

Una propuesta para incrementar por medio de Algoritmos Genéticos la capacidad discriminante de las técnicas PCA y LDA aplicadas al Reconocimiento de Rostros con Imágenes IR

A proposta para acrescentar a capacidade discriminatória das técnicas de PCA e LDA aplicadas ao reconhecimento facial em imagens IR mediante algoritmos genéticos

A Proposal to increase by genetic algorithm the discriminatory power of PCA and LDA techniques applied to Face Recognition with IR images

Duber Martínez T. ¹, Humberto Loaiza C. ² y
Eduardo Caicedo B. ³

Recepción: 11-may-2010/Modificación: 08-ene-2011/Aceptación: 07-feb-2011

Se aceptan comentarios y/o discusiones al artículo

¹ Magíster en Ingeniería de la Universidad del Valle, duber@univalle.edu.co, profesor, Universidad del Valle-Cali, Colombia.

² Doctor en Robótica y Visión Artificial de l'Université d'Evry- France, humberto.loaiza@correounivalle.edu.co, profesor, Universidad del Valle, Cali-Colombia.

³ Doctor en Informática Industrial de la Universidad Politécnica de Madrid, eduardo.caicedo@correounivalle.edu.co, profesor, Universidad del Valle, Cali-Colombia.

Resumen

Dos de las técnicas más ampliamente utilizadas en el campo del reconocimiento de rostros con imágenes infrarrojas son PCA (Principal Component Analysis) y LDA (Linear Discriminant Analysis). En este trabajo se presentan los resultados obtenidos al emplear algoritmos genéticos para incrementar el poder discriminante de los vectores que conforman el espacio de características generado por dichas técnicas, por medio de la asignación ponderada de pesos a cada vector según su nivel de aporte en la etapa de clasificación. Se muestra que bajo el esquema propuesto, se obtiene un menor error de clasificación respecto al método convencional.

Palabras claves: Reconocimiento de rostros, imágenes infrarrojas, Algoritmos genéticos, Análisis de Componentes Principales, Análisis Discriminante Lineal.

Resumo

Das das técnicas mais utilizadas no campo do reconhecimento facial em imagens de infravermelhos são PCA (Análise de Componentes Principais) e LDA (Análise de Discriminantes Lineales). Este artigo apresenta os resultados obtidos ao usar a seguir dessas técnicas uma nova etapa com algoritmos genéticos. Os resultados dessa combinação mostram um aumento na capacidade de discriminação obtida por só usar PCA ou LDA. Os algoritmos genéticos melhoram o reconhecimento ao estabelecer pesos ponderados para cada vetor de acordo com seu nível de contribuição na etapa de classificação. Mostra-se que com o esquema proposto, o erro de classificação é inferior ao obtidos por os métodos convencionais.

Palavras chaves: Reconhecimento facial, imagens de infravermelhos, algoritmos genéticos, Análise de Componentes Principais, Análise de Discriminantes Lineales.

Abstract

PCA and LDA are two of most widely used techniques for face recognition with IR images. In this paper we report the results obtained by using Genetic Algorithms for optimization the characteristic vector generated by these techniques, by assignation of weights to each vector according its performance in the classification task. It shows that, under the proposed scheme, is able to obtain a lower classification error compared to conventional method.

Key words: Faces recognition, infrared images, genetic algorithm, Principal Component Analysis, Linear Discriminant analysis.

1 Introducción

Uno de los aspectos más críticos para los sistemas automáticos de reconocimiento de rostros es la variación de las condiciones de iluminación de la escena [1], [2]. En los últimos años se ha explorado el empleo de cámaras infrarrojas (IR) que visualizan la distribución del calor corporal y son inherentemente invariantes ante cambios en las condiciones de iluminación y a las sombras que se presentan por variaciones en la expresión del rostro. Una ventaja adicional al emplear imágenes IR es su mayor seguridad para evitar suplantación de identidad por medio de máscaras o imágenes del sujeto suplantado.

Varios trabajos previos han mostrado la validez del empleo de imágenes IR para el reconocimiento de rostros, al comparar su desempeño respecto a imágenes en el espectro visible. En [3] los autores comprueban el efecto de las variaciones de iluminación en la tarea de reconocimiento al emplear imágenes IR. En [4] se emplea PCA para reconocimiento en completa oscuridad. Una comparación entre el desempeño de PCA al emplear imágenes IR respecto a las de espectro visible se realizó en [5]. En [6] los autores fusionan información del espectro visible con el infrarrojo para la tarea de reconocimiento en ambientes no controlados tanto interiores como exteriores. En [7] se estudia el efecto sobre el desempeño cuando entre las imágenes de prueba ha transcurrido intervalos de tiempo del orden de semanas. En [8] se emplean imágenes infrarrojas en el espectro cercano y patrones locales binarios para contrarrestar las variaciones de iluminación. El trabajo en [9] se basa en la constitución de la estructura formada por los vasos sanguíneos buscando una mayor independencia respecto a factores ambientales. En [10] se emplean métodos de Kernel KPCA y KFLD llevándolos a un dominio de transformación no lineal. En [11] emplean PCA en conjunto con un perceptrón multicapa. En [12] extraen características fisiológicas a partir de la estructura del tejido sanguíneo para obtener una huella térmica del rostro. En [13] se emplea un modelo de probabilidad bayesiano para reducir los efectos de las variaciones internas del sujeto. En [14], [15] y [16] los autores emplearon la transformada Curvelet y compararon con PCA. En [17] los autores buscan mejorar la robustez de los patrones térmicos del rostro para fines biométricos. En [18] se estudia las ventajas y desventajas comparativas de métodos sub-espaciales como PCA, LDA y FastICA y realizan una fusión entre ellos obteniendo mejores resultados. En [19] emplean LBP (Local Binary Pattern) y LTP (Local Ternary

Pattern) como descriptores de textura del **rostro** infrarrojo para el sistema de reconocimiento. En [20] se emplea la transformada Wavelet para la obtención de las características y una Máquina de Vectores de Soporte como clasificador sobre las imágenes térmicas.

Dos de las técnicas más ampliamente utilizadas en reconocimiento de rostros con imágenes IR son: Eigenfaces basada en PCA (Principal Component Analysis) y Fisherfaces basada en LDA (Linear Discriminant Analysis). Por medio de estas técnicas, las imágenes originales son proyectadas a un sub espacio, donde se genera un conjunto de características de dimensión reducida. Desde el punto de vista de la clasificación, no todos los ejes del espacio de características suministran la misma información. En este artículo se presenta un método basado en algoritmos genéticos donde se pondera la contribución de cada eje en la tarea de clasificación, buscando optimizar el poder discriminante del espacio de características generado.

Si bien es cierto, que las imágenes IR ofrecen ventajas respecto a las de espectro visible en cuanto a variación de iluminación se refiere, existen otros factores como la temperatura ambiente y la humedad relativa que pueden afectar en mayor medida el desempeño del sistema de reconocimiento al emplear imágenes IR. Con el fin de obtener mayor información sobre la incidencia en el desempeño del sistema para algunos factores que pueden presentarse, en este trabajo se realiza una subdivisión del banco de datos de imágenes de validación en ocho categorías que tienen en cuenta entre otros: los gestos de las caras, el empleo de gafas, la inclinación de la cabeza y el flujo de aire sobre el **rostro**.

En resumen, el trabajo tiene como objetivo establecer las ventajas de aplicar técnicas de optimización para establecer esquemas de selección y ponderación de los ejes del subespacio de características generado por PCA y LDA que impliquen mejoras en la tarea de clasificación respecto a los métodos convencionales de selección, determinando a su vez el impacto de los principales fenómenos que pueden afectar en mayor medida la tarea de reconocimiento al emplear imágenes IR.

En los apartados 2 y 3 se presentan los fundamentos básicos para la implementación de las técnicas PCA y LDA respectivamente. En el apartado 4 se describe la estrategia empleada de ajuste por ponderación de pesos por algoritmos genéticos. En el apartado 5 se presenta una descripción de las

imágenes que conforman el banco de datos usado para las pruebas en este trabajo. Los resultados obtenidos y comparaciones realizadas se indican en el apartado 6.

2 Algoritmo PCA

El algoritmo implementado se basa en el trabajo introducido por [21] que se ha convertido en una referencia para todos los nuevos métodos de reconocimiento de rostros. Igualmente los trabajos reportados en [5], [6] han sido utilizados como punto de partida en diversa investigaciones sobre reconocimiento de rostros en imágenes termográficas.

La técnica denominada Eigenfaces se basa en el Análisis de Componentes Principales (PCA por sus siglas en inglés), por tal motivo para mencionar la técnica se emplea el término Eigenfaces o PCA. La idea fundamental consiste en proyectar las imágenes de los rostros dentro de un subespacio de una dimensión más reducida, donde se busca eliminar la mayor cantidad de información redundante (correlacionada). Al considerar sólo aquellos vectores propios con sus respectivos valores propios de mayor valor, se obtiene un subespacio cuyos ejes corresponden a las direcciones donde se presenta mayor dispersión en el espacio original y que conforma el espacio de características. En la figura 1 se presentan los pasos a seguir para la implementación. Un mayor detalle puede encontrarse en [21].

3 Algoritmo LDA

Con el Análisis de Discriminantes Lineales (LDA), se busca maximizar la separación en la proyección del grupo conformado por las imágenes diferentes de los mismos sujetos y el grupo conformado por las imágenes de diferentes sujetos. Aunque en la literatura se encuentran múltiples algoritmos, en este trabajo se parte de los resultados de [22] y [23]. En esta técnica se considera las imágenes correspondientes a un mismo sujeto como una clase, de tal forma que se tendrán tantas clases como sujetos haya. Con estas clases definidas, se procede a obtener dos matrices de dispersión diferentes, la matriz de dispersión interna de las clases S_W y la matriz de dispersión entre clases S_B , que se calculan según las ecuaciones (1) y (2) respectivamente.

1. Expresar cada imagen como vector columna I_k
2. Calcular el vector promedio $\mu = \frac{1}{M} \sum_{k=1}^M I_k$
3. Restar a cada imagen el promedio $x_k = I_k - \mu$
4. Obtener la matriz $A = [x_1 x_2 \dots x_M]$
5. Calcular los vectores y valores propios de la matriz $A^T A$
6. Seleccionar los n vectores con los valores propios asociados de mayor valor.
7. Obtener los vectores propios de la matriz de covarianza por medio de la relación $U_i = AV_i$. Donde V_i son los vectores obtenidos en el paso 6.
8. Normalizar los vectores obtenidos de tal forma que $\|U_i\| = 1$
9. Proyectar en el sub-espacio todos los vectores columnas x_k correspondientes a las imágenes de referencia para obtener los respectivos pesos en cada dirección $w_i = U_i^T x_k$

Figura 1: Procedimiento de implementación de PCA

$$S_w = \sum_{i=1}^P \sum_{k=1}^{N_i} (I_k^i - \mu_i)(I_k^i - \mu_i)^T \quad (1)$$

$$S_B = \sum_{i=1}^P (\mu_i - \mu)(\mu_i - \mu)^T \quad (2)$$

Donde,

I_k^i Vector correspondiente a la imagen k del sujeto i

μ_i Vector promedio de las imágenes del sujeto i

μ Vector promedio del total de las imágenes

P Número de sujetos de entrenamiento

N_i Número de imágenes de entrenamiento del sujeto i

El criterio de Fisher establece que para lograr la mayor separabilidad de las clases se debe maximizar la razón de los determinantes de las matrices de dispersión proyectadas, donde el argumento de maximización se indica en la ecuación (3).

$$\arg \max_A = \frac{AS_B A^T}{AS_W A^T} \quad (3)$$

Dado que el número de datos de entrenamiento es menor que la dimensión de los vectores, la matriz S_W es singular lo que impide resolver el problema directamente. En la figura 2 se presentan los pasos a seguir para solucionar el problema. Un mayor detalle puede encontrarse en [24].

1. Expresar cada imagen como vector columna I_k
2. Calcular el vector promedio $\mu_i = \frac{1}{N_i} \sum_{k \in C_i} I_k$
3. Calcular el promedio del total de las imagenes de referencia $\mu = \frac{1}{P} \sum_{k=1}^P \mu_k$
4. Obtener la matriz $\Phi_b = [(\mu_1 - \mu)(\mu_2 - \mu) \dots (\mu_M - \mu)]$
5. Calcular los vectores propios de S_B a partir de $\Phi_b^T \Phi_b$
6. Seleccionar los vectores con los m valores propios mas altos.
7. Conformar la matriz Y con los vectores propios seleccionados normalizados.
8. Obtener la matriz $Z = Y D_b^{-1/2}$
9. Obtener la matriz $\Phi_w = [(I_1^i - \mu_1) \dots (I_r^j - \mu_j) \dots (I_{N_p}^p - \mu_p)]$
10. Calcular los vectores propios de la matriz $(\Phi_w^T Z)^T (\Phi_w^T Z)$
11. Obtener la matriz U con los vectores seleccionados
12. Calcular la matriz $A = U^T Z^T$
13. Obtener la matriz de transformacion total $T = D_w^{-1/2} A$
14. Obtener los pesos $W_k = T X_k$ proyectando sobre el espacio de caracteristicas la resta de los vectores columnas I_k de las imagenes de referencia con el promedio μ .

Figura 2: Procedimiento de implementación de LDA

4 Algoritmo Genético para Asignación de Ponderaciones

Los algoritmos genéticos (AG) son métodos adaptativos especialmente útiles, cuando se hace inabordable explorar todas las posibles combinaciones de un

conjunto de datos en busca de la mejor de ellas. Aunque el algoritmo genético no garantiza encontrar la solución óptima, generalmente ofrece una solución o conjunto de soluciones con características deseables y que cumplen con los requerimientos del problema [25]. En este trabajo se emplea un algoritmo genético para optimizar el poder discriminante de los vectores de características obtenidos con PCA y LDA.

Cada componente del vector de características obtenido por PCA o LDA, corresponde a la proyección de la imagen original sobre el respectivo vector eje que conforma el subespacio. El método convencional de selección, consiste en incluir sólo los vectores con los correspondientes valores propios de mayor valor, dado que estos corresponden a las direcciones donde se presenta mayor dispersión de los datos.

Aunque los vectores eje con los correspondientes valores propios de más alto valor concentran la mayor cantidad de información, no necesariamente quiere decir que estos sean los más útiles en cuanto a la tarea de clasificación. Establecer sin embargo, cuales vectores ejes tiene mayor poder discriminante no es tarea sencilla, por esta razón en este trabajo se emplea un Algoritmo Genético para darle mayor peso a los vectores ejes que más contribuyen a una correcta clasificación.

Sean

$$[U_{1pca} U_{2pca} U_{Ppca}] \text{ y } [U_{1lda} U_{2lda} U_{Qlda}]$$

Los P y Q vectores que conforman los ejes del subespacio obtenido por PCA y LDA respectivamente.

Los vectores de características obtenidos al proyectar el vector imagen I_k en el subespacio de características estarán dados por las ecuaciones (4),(5) y (6).

$$x_k = I_k - \mu \quad (4)$$

$$V_{pca} = [x_k U_{1pca} x_k U_{2pca} \cdots x_k U_{Ppca}] \quad (5)$$

$$V_{lda} = [x_k U_{1lda} \ x_k U_{2lda} \ \cdots \ x_k U_{Qlda}] \quad (6)$$

Se introducen las ecuaciones (7) y (8) correspondientes a los vectores de pesos con los factores de ponderación α_i y β_i

$$W_{pca} = [\alpha_1 \ \alpha_2 \ \cdots \ \alpha_P] \quad (7)$$

$$W_{lda} = [\beta_1 \ \beta_2 \ \cdots \ \beta_Q] \quad (8)$$

Los nuevos vectores de características estarán dados por las ecuaciones (9) y (10).

$$W'_{pca} = W_{pca} V_{pca} \quad (9)$$

$$W'_{lda} = W_{lda} V_{lda} \quad (10)$$

Para la implementación del Algoritmo Genético se tuvieron en cuenta los siguientes elementos:

Función de Mérito: Se seleccionó como función objetivo la reducción en el error de clasificación empleando la distancia angular como métrica. Para ello se asignó un conjunto de imágenes diferentes a las empleadas tanto para la generación de los espacios de características de PCA y LDA como a las utilizadas para su validación. Durante cada interacción del algoritmo genético se evaluó el porcentaje de acierto sobre este conjunto de imágenes buscando el cromosoma que minimice el error.

Cromosomas: Los genes o cromosomas que hacen parte de la población están conformados por los vectores de peso $[\alpha_1 \ \alpha_2 \ \cdots \ \alpha_P]$ y $[\beta_1 \ \beta_2 \ \cdots \ \beta_Q]$ para PCA y LDA respectivamente.

Operador de Selección: Se empleó la selección tipo ruleta estableciendo adicionalmente un elitismo de los 2 mejores individuos para hacer parte de la próxima generación.

Operador de cruce: Se empleó un operador tipo heurístico con probabilidad de 0,6.

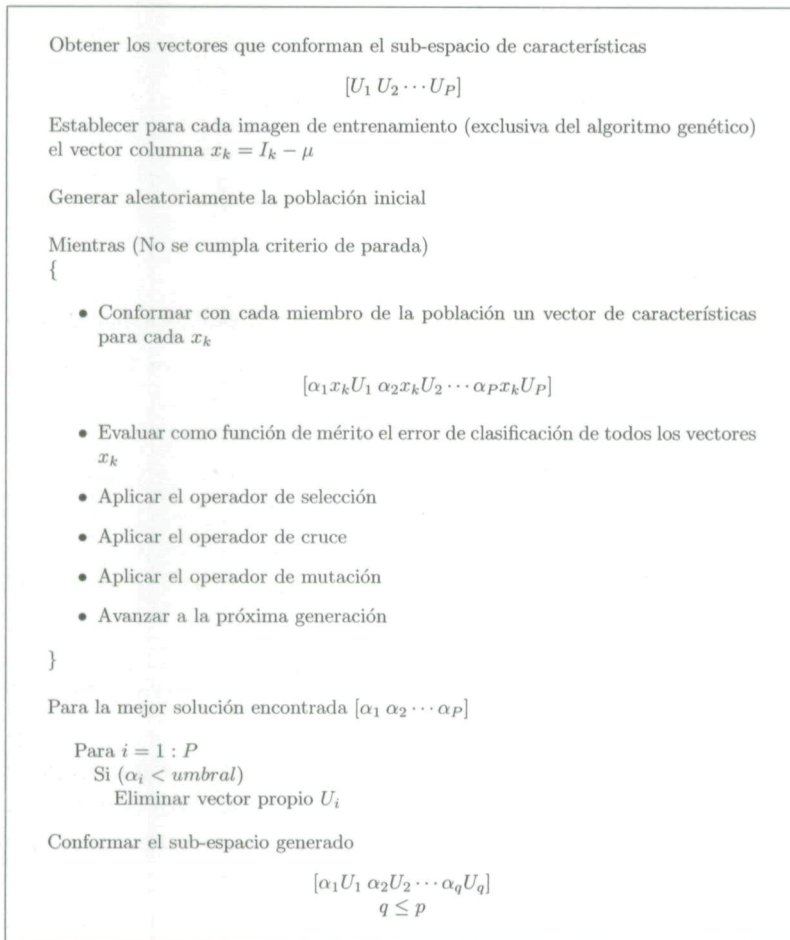


Figura 3: Procedimiento de ajuste con algoritmos genéticos

Operador de mutación: Se seleccionó un operador con distribución uniforme con probabilidad de 0,005.

Los resultados reportados se obtuvieron empleando una población de 100 individuos y 300 generaciones.

El algoritmo genético suministra como población final, el valor de los pesos de cada vector eje (α_i o β_i) de tal forma que un valor elevado de α_i o β_i indica un mayor aporte en la clasificación para el vector eje i . Los vectores eje con pesos muy pequeños son eliminados con el fin de reducir la dimensionalidad del espacio. En la figura 3 se presenta un esquema del algoritmo empleado para el ajuste ponderado de los pesos.

5 Descripción del banco de datos

Las imágenes infrarrojas que hacen parte del banco de datos fueron obtenidas con la cámara Termo Vision A20M de FLIR SYSTEM que presenta una sensibilidad térmica de 0.12°C , con un rango espectral de 7.5 a 13 μm , resolución de 320×240 con 12 bits en escala de grises.

Aunque existen bases de imágenes de rostros IR con libre acceso, éstas presentan pocas variantes respecto a diferentes fenómenos que pueden afectar el espectro infrarrojo. Al ser uno de los principales objetivos de este trabajo determinar cuáles factores pueden producir mayor efecto sobre la tasa de reconocimiento fue necesario crear una base de imágenes propias como se describe a continuación:

En una primera sección se hizo el registro de 100 personas de ambos sexos, variados tonos de piel y diferentes rangos de edades. Un aspecto a destacar respecto a la mayoría de trabajos reportados en la literatura consultada, es el haber empleado imágenes de validación y entrenamiento obtenidas en periodos de tiempo diferentes. Mientras que en la mayor parte de los trabajos, las imágenes empleadas tanto durante el entrenamiento como en la validación fueron obtenidas durante una misma sección, en este trabajo con el fin de obtener resultados más cercanos a la realidad las imágenes de validación fueron adquiridas cuatro meses después de las de entrenamiento y se dividieron en 8 categorías: Variación por gestos (*Gestos*), variación por la distancia a la cámara (*Distancia*), variación por aire caliente sobre el rostro (*Calor*), variación por aire frío sobre el rostro (*Frío*), ambiente con baja iluminación (*Oscuro*), variación por rotación horizontal (*Horizontal*), variación por ro-

tación vertical (*Vertical*) y variación por empleo de gafas (*Gafas*). En total se emplearon 2233 imágenes de validación. En la figura 4 se muestran algunos ejemplos en el orden que acaba de indicarse.

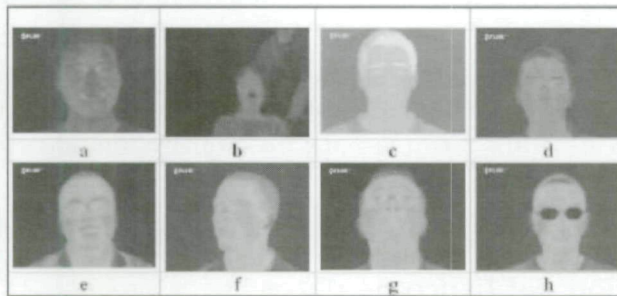



Figura 4: Imágenes infrarrojas de validación. (a) Gestos. (b) Distancia. (c) Calor. (d) Frío. (e) Oscuro. (f) Horizontal. (g) Vertical. (h) Gafas

6 Resultados Experimentales


La figura 5 indica el comportamiento del porcentaje de acierto respecto al número de vectores propios seleccionados para conformar el espacio de características. Se observa como después de alrededor de 150 vectores para PCA y 65 para LDA, el nivel de acierto empieza a converger. De esta forma, se obtiene una reducción del espacio original con vectores de características de $[14832 \times 1]$ correspondiente al tamaño de las imágenes a $[150 \times 1]$ para PCA y $[65 \times 1]$ para LDA, que corresponde al 1% y 0.4% del tamaño original respectivamente.

Para la estrategia propuesta con algoritmos genéticos, la reducción de características se establece mediante la inclusión de un valor umbral por debajo del cual, los vectores a conformar el espacio de características son descartados. La figura 6 indica la evolución del porcentaje de acierto al variar el valor del umbral. Considerando los valores del umbral para los cuales la gráfica empieza a converger, se obtuvo una reducción del 2.2% y 0.42% del tamaño original para PCA y LDA respectivamente.

Las gráficas de la figura 7 muestran los pesos establecidos por el algoritmo genético. Se observa que no existe una relación directa con el valor de estos pesos y la magnitud de los valores propios de los vectores que cada peso




(a)




(b)

Figura 5: Porcentaje de acierto Vs. Dimensión del sub-espacio .
(a)PCA (b)LDA



(a)



(b)

Figura 6: Porcentaje de acierto Vs. Valor de umbral.
(a)PCA (b)LDA

representa, lo cual indica, que no necesariamente las direcciones de mayor dispersión de los datos ofrecen las mejores propiedades de clasificación e incluso

en algunos casos puede afectarla.




Figura 7: Distribución de pesos. (a) PCA (b) LDA

En la tabla 1, se indican los porcentajes de acierto obtenidos en cada categoría al evaluar las diferentes técnicas de reconocimiento. En la figura 8 se presenta una gráfica comparativa de estos porcentajes para cada una de las 8 categorías. Se observa claramente un mayor desempeño tanto para PCA como para LDA, después del ajuste realizado con los pesos resultantes de la aplicación del algoritmo genético.

Las mayores diferencias se obtienen para las categorías Gestos, Distancia, Calor y Frío. Para estas categorías PCA con ajuste supera a PCA convencional en **11.7**, **12.85**, **13.09** y **15.87** puntos porcentuales respectivamente. Por su parte LDA con ajuste supera a LDA sin ajuste en **4.69**, **11.22**, **6.43** y **3.8** puntos porcentuales respectivamente. La categoría gafas fue la única donde se nota un decremento en el nivel de acierto al introducir el algoritmo genético.

Para las imágenes con rotación horizontal ninguna de las técnicas suministró un porcentaje de acierto alto. Una de las razones de este bajo desempeño, radica en el hecho de haber decidido no incluir imágenes con rotación horizontal dentro de la etapa de entrenamiento, con el fin de medir de una forma más directa su impacto. Sin lugar a dudas, el desempeño para esta cate-

CATEGORIA	PCA		AJUSTE PCA		LDA		AJUSTE LDA	
	Acierto	FP	Acierto	FP	Acierto	FP	Acierto	FP
Gestos	74.10	9.05	85.80	7.18	85.95	7.64	90.94	6.86
Distancia	49.54	19.04	62.39	18.58	67.68	20.87	78.90	18.12
Calor	47.62	23.80	60.71	19.52	56.43	29.29	62.86	20.48
Frío	69.65	7.93	85.52	5.88	84.82	11.03	88.62	6.21
Oscuro	98.33	0.00	98.33	0.00	100.00	0.00	100.00	0.00
Horizontal	34.71	27.87	33.19	34.07	38.94	33.19	38.94	49.12
Vertical	70.83	11.67	71.67	16.67	78.33	11.67	80.83	15.83
Gafas	52.63	21.05	39.47	36.84	47.37	34.21	42.11	26.32
Promedio	62.18	15.05	67.13	17.29	69.94	18.48	72.86	17.86
Desv. Std	19.98	9.39	22.87	13.10	17.72	12.80	21.20	15.28

Tabla 1: Porcentajes Globales de Acierto por Categoría




Figura 8: Porcentaje de acierto con y sin ajuste. (a) PCA (b) LDA

goría podría incrementarse considerablemente al incluir este tipo de imágenes durante dicha etapa. Cabe mencionar además, que dentro de las pruebas realizadas, este alto nivel de error se presentó para las imágenes con ángulos de rotación mayores a 15° , que podría considerarse una restricción para el sistema.

Los falsos positivos corresponden a aquellos casos donde la imagen de un determinado sujeto es asignada a un individuo equivocado en lugar de declararse como no reconocida. Aunque la función mérito del algoritmo genético no considera directamente los falsos positivos como factor de premio o castigo, se observa para el caso de PCA que el aumento en el promedio del error por falsos positivos se presentó solo en tres de las ocho categorías, mientras que en cuatro de ellas el error disminuyó y en una permaneció igual. Para el caso de LDA también se obtuvo una mejora en cuatro categorías y el error promedio disminuyó levemente.

7 Conclusiones

Las técnicas PCA y LDA operan en el dominio espacial, permitiendo representar las imágenes en un subespacio de dimensión reducida, generando vectores de características con longitudes en el orden del 1% del tamaño original. Al proyectar la imagen sobre los vectores que conforman los ejes de este subespacio, cada una de estas proyecciones puede aportar o dificultar la tarea de clasificación. Los resultados presentados en este artículo muestran que la forma convencional de selección de los ejes que conforman el subespacio no es óptima, siendo factible su ajuste. En este trabajo se ha introducido un algoritmo genético que busca acentuar las dimensiones del espacio de características que favorecen la tarea de clasificación y eliminar o reducir el efecto de aquellos que la afectan.

Para las técnicas empleadas, los factores de menor impacto sobre la tasa de reconocimiento son los causados por variación en las condiciones de iluminación, variación por aire frío sobre el rostro y las variaciones por gestos; mientras que los que producen mayor dificultad son los causados por variaciones por rotación del rostro en sentido horizontal, empleo de gafas y las variaciones por aire caliente sobre el rostro.

Si bien el empleo de algoritmos genéticos requiere un proceso de entrenamiento con un esfuerzo computacional elevado, este entrenamiento sólo se efectúa una vez, razón por la cual después de realizado el ajuste, el efecto sobre el costo computacional respecto al sistema sin ajustar es mínimo. Por otra parte, con la sintonización realizada con el algoritmo genético se alcanzaron resultados de clasificación significativamente superiores respecto a las

técnicas convencionales implementadas en el estudio. Las mayores diferencias se obtienen en PCA para las categorías Gestos, Distancia, Calor y Frío, donde con el ajuste se lograron mejoras en **11.7**, **12.85**, **13.09** y **15.87** puntos porcentuales respectivamente, con lo que se muestra la validez y ventajas del esquema propuesto, abriendo un panorama de optimización para este tipo de técnicas de extracción de características.

Cabe notar sin embargo, que en no todas las categorías se logró mejorar el desempeño. En el caso particular de la categoría *Gafas* se tiene una disminución. Además del hecho de que los materiales de los lentes no son transparentes al infrarrojo lo que dificulta la tarea de reconocimiento, otra posible razón para la reducción del desempeño, radica en la dificultad técnica de poder contar con el mismo número de imágenes para cada categoría. Mientras que para la categoría *Gestos* se tenía un importante número de imágenes, para otras categorías el número es mucho más limitado. En el caso particular de la categoría *Gafas*, se emplearon pocas imágenes (menor al 10% de las empleadas en *Gestos*) durante el entrenamiento del algoritmo genético de allí su pobre sintonía. Otro aspecto a tener en cuenta es el hecho de que si bien para más de la mitad de las categorías los errores por falsos positivos disminuyeron o permanecieron igual, en el caso de PCA el valor promedio de este error aumentó ligeramente.

Los dos principales aportes del presente trabajo se focalizan en el área de reconocimiento de rostros con imágenes infrarrojas: El primero es la introducción de una técnica de optimización para seleccionar los ejes del sub-espacio generado por PCA y LDA con mayor poder discriminante en la tarea de clasificación. Los resultados obtenidos abren un camino de exploración en la aplicación de nuevos esquemas de optimización que mejoren el ajuste tanto de las técnicas PCA y LDA como otras empleadas en el reconocimiento de rostros.

El segundo aporte lo constituye la generación de un banco de imágenes con 8 categorías, que permite medir el impacto en el desempeño de las distintas técnicas considerando los principales fenómenos que pueden afectar la calidad de las imágenes IR en ambientes más cercanos a la realidad. En los trabajos reportados en la literatura consultada se emplearon conjuntos de imágenes con pocas variantes y en los resultados se hace un análisis global sin analizar los diferentes fenómenos.

Referencias

- [1] J. Ross Beveridge, Geof H. Givens, P. Jonathon Phillips and Bruce A. Draper. *Factors that influence algorithm performance in the Face Recognition Grand Challenge*. Computer Vision and Image Understanding, ISSN 1077-3142, **113**(6), 750-762, June 2009. Referenciado en 113
- [2] Prokoski, F. *History, Current Status, and Future of Infrared Identification*. Proceedings of IEEE Workshop on Computer Vision Beyond the Visible Spectrum: Methods and Applications, ISBN 0-7695-0640-2, 5-14, (2000). Referenciado en 113
- [3] Lawrence B. Wolff, Diego A. Socolinsky, and Christopher K. Eveland. *Quantitative Measurement of Illumination Invariance for Face Recognition Using Thermal Infrared Imagery*. Proceedings of IEEE Workshop on Computer Vision Beyond the Visible Spectrum: Methods and Applications, ISBN 0-7695-0640-2, **4820**, 140-151 (2003). Referenciado en 113
- [4] G. Friedrich and Y. Yeshurun. *Seeing People in the Dark: Face Recognition in Infrared Images*. Proceedings of Second International Workshop on Biologically Motivated Computer Vision, ISBN:3-540-00174-3, **Vol. 2525**, 348-359 (2002). Referenciado en 113
- [5] Xin Chen, Patrick J. Flynn and Kevin W. Bowyer. *IR and visible light face recognition*. Computer Vision and Image Understanding, ISSN: 1077-3142, **9**(3), (2005). Referenciado en 113, 115
- [6] Lawrence B. Wolff, Diego A. Socolinsky. *Thermal Face Recognition in an Operational Scenario*. Computer Vision and Pattern Recognition. CVPR 2004, ISSN: 1063-6919, Vol. 2 ,1012-1019 (2004). Referenciado en 113, 115
- [7] Diego A. Socolinsky and Selinger A.; . *Thermal Face Recognition Over Time*. Proceedings of the 17th International Conference on Pattern Recognition, ISSN: 1051-4651, **Vol. 4**, 187-194 (2004). Referenciado en 113
- [8] Li S.Z, RuFeng Chu, ShengCai Liao and Lun Zhang. *Illumination Invariant Face Recognition Using Near-Infrared Images*. Transactions on Pattern Analysis and Machine Intelligence, ISSN 0162-8828, **29**(4), 627-639 (2007). Referenciado en 113
- [9] P. Buddharaju, I.T. Pavlidis, P. Tsiamyrtzis and M. Bazakos. *Physiology-based face recognition in the thermal infrared spectrum*. IEEE Transactions on Pattern Analysis and Machine Intelligence, ISSN 0162-8828, **29**(4), 613-626 (2007). Referenciado en 113

- [10] Shahbe M. Desa and Subhas Hati. *IR and Visible Face Recognition using Fusion of Kernel Based Features*. 19th International Conference on Pattern Recognition. ICPR 2008, ISSN 1051-4651, pp. 1-4 (2008). Referenciado en 113
- [11] Mrinal Kanti Bhowmik, Debotosh Bhattacharjee, Mita Nasipuri, Dipak Kumar Basu and Mahantapas Kundu. *Classification of Polar-Thermal Eigenfaces using Multilayer Perceptron for Human Face Recognition*. Third international Conference on Industrial and Information Systems, 2008. ICIIS 2008, ISBN: 978-1-4244-2806-9, pp. 1-6 (2008). Referenciado en 113
- [12] Moulay A. Akhloufi, and Abdelhakim Bendada. *Infrared face recognition using distance transforms*. International Conference on Image and Vision Computing, Paris, France, Proceedings of World Academy of Science, Engineering and Technology, ISSN 1307-6884, Vol. 30, pp. 160-163 (2008). Referenciado en 113
- [13] Moulay A. Akhloufi and Abdelhakim Bendada. *Probabilistic Bayesian framework for infrared face recognition*. World Academy of Science, Engineering and Technology, ISSN 2010-376X, (2009). Referenciado en 113
- [14] Zhihua Xie, Guodong Liu, Shiqian Wu and Yu Lu. *A Fast Infrared Face Recognition System Using Curvelet Transformation*. Second International Symposium on Electronic Commerce and Security, 2009. ISECS '09, ISBN: 978-0-7695-3643-9, Vol. 2, 145-149 (2009). Referenciado en 113
- [15] Xie, Shiqian Wu, Guodong Liu and Zhijun Fang. *Infrared Face Recognition Based on Radiant Energy and Curvelet Transformation*. Fifth International Conference on Information Assurance and Security 2009, ISBN: 978-0-7695-3744-3, (2009). Referenciado en 113
- [16] Xie, Shiqian Wu, Guodong Liu, Zhijun Fang. *Infrared face recognition method based on blood perfusion image and Curvelet transformation*. Proceedings of the 2009 International Conference on Wavelet Analysis and Pattern Recognition, ICWAPR 2009, ISBN: 978-1-4244-3728-3, pp. 360-364 (2009). Referenciado en 113
- [17] Siu-Yeung Cho, Lingyu Wang and Wen Jin Ong. *Thermal Imprint Feature Analysis for Face Recognition*. IEEE International Symposium on Industrial Electronics (ISIE 2009), ISBN: 978-1-4244-4347-5, pp. 1875-1880 (2009). Referenciado en 113
- [18] Wei Ge, Dawei Wang, and Yuqi Cheng. *Infrared face recognition using linear subspace analysis*. Proceedings of the SPIE on Pattern Recognition and Computer Vision, ISBN 978-0-8194-7807-8, Vol. 7496, pp. 74961Z-74961Z-8 (2009). Referenciado en 113

- [19] Moulay A. Akhloufi and Abdelhakim Bendada. *Infrared face recognition using texture descriptors*. Proc. SPIE, Vol. 7661, 766109, ISBN: 9780819481252, (2010). Referenciado en 113
- [20] Zhaojun Xue, Dong Ming, Wei Song, Baikun Wan and Shijiu Jin. *Infrared gait recognition based on wavelet transform and support vector machine*. Pattern Recognition, ISSN: 0031-3203, **43**(8), 2904–2910 (2010). Referenciado en 114
- [21] Matthew Turk and Alex Pentland. *Eigenfaces for Recognition*. Journal of Cognitive Neuroscience Winter 1991, ISSN 0898-929X, **Vol. 3**, 71–86 (1991). Referenciado en 115
- [22] Juwei Lu, Plataniotis K.N and Venetsanopoulos A.N. *Face recognition using LDA-based algorithms*. IEEE Transactions on Neural Networks, ISSN: 1045-9227, **14**(1), 195–200 (2001). Referenciado en 115
- [23] M. Brand. *Fast low-rank modifications of the thin singular value decomposition*. Algebra and Its Applications, ISSN 0024-3795, **Vol. 415**, 20–30 (2006). Referenciado en 115
- [24] Martínez T, D. *Estudio Comparativo entre Diferentes Técnicas de Extracción de Características Aplicadas al Reconocimiento de Rostros Empleando Imágenes Infrarrojas*. Trabajo de grado de Maestría presentado a la Universidad del Valle, (2007). Referenciado en 117
- [25] De La Cruz C, Patino H.D, and Carelli R. *New Evolutionary Algorithm based on the Mathematical Modeling of the Evolution of a Species*. IEEE Latin America Transactions, ISBN: 0-7803-9487-9, **3**(4), 310–316 (2005). Referenciado en 118

Copyright of Ingeniería y Ciencia is the property of Universidad EAFIT 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.