.
- [3] L. Lorente and L. Torres, "A global eigen approach for face recognition." International Workshop on Very Low Bit-rate Video Coding, Urbana, Illinois, USA, October 8-9 1998.

- [4] "Special issue on face and gesture recognition" IEEE Transactions on Pattern Analysis and Machine Intelligence, July 1997, vol. 19.
- [5] O.J. Hernandez and M. S. Kleiman, "Face recognition using multispectral random field texture models, color content, and biometric features". Applied Image Pattern Recognition Workshop, 2005, pp.204-209.
- [6] S. B. Lee and S. tsutsui, "Intelligent biometric techniques in fingerprint and face recognition". Boca Raton, FL, USA: CRC Press, Inc., 1999.
- [7] J. Fabregas and M. Faundez-Zanuy, "Biometric face recognition with different training and testing databases". in Verbal and Nonverbal Features of Human-Human and Human-Machine Interaction (A.Esposito, N.Bourbakis, N.Avouris, and I. Hatzilygeroudis, eds.), vol. 5042 of Lecture Notes in Computer Science, Springer Berlin Heidelberg, 2008, pp. 44—55.
- [8] E. Hjelmas, "Biometric Systems: A Face Recognition Approach", 2000.
- [9] J. Abbazio, S. Perez, D. Silva, R. Tesoriero, F. Panna, and R. Zack, "Face biometric systems". Proceeding of Student-Faculty Research Day, CSIS, Pace University, Mayo 8th 2009.
- [10] S. M. V. Palacios, "Sistema de reconocimiento de reconocimiento de rostros". Universidad Peruana de Ciencias Aplicadas (UPC).
- [11] R. C. González and R. E. Woods, "Digital Image Processing", 3rd ed. Upper Saddle River, NJ, USA: Prentice-Hall, Inc., 2006.
- [12] J. C. Russ, "The image processing handbook", 3rd ed Boca Raton, FL, USA: CRC Press, Inc., 1999.
- [13] A. Rama and F. Tarrés, *Un nuevo método para la detección de caras basado en integrales difusas*. Universidad Politécnica de Catalunya, Barcelona, España.
- [14] P. Viola and M. J. Jones, Robust real-time face detection. Int. J.Comput. Vision, vol.57, May 2004, pp.137-154.
- [15] R. Lienhart, A. Kuranov, and V. Pisarevsky, "Empirical analysis of detection cascades of boosted classifiers for rapid object detection". in Pattern Recognition of Lecture Notes in Computer Science, Springer Berlin / Heidelberg, 2003, vol. 2781, pp. 297-304.
- [16] H. Masnadi-Shirazi, "Adaboost face detection". Department of Electoral and Computer Engineering at the University of California, San Diego.
- [17] R. E. Schapire, Y. Freund, P. Bartlett, and W. S. Lee, "Boosting the margin: A new explanation for the effectiveness of voting methods". The Annals of Statistics, 1997, vol. 26, pp. 322-330.
- [18] R. E. Schapire, Y. Freund, P. Bartlett, and W. S. Lee, "Boosting the margin: A new explanation for the effectiveness of voting methods". The Annals of Statistics, 1998, vol. 26, No. 5, pp. 1651-1686.
- [19] *An extended set of Haar-like features for rapid object detection*. 2002, vol. 1.
- [20] E. Osuna, R. Freund, and F. Girosit, "Training support vector machines: an application to face detection". in Computer Vision and Pattern Recognition, Proceedings, IEEE Computer Society Conference, June 1997, pp. 130-136.
- [21] C. P. Papageorgiou, M. Oren, and T. Poggio, "A general framework for object detection". Computer Vision, IEEE International Conference on, 1998, p. ~555.
- [22] E. E. Osuna, R. Freund, and F. Girosi, "Support vector machines: Training and applications". 1997.
- [23] S. Han, Y. Han, and H. Hahn, "Vehicle on significance of color in face recognition using several eigenface algorithms". World Academy of Science, Engineering and Technology, 2009.
- [24] B. Karimi and A. Krzyzak, "A study on significance of color in face recognition using several eigenface algorithms". in Electrical and Computer Engineering, CCECE 2007. Canadian Conference on, pp. 1309-1312.
- [25] L. Torres, J. Reutter, and L. Lorente, "The importance of the color information in face recognition". Image Processing, ICIP99, Proceedings. International Conference, 1999, vol. 3, pp. 627-631.

- [26] A. Yip and P. Sinha, "Role of color in face recognition". AIM-2001-035, CBCL-212, December 2001.
- [27] X. Yu and G. Baciú, Face recognition from color images in presence of dynamic orientations and illumination conditions in Biometric Authentication (D. Zhang and A. K. Jain, eds.), of Lecture Notes in Computer Science, Springer Berlin Heidelberg, 2004, vol. 3072, pp. 1-21.
- [28] M. J. Swain and D. H. Ballard, "Color indexing". International Journal of Computer Vision, 1991, vol. 7, pp. 11-32.
- [29] J. Lu, K. Plataniotis, and A. Venetsanopoulos, "Face recognition using lda-based algorithms". Neural Networks, IEEE Transactions, Jan. 2003, vol. 14, pp. 195 - 200.
- [30] M. Bartlett, J. Movellan, and T. Sejnowski, "Face recognition by independent component analysis". Neural Networks, IEEE Transactions on, Nov. 2002, vol. 13, pp. 1450 - 1464.
- [31] H. Cevikalp, M. Neamtu, M. Wilkes, and A. Barkana, "Discriminative common vectors for face recognition". IEEE Transactions on Pattern Analysis and Machine Intelligence, 2005, vol. 27, pp. 4-13.
- [32] X. He, S. Yan, Y. Hu, P. Niyogi, and H.-J. Zhang, "Face recognition using laplacianfaces". Pattern Analysis and Machine Intelligence, IEEE Transactions, 2005, vol. 27, No. 3, pp. 328 -340.
- [33] Z. Liu and C. Liu, "A hybrid color and frequency features method for face recognition". Image Processing, IEEE Transactions, 2008, vol. 17, No. 10, pp. 1975-1980.
- [34] A. H. Sahoozadeh, B. Z. Heidari, and C. H. Dehghani, "A new face recognition method using pca, lda and neural network". Proc. WASET, Julio 2008, vol. 31.
- [35] H. Moon and P. J. Phillips, "Computational and performance aspects of pca-based face-recognition algorithms". 2001, vol. 30, No. 3, pp. 303-321.
- [36] K. Kim, "Face recognition using principal component analysis".
- [37] M. Turk and A. Pentland, "Eigenfaces for recognition". J. Cognitive Neuroscience, January 1991, vol. 3, pp. 71-86.
- [38] M. A. Turk and A. P. Pentland, "Face recognition using eigenfaces". Proceedings IEEE Computer Society Conference on Computer Vision and Pattern Recognition, 1991, pp. 586-591.
- [39] N. Morizet, F. Amiel, I. Hamed, and T. Ea, "A comparative implementation of pca face recognition algorithm". in Electronics, Circuits and Systems, ICECS 2007. 14th IEEE International Conference, pp. 865-868.

Copyright of UIS Ingenierías is the property of Revista UIS Ingenierías and its content may not be copied or emailed to multiple sites or posted to a listserv without the copyright holder's express written permission. However, users may print, download, or email articles for individual use.