



TÉCNICAS DE PROCESAMIENTO DIGITAL DE IMÁGENES APLICADOS AL RECONOCIMIENTO AUTOMÁTICO DE ROSTROS

DIGITAL PROCESSING TECHNIQUES OF IMAGES APPLIED TO AUTOMATIC FACE RECOGNITION

Renzo Apaza Cutipa¹, Gina Fiorella Charaja Sánchez¹, Julio Cesar Laura Huanca¹.

¹Universidad Nacional del Altiplano, Escuela de Posgrado, Av. Floran N° 1153, Ciudad Universitaria, Puno Perú,
ac_renzo@hotmail.com

RESUMEN

En el presente documento se expone una revisión de los métodos aplicados al problema de reconocimiento automático de rostros, se revisan los modelos holísticos, los basados en características locales y los de métodos híbridos. Dentro de los métodos holísticos se revisan el Análisis de componentes Principales PCA y el Análisis Discriminatorio Lineal LDA. Dentro de los métodos basados en características locales se revisan los basados en las características de Gabor y Dentro de los métodos híbridos se revisa una propuesta que combina el PCA y las características de Gabor. Finalmente se presentan y explican las ventajas y desventajas de cada método así como los resultados publicados en los 4 artículos revisados objeto del presente.

Palabras clave: Reconocimiento automático de rostros, métodos holísticos, métodos basados en características locales, métodos híbridos,

ABSTRACT

This paper presents a review of the methods applied to the problem of automatic face recognition, we review the holistic models, those based on local features and those of hybrid methods. Within the holistic methods we review the Principal Components Analysis PCA and the Linear Discriminatory Analysis LDA. Within the methods based on local characteristics are reviewed those based on the characteristics of Gabor and Within the hybrid methods is revised a proposal that combines the PCA and the characteristics of Gabor. Finally, the advantages and disadvantages of each method as well as the results published in the 4 revised articles object of the present are presented and explained.

Keyword: Automatic face recognition, holistic methods, local feature based methods, hybrid methods.

*Autor para Correspondencia: ac_renzo@hotmail.com





INTRODUCCIÓN

El reconocimiento de rostros tiene muchas ventajas sobre otros métodos biométricos tales como reconocimiento de huella digital y de iris; entre estas que es natural y no intrusiva además del hecho que el reconocimiento de rostros se puede realizar a una distancia y forma prudente. También debemos indicar que entre los seis atributos considerados por (Heitmeyer, 2000), las características faciales obtuvieron la más alta compatibilidad en una máquina lectora de documentos de viaje. Un sistema de reconocimiento de rostros generalmente consiste de cuatro módulos: localización del rostro, normalización, extracción de características y emparejamiento o matching (Jain y Li, 2011).

Así desde los primeros trabajos realizados por (Kanade, 1973) que desarrollo un sistema automático de rostros, (Kirby y Sirovich, 1990) y (Sirovich y Kirby, 1987) sobre una representación de rostros de baja dimensionalidad basada en la utilización de la transformada Karhunen-Loeve (o Análisis de Componentes Principales) no fue sino hasta el trabajo de (Turk y Pentland, 1991) sobre Eigenface, que la investigación de reconocimiento de rostros cobro relevancia. Otras investigaciones que marcaron un hito importante fueron: el método de Fisherface (Belhumeur, Hespanha, y Kriegman, 1997)(Etemad y Chellappa, 1996) que aplicaba el Análisis Discriminante Lineal LDA después de una etapa de PCA para lograr una mayor precisión, también se resalta el uso de filtros locales como los Jets de Gabor (Lades et al., 1993)(Wiskott, Fellous, Krüger, y Von der Malsburg, 1997) para brindar características faciales más efectivas y el diseño de un clasificador en cascada para el aprendizaje AdaBoost para el diseño de un detector facial en tiempo real.

Se tiene también los retos tecnológicos entre ellos que la detección de los rostros es no lineal y no convexo y mucho más para el reconocimiento de rostros. Los reportes de evaluación de reconocimiento de rostros, por ejemplo Face Recognition Technology (FERET) (Phillips *et al.*, 2000) indican que muchas de los resultados de los métodos del reconocimiento de rostros disminuye con cambios en la luz, postura y otros factores (Chellappa, Sirohey y Wilson, 1995; Valentin, Abdi, O'Toole, y Cottrell, 1994; Zhao y Rosenfeld, 2003).

La Tecnología en reconocimiento de rostros ha avanzado significativamente en situaciones controladas donde la luz, posición, accesorios para la cabeza, oclusiones de boca y ojos (Jain y Li, 2011). El reconocimiento automático de rostros puede igualar al reconocimiento de rostros realizado por los humanos especialmente cuando la base de datos contiene una gran cantidad de rostros. Sin embargo, el reconocimiento automático de rostros en tiempo real aún enfrenta muchos desafíos cuando las imágenes de rostros son adquiridas bajo entornos no controlados (Jain y Li, 2011).

En las siguientes secciones se revisan los trabajos representativos que enfrentan el reconocimiento de rostros en tiempo real realizados por: (Turk y Pentland, 1991) "Face Recognition Using EigenFace", (Etemad y Chellappa, 1996) "Face Recognition Using Discriminat Eigenvector", (Yang, Zhang, Frangi, y Yang, 2004) "Face Recognition by Elastic Bunch Graph Matching" y (Bellakhdhar *et al.* 1994) "Face recognition approach using Gabor Wavelets, PCA and SVM".

MATERIALES Y METODOS

Esta sección está dividida en cinco sub secciones donde se exponen cinco aproximaciones distintas al reconocimiento automático de rostros sus aspectos generales, métodos y algoritmos empleados en la tarea de reconocimiento.





Face Recognition Using Eigenface

En este trabajo (Turk y Pentland, 1991) presentan el PCA que es una técnica estadística. En términos de teoría de información, se trata de extraer la información relevante en una imagen que contiene un rostro, tratando de hacerla lo más eficientemente posible. Se desea encontrar los componentes principales de una distribución de rostros, o los vectores propios de la matriz de covarianza del conjunto de imágenes de rostros donde cada posición de la imagen contribuye más o menos a cada vector propio, así se puede ver un vector propio como una representación más reducida de un rostro denominado Eigenface. La idea de utilizar eigenface fue motivado por el trabajo de Sirovich y Kirby (Sirovich y Kirby, 1987) para representar imágenes de rostros eficientemente utilizando PCA.

Los pasos necesarios para el reconocimiento de rostros son:

- Adquirir imágenes de rostros para entrenamiento y calcular los eigenfaces, espacio de rostros.
- Ante una imagen nueva, calcular un conjunto de pesos basado en la imagen de entrada y los M eigenfaces mediante la proyección de la imagen de entrada sobre cada uno de los eigenfaces.
- Determinar si la imagen es un rostro, controlando si esta cercana al espacio de rostros.
- Si es un rostro clasificar como una persona conocida o desconocida.
- Opcionalmente si el mismo rostro conocido es visto muchas veces, calcular sus características e incorporarlo a los rostros conocidos.

A. Base de datos.

La base de datos de imágenes con las que trabajaron estuvo conformada por 2500 imágenes de rostros en condiciones ambientales controladas.

B. Cálculo de Eigenfaces.

Sea una imagen de una cara dada por una matriz $N \times N(N^2)$, así una imagen de 256×256 será un vector de dimensión 65536 o de forma equivalente, un punto en un espacio de 65536 dimensiones. Sea el conjunto de imágenes de caras $x_1, x_2, x_3, \dots, x_m$ (considerando vectores columna de dimensión d podemos contruir la matrix X de dimensiones $d \times m$). La media del conjunto (o la cara media) se define $\mu = \frac{1}{m} \sum_{i=1}^m x_i$. Cada cara difiere de la media por el vector $x_i - \mu$. Este conjunto de vectores grandes es sometido a PCA lo cual buscará un conjunto de m vectores ortonormales μ_k que describe la distribución de los datos.

Los vectores μ_k y los escalares k son los vectores y valores propios respectivamente de la matriz de covarianza:

$$S = \frac{1}{m} \sum_{i=1}^m (x_i - \mu)(x_i - \mu)^T = AA^T$$

Donde

A : es la matriz X normalizada (a cada x_i columna se le ha restado la media). La matriz S tiene una dimensión $d \times d (=N^2 \times N^2)$, lo que hace de extraer sus vectores y valores propios una tarea computacionalmente prohibitiva para imágenes de un tamaño normal.

Si el número de puntos en el espacio de imágenes es menor que la dimensión del espacio $m < N^2$, habrá como mucho $m-1$ vectores propios significativos. Puede resolverse el problema tomando apropiadamente combinaciones lineales de las imágenes. Si en lugar de calcular AA^T consideramos v_i los vectores propios de $A^T A$ (y λ_i sus valores propios) resultará que.

$$A^T A v_i = \lambda_i v_i$$

Premultiplicando a ambos lados por A , se tiene:

$$AA^T A v_i = \lambda_i A v_i$$

Donde $A v_i$ son los vectores propios de $S = AA^T$





Partiendo de este análisis, se construye la matriz $A^T A$ de dimensión $m \times m$ y se encuentran los m vectores propios.

C. Algoritmo de Entrenamiento

Entrada: imagen de entrenamiento

Resultado: características de imágenes, matriz de eigenvector, matriz de características.

Metodo:

- Aplicar técnicas de pre-procesamiento a las imágenes de entrenamiento.
 - Transformar las imágenes de entrenamiento en vectores columna agregando las imágenes en columnas consecutivamente.
 - Construir la matriz A de imágenes en vectores columna con una etiqueta L teniendo las correspondientes nombres de las imágenes columnas en A .
 - Obtener el vector columna para la media M de la matriz A .
 - Sustraer la media M de cada columna de A para obtener la media centrada en la matriz A .
 - Calcular la matriz de covarianza C de A como $C = AA^T$.
 - Obtener la matriz de eigenvectors E y eigenvalues vector V de C .
 - Reordenar el eigenvector columna en E como los correspondientes eigenvalues en V están ordenados en orden descendente.
 - Proyectar la matriz centrada A sobre E para obtener matriz de características $P = E^T A$.
- Fin del entrenamiento.

D. Algoritmo de reconocimiento

Entrada: imagen C a ser reconocida, número de dimensiones a ser consideradas m , matriz de características P , matriz de eigenvector E , vector media M , vector de etiquetas L .

Respuesta: Etiqueta de Clasificación de la imagen de entrada.

Metodo:

- Aplicar la técnica de preprocesamiento adecuada, sobre B .
- Transformar la imagen procesada B en un vector columna vector J colocando las columnas en la imagen consecutivamente.
- Sustraer el vector media M de la imagen Vector J , $J = J - M$.
- Proyectar el vector de la imagen J sobre la matriz eigen E para obtener el vector de características $Z = E^T J$.
- Calcular la distancia Euclideana d entre el vector de características Z y todos los vectores columna en la matriz de características en la matriz de características P considerando solo m elementos en el vector e identificando la columna que tiene la distancia mínima d .
- Obtener la etiqueta del vector L correspondiente a la columna identificada en P teniendo la mínima distancia a Z .
- Fin de reconocimiento.

Face Recognition Using Discriminant Eigenvector

La misma persona con la misma expresión facial y vista desde el mismo punto de vista puede aparecer dramáticamente diferente cuando las fuentes de luz iluminan la cara desde diferentes direcciones. Originalmente (Belhumeur *et al.*, 1997), el método de Fisherfaces explota dos observaciones:

- Todas las imágenes de una superficie de Lambert tomadas desde un punto de vista fijo pero con variaciones en la iluminación, se proyectan en un subespacio lineal 3d del espacio de la imagen.
- En la práctica por razones de sombra, reflejos y expresiones faciales, la anterior observación no se mantiene exactamente. En la práctica, ciertas regiones de la cara pueden tener variabilidad



de imagen a imagen que frecuentemente deriva significativamente del subespacio lineal y consecuentemente merma la fiabilidad del reconocimiento.

El método de Eigenface se basa también en la proyección lineal del espacio de las imágenes en un espacio de características de dimensión menor, ya que uno de los objetivos es encontrar una proyección lineal de las imágenes de las caras en un espacio menor de características insensible a las variaciones de la luz y la expresión facial. Sin embargo, al utilizar PCA para reducir la dimensión (ya que PCA busca maximizar la dispersión) se mantienen variaciones indeseadas debidas a cambios en la luz y en la expresión facial. De acuerdo con la literatura, (Belhumeur et al., 1997) en se insiste en que “las variaciones entre las imágenes de la misma cara debidas a la dirección del punto de vista y la luz son siempre más grandes que las variaciones en la identidad de la cara”. Mientras que las proyecciones por PCA son óptimas para reconstruir los datos desde bases de menor dimensión, no son óptimas para la discriminación.

Formulación

Como el conjunto de aprendizaje está etiquetado, tiene sentido utilizar dicha información para construir un método de reducción de dimensionalidad del espacio de características más confiable. En este sentido el análisis discriminante de Fisher intenta proyectar los datos de manera que su nueva dispersión sea óptima para clasificación. Mientras PCA busca los vectores que mejor describen los datos, LDA busca los vectores que proporcionan mejor discriminación entre clases después de la proyección.

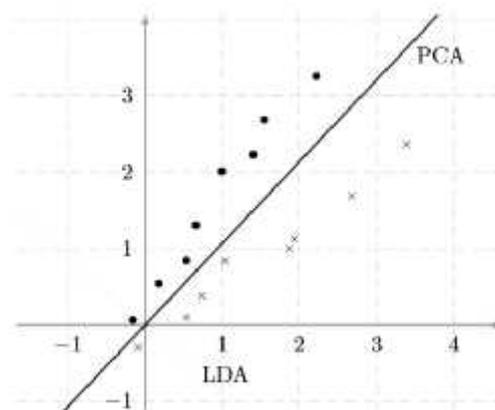


Figura 1. LDA, ejemplo en dos dimensiones

La Figura 1 muestra un ejemplo habitual en dos dimensiones para ilustrar los beneficios de LDA. En la recta que representa la dirección principal de los datos según PCA, los puntos se proyectarían mezclados y sería imposible discriminarlos. Mientras PCA describe la dispersión total, LDA describe mejor la dispersión entre clases.

En el problema de reconocimiento de caras, de acuerdo con (Belhumeur, Hespanha, y Kriegman, 1997), existe la dificultad de que la matriz de dispersión intraclase siempre es singular, es decir que no tiene inversa. Esto ocurre porque en general, el número de imágenes en el conjunto de aprendizaje siempre es menor que el número de píxeles en cada imagen.

Para salvar este obstáculo, originalmente, el método de las Fisherfaces propone una variación al LDA tradicional: Aunque existen otras estrategias, se puede evitar el problema proyectando el conjunto de imágenes en un espacio de dimensión más baja donde la resultante S_w es no singular.

Se utiliza PCA para reducir la dimensión del espacio de características y después se aplica el LDA estándar. Puede formularse estrictamente que la proyección óptima W_o de acuerdo con:

$$W_o^T = W_l^T W_p^T$$

Donde W_o se calcula partiendo de la matriz de dispersión total S_T y W_o se obtienen buscando una matriz w que maximice $J_{li}(w)$:

$$J_{li}(w) = \frac{w^T w_p^T S_B w_p}{w^T w_p^T S_W w_p} w$$

Base de datos.

La base de datos de imágenes con las que trabajaron estuvo conformada por 400 imágenes controladas de la base de datos ORL.

Algoritmo

- Construir la matriz de proyección con los vectores propios generalizados a S_B y S_W correspondientes a los valores propios no nulos.
- Para cada clase construir un vector de características proyectando con la matriz anterior. Se puede elegir uno por cada clase o promediarlos.
- Previamente, puede ser necesaria una reducción de dimensionalidad para poder tratar con S_B y S_W , dicha reducción debe hacerse a los vectores de características y a los de prueba para la clasificación.
- La clasificación se resuelve por la distancia a los vectores de características.

Face Recognition by Elastic Bunch Graph Matching

Se presenta un Sistema para reconocer rostros humanos de una imagen simple de una base de datos grande conteniendo una imagen por persona. La tarea es difícil debido a la variación de la imagen en terminos de posición. Tamaño, expresión y postura. El sistema reduce estas dificultades extrayendo descriptores de rostros concisos en la forma de grafos de imágenes. En estos puntos fiduciales sobre el rostro (ojos, quijada, etc) están descrito por conjuntos de componentes wavelets (Jets). El bunch graph, está construido de un pequeño conjunto de muestras de grafos de imagen. El reconocimiento está basado sobre una sencilla comparación de grafos de imágenes.

El Sistema.

- a) Preprocesando con Gabor Wavelets

La representación de características locales vistas: Son kernel de convolución motivadas biológicamente en la forma de olas planas restringidas por una función envolvente gaussiana el conjunto de los coeficientes de convolución para kernels de diferentes orientaciones y frecuencias en un pixel de imagen es llamado un jet. (Figura 2)

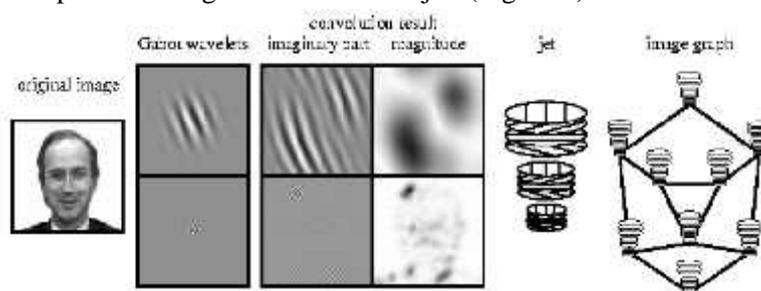


Figura 2. La representación gráfica de un rostro está basado en la transformada wavelets de Gabor, una convolución con un conjunto de kernels wavelets.

Se calculan 40 coeficientes (5 frecuencias x 8 orientaciones). Un jet J está definido como el conjunto $\{J_j\}$ de 40 coeficientes complejos obtenidos para un punto de la imagen puede ser escrito como $J_j = a_j \exp(i\phi_j)$



Con magnitud $a_j(\vec{x})$, que lentamente varía con posición, y fase $\phi_j(\vec{x})$, cual rota en una ratio aproximadamente determinado por la frecuencia espacial o hola del vector \vec{k}_j de los Kernels.

b) Comparación de Jets.

La función de similaridad está dada por:

$$S_a(J, J') = \frac{\sum_j a_j a'_j}{\sqrt{\sum_j a_j^2 \sum_j a'^2}}$$

A. Experimentos.

- a) Base de Datos. Se usaron dos bases de datos diferentes. La primera es la ARPA/ARL FERET. La segunda base de datos ha sido recolectada en el Instituto para Neural Computación.
- b) Resultados. Se utilizaron varios modelos y se probaron galerías con rostros en diferentes posiciones. Cada galería de imágenes contiene 250 rostros con solo una imagen por persona.

Face Recognition Approach Using Gabor Wavelets, PCA y SVM

En este paper se propone una mejora a la metodología de reconocimiento de rostros para aumentar el ratio de face recognition fusionando la fase de magnitud de la representación de Gabor del rostro como una nueva representación. La representación de Gabor fue largamente utilizada, particularmente en los algoritmos basados en un modelo general, La fase de Gabor no fue usada anteriormente, seguido de un algoritmo de reconocimiento basado en el modelo de Análisis de Componentes Principales, seguidamente Support Vector Machine es utilizado para un nuevo clasificador para reconocimiento de patrones. El rendimiento del algoritmo propuesto fue testeado sobre la base de datos FRGCv2 y ORL.

A. Support Vector Machine

Son máquinas de aprendizaje que clasifican la data transformando un conjunto de vectores de soporte. SVM provee un mecanismo genérico para reforzar la superficie del hiper plano.

B. Procesos para el reconocimiento de rostros según los autores.

La figura 3 resume los procesos propuestos para la tarea de reconocimiento de rostros.

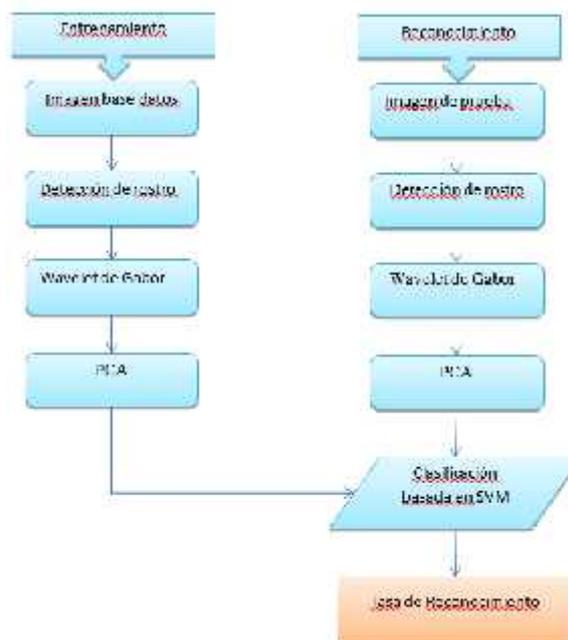


Figura 3: Procesos para el reconocimiento automático de rostros.





RESULTADOS Y CONCLUSIONES

Los resultados obtenidos en cada una de las aproximaciones a la resolución del problema del reconocimiento automático de rostros fueron los siguientes:

(Turk y Pentland, 1991) experimentó con una base de datos sobre las 2500 imágenes de rostro tomadas bajo condiciones controladas. Se digitalizó 16 sujetos en tres orientaciones de la cabeza, tres escalas de cabeza y tres condiciones de luz. Se construyó una pirámide gauseana para cada imagen, reduciendo de una imagen de 512 x 512 píxeles a 16 x 16 píxeles el sistema logró un 96% de correcta clasificación promediado sobre la variación de la luz, 85% correctos promediados sobre la variación de la orientación y 64% de promedio correcto sobre la variación del tamaño.

(Etemad y Chellappa, 1996) utilizaron una base de datos proporcionada por Olivetti Research Ltd. Conformada por 10 diferentes imágenes de 40 distintos sujetos. Todas las imágenes fueron tomadas de forma homogénea que incluyen vistas frontales y de lado derecho con muy pocos cambios en la configuración de iluminación. Para la extracción de características se calcula la matriz de separación y sus vectores y valores propios. Ordenando los vectores basados en la magnitud de sus valores propios seleccionando los 4 primeros. Todas las muestras de rostros fueron colocados en un vector y proyectados teniendo como resultados una 4-tupla como vector de características utilizadas posteriormente para la clasificación. Para la clasificación ante una nueva muestra se calcula la distancia ante los correspondientes 4-D características almacenadas en el entrenamiento y se selecciona al mejor emparejamiento. Basada en esa configuración lograron una 100% de confianza.

(Wiskott *et al.*, 1997) Se usaron dos bases de datos diferentes. La primera es la ARPA/ARL FERET. La segunda base de datos ha sido recolectada en el Instituto para Computación Neural. Se obtuvieron modelos y se probaron galerías con rostros en diferentes posiciones. Cada galería de imágenes contiene 250 rostros con solo una imagen por persona. Obteniéndose como mejor resultado entre 98% a 99% de resultados positivos.

(Bellakhdhar *et al.*, 1994) Este modelo consiste en combinar la magnitud y la fase de Gabor para extraer el vector de características, el algoritmo PCA para reconocimiento y SVM para clasificar rostros. El principio que se pueda construir un espacio de sub-vector reteniendo solo los mejores eigenvectores, mientras se retiene mucha información útil, hace al PCA un algoritmo efectivo y comúnmente usado para reducir dimensionalidad donde puede ser utilizado para otros algoritmos mejorando el resultado de la aplicación. Se utilizó la base de datos ORL y los resultados obtenidos del método implementado de la combinación de extracción de características con Wavelets de Gabor, la reducción de dimensionalidad, extracción de características con PCA y la clasificación basada en SVM supera a los métodos Gabor-PCA-SVM, PCA-SVM, y CWT-SVM; logrando el método propuesto una tasa de reconocimiento del 99.9%. Las características de la base de datos y los resultados obtenidos en las cinco aproximaciones tratadas en la presente revisión (Tabla 1).





Tabla 1. Resumen de los métodos utilizados para el reconocimiento de rostros y su porcentaje de acierto

Método	Base de Datos	Condiciones Ambientales	Mejores Resultados
Face Recognition Using Eigenface	2500 imágenes	controladas	96% de aciertos
Face Recognition Using Discriminant Eigenvector	400 imágenes (ORL)	controladas	100% de aciertos
Face Recognition by Elastic Bunch Graph Matching	500 imágenes (ARPA/ARL FERET)	controladas y no controladas	99% de aciertos
Face Recognition Approach Using Gabor Wavelets, PCA y SVM	FRGCv2 y ORL	controladas y no controladas	99,9% de aciertos

CONCLUSIONES

La amplia variedad de técnicas aplicadas al reconocimiento automático de rostros sobre imágenes digitales hace difícil la elección de los métodos a implementar en la industria del software el presente buscó exponer las principales técnicas de reconocimiento de rostros. Se evidenció que en todos los trabajos realizados se trató de reducir la variación del ruidos controlando principalmente la iluminación para hacerlas más robustas a pequeñas variaciones. Las primeras propuestas (Face Recognition Using Eigenface, Face Recognition using Discriminat Eigenvector y Two dimensional PCA) enfrentaron el problema de reconocimiento de rostros de forma holística tomando el 100% de las imágenes sin filtrar características locales. Las siguientes propuestas realizaron un refinamiento en la extracción de características mediante kernels aplicados principalmente a la iluminación (Two dimensional PCA). Las propuestas basadas en características locales (Face Recognition by Elastic Bunch Graph Matching) buscan extraer puntos representativos del rostro y construir vectores de características por cada punto a continuación ante una nueva imagen mediante métodos iterativos buscan ajustar los nuevos modelos obtenidos a los almacenados y realizar un cálculo de distancia estos modelos los hacen invariantes a oclusiones y gesticulación de los rostros pero no es robusta a la variación de la iluminación. Otro tipo de propuesta busca combinar las características locales mediante la localización de puntos característicos utilizando filtros, para posteriormente utilizar el PCA y reducir los ruidos producidos por la variación de la luz, finalmente la etapa de clasificación es realizada mediante SVM (Face Recognition Approach Using Gabor Wavelets, PCA, and SVM). La elección y construcción de las base de datos en los artículos tratados en el presente no fueron muy variadas ni probadas en situaciones reales por lo que no se puede concluir que tengan el mismo rendimiento sobre aplicaciones reales. Se puede evidenciar también que es necesaria garantizar la calidad de las características extraídas para la posterior clasificación de las imágenes de rostros para hacer factible una mejor clasificación. Con respecto a la etapa de clasificación se presentaron los basados en distancias y uno basado en SVM.

Finalmente, podemos decir que el reconocimiento de rostros sigue siendo un problema complejo, a pesar de la investigación activa actual. Hay muchas condiciones reales, difíciles de modelar y prever, que limitan el rendimiento de los sistemas actuales en términos de fiabilidad y tiempo.

LITERATURA CITADA

- Belhumeur, N., Hespanha, P. y Kriegman, J. (1997). Eigenfaces vs. fisherfaces: Recognition using class specific linear projection. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 19(7), 711–720.
<https://doi.org/10.1109/34.598228>
- Bellakhdhar, F., Loukil, K. y Abid, M. (n.d.). Face recognition approach using Gabor Wavelets, PCA and SVM. Retrieved from <https://ijcsi.org/papers/IJCSI-10-2-3-201-207.pdf>





- Chellappa, R., Sirohey, S. y Wilson, L. (1995). Human and Machine Recognition of Faces: A Survey. *Proceedings of the IEEE*, 83(5), 705–741. <https://doi.org/10.1109/5.381842>
- Etemad, K., y Chellappa, R. (1996). Face recognition using discriminant eigenvectors. In *1996 IEEE International Conference on Acoustics, Speech, and Signal Processing Conference Proceedings* (Vol. 4, pp. 2148–2151). <https://doi.org/10.1109/ICASSP.1996.545741>
- Heitmeyer, R. (2000). Biometric identification promises fast and secure processing of airline passengers. *ICAO Journal*, 55(9), 10–11.
- Jain, K. y Li, Z. (2011). *Handbook of face recognition*. Springer.
- Jonathon Phillips, P., Moon, H., Rizvi, A., y Rauss, J. (2000). The FERET evaluation methodology for face-recognition algorithms. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 22(10), 1090–1104. <https://doi.org/10.1109/34.879790>
- Kanade, T. (1973). Picture Processing System by Computer Complex and Recognition of Human Faces. *Doctoral Dissertation, Kyoto University*.
- Kirby, M. y Sirovich, L. (1990). Application of the Karhunen-Loeve procedure for the characterization of human faces. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 12(1), 103–108. <https://doi.org/10.1109/34.41390>
- Lades, M., Vorbrueggen, C., Buhmann, J., Lange, J., v.d Malsburg, C., Wuertz, P., y Konen, W. (1993). Distortion invariant object recognition in the dynamic link architecture. *IEEE Transactions on Computers*, 42(3), 300–311. <https://doi.org/10.1109/12.210173>
- Sirovich, L., y Kirby, M. (1987). Low-dimensional procedure for the characterization of human faces. *Journal of the Optical Society of America. A, Optics and Image Science*. <https://doi.org/10.1364/JOSAA.4.000519>
- Turk, M., y Pentland, A. (1991). Eigenfaces for Recognition. *Journal of Cognitive Neuroscience*. <https://doi.org/10.1162/jocn.1991.3.1.71>
- Valentin, D., Abdi, H., O'Toole, A. J., y Cottrell, G. W. (1994). Connectionist models of face processing: A survey. *Pattern Recognition*, 27(9), 1209–1230. [https://doi.org/10.1016/0031-3203\(94\)90006-X](https://doi.org/10.1016/0031-3203(94)90006-X)
- Wiskott, L., Fellous, M., Krüger, N., y Von der Malsburg, C. (1997). Face recognition by elastic bunch graph matching. In *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)* (Vol. 1296, pp. 456–463). https://doi.org/10.1007/3-540-63460-6_150
- Yang, J., Zhang, D., Frangi, F., y Yang, Y. (2004). Two-Dimensional PCA: A New Approach to Appearance-Based Face Representation and Recognition. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 26(1), 131–137. <https://doi.org/10.1109/TPAMI.2004.1261097>
- Zhao, W. y Rosenfeld, A. (2003). Face Recognition : A Literature Survey AND. *Computing*, 35(4), 399–458.

