

Identificación de rostros por técnica de puntos de interés SURF

Cesar Benavides Alvarez

Universidad Autónoma Metropolitana-Iztapalapa, Departamento de Ing. Eléctrica, San Rafael Atlixco 186,
Vicentina, C.P. 09340, México, D.F, Teléfono: 5804-4600
cesarba@xanum.uam.mx

Graciela Román Alonso

Universidad Autónoma Metropolitana-Iztapalapa, Departamento de Ing. Eléctrica, San Rafael Atlixco 186,
Vicentina, C.P. 09340, México, D.F, Teléfono: 5804-4600
grac@xanum.uam.mx

Juan Villegas Cortez

Universidad Autónoma Metropolitana-Azcapotzalco, Departamento de Electrónica, Av. San Pablo Xalpa
No.180, Col Reynosa Tamaulipas, C.P. 02200, México, D.F, Teléfono: 01 55 5318 9000
juanvc@azc.ua.mx

Carlos Avilés Cruz

Universidad Autónoma Metropolitana-Azcapotzalco, Departamento de Electrónica, Av. San Pablo Xalpa
No.180, Col Reynosa Tamaulipas, C.P. 02200, México, D.F, Teléfono: 01 55 5318 9000
caviles@azc.uam.mx

Resumen

En este trabajo se muestra un sistema de identificación de rostros a través de la técnica de extracción y análisis de los puntos de interés SURF (Speeded Up Robust Features). En esta metodología se hace uso de los puntos extraídos a partir de aplicar una partición al rostro en rejillas para obtener ventanas de la imagen, por medio de una ventana que se desliza a través de la imagen a analizar; el sistema obtiene los puntos de interés y el descriptor correspondiente a estos, para cada una de las ventanas

(rejillas) de la imagen y son guardados en la base de datos de entrenamiento. Este problema requiere un alto costo computacional ya que para extraer 225 rejillas de una imagen y generar los descriptores, de manera secuencial tiene un alto costo computacional, por lo que también se muestra la implementación con técnicas de programación en paralelo, logrando una reducción significativa del tiempo de cómputo para hacer factible su aplicación. El sistema se probó con cuatro bases de datos de rostros y se ha alcanzado un resultado fiable.

Palabra(s) Clave(s): Matching, reconocimiento de rostros, reconocimiento de patrones, puntos de interés SURF.

1. Introducción

Considerando al rostro humano como la primera impresión de identidad entre personas, su análisis para lograr una clasificación y posterior reconocimiento es importante, con base a desarrollar aplicaciones que automaticen las tareas de reconocimiento de personas en gran cantidad o bien de forma repetitiva a fin de tener un mínimo de error en la tarea. Al hablar de la biometría, ésta se encarga del reconocimiento de personas de manera automática por medio de sus características físicas (retina, iris, huellas dactilares, rostro, etc.). El rostro (también cara y faz) es la parte de la cabeza que se tiene al frente, en los humanos la parte anteroinferior, incluye cejas, ojos, nariz, mejilla, boca, labios, dientes, piel y barbilla; es así que se considera también a la clasificación y reconocimiento del rostro una parte de aplicación del reconocimiento de patrones [1]; por otra parte, también puede entrar en el reconocimiento de objetos, si vemos al rostro como un objeto tridimensional que puede tener forma, iluminación, etc. Los estudios de reconocimiento facial han determinado que, los ojos, la boca y la nariz se encuentran entre las partes más importantes para recordar rostros; esto quiere decir que presentan características distinguibles que no se pueden encontrar en otras partes como la frente o las mejillas [2].

Dentro de los diferentes tipos de métodos para la extracción de características del rostro, los más destacados son los basados en apariencia, basados en plantillas y en geometría. En los basados en geometría [3,4], las características son obtenidas a través de la información geométrica, posición, tamaño y distancias de los rasgos de la cara; en estos métodos es importante seleccionar de manera cuidadosa los umbrales de las características. Los basados en apariencia [5,6], utilizan la técnica de segmentación por color, usando el color de la piel para separar la región del rostro; cualquier región que no tenga el color de la piel puede ser aceptada como zona candidata para la ubicación de la boca o los ojos. La efectividad de esta técnica es limitada a causa de los diferentes tonos de piel de las personas. Los basados en plantillas [7,8,9], se realizan por medio de la correspondencia, con alguna plantilla de puntos de referencia que se realiza previamente, la mayor correspondencia produce la energía mínima. El costo computacional en estos métodos es muy elevado y presenta grandes dificultades cuando las características cambian de manera significativa, e.g. en el caso de las oclusiones, expresiones, ojos cerrados, boca abierta, etc.

El problema del reconocimiento de rostros se torna difícil por la gran variabilidad que existe: en la rotación de la cabeza, su inclinación, la iluminación, el ángulo, la expresión facial, envejecimiento, etc. [10,11,12]. Los aspectos a considerar aquí son: la variabilidad interclases, la similitud entre clases y las propiedades particulares de cada base de datos de imágenes.

Uno de los métodos más utilizados para el reconocimiento de rostros mencionado en la literatura, es el de "Eigenfaces" descrito en [13], el cual toma un enfoque holístico para el reconocimiento facial. Utiliza los componentes principales de una distribución de rostros, los vectores propios de la matriz de covarianza del conjunto de imágenes del rostro, donde cada imagen con N píxeles se considera un punto del espacio N -Dimensional.

En este trabajo presentamos la propuesta de usar una técnica utilizando los puntos de interés SURF [14], para la clasificación y reconocimiento de rostros, ya que ha probado

funcionar muy bien para el reconocimiento de objetos y se plantea una variante aplicada al reconocimiento de rostros así como el uso de computo paralelo, para la extracción de las características. Se aplicara la metodología a fotos de rostros en condiciones ideales (rostro de frente, sin oclusiones).

2. Método

Los descriptores de características locales describen un pixel de una imagen a través del contenido local en una vecindad. Estos deben ser distintivos y al mismo tiempo robustos a cambios de las condiciones de visualización. En este tiempo se han propuesto diversos descriptores y detectores dentro de la literatura, se ha encontrado que el rendimiento del descriptor depende a menudo del detector del punto de interés [15]. Recientemente se ha encontrado en un estudio comparativo en [16] que el rendimiento es superior en las características locales para el reconocimiento de rostros en ambientes sin restricciones. Los descriptores SURF se han utilizado en combinación con una maquina de soporte vectorial (SVM) únicamente para los componentes del rostro [17]. Sin embargo existen pocos análisis detallados del uso de SURF aplicado al reconocimiento facial hasta el momento.

Los factores principales que se deben tener en consideración en la detección de rostros son: *(i)* iluminación, *(ii)* orientación, *(iii)* escala y *(iv)* textura. El análisis automatizado del contenido de una imagen se refiere a la detección y estudio de su contenido e.g. colores, formas, texturas o cualquier otra información que pueda derivarse de la propia imagen. Específicamente para la detección de rostros la metodología tradicional marca 4 etapas: *(i)* detección de la cara, *(ii)* alineación de la cara, *(iii)* extracción de las características y *(iv)* reconocimiento. A continuación tenemos las etapas secuenciales a partir cada una de las imágenes a analizar ver Fig. 1.

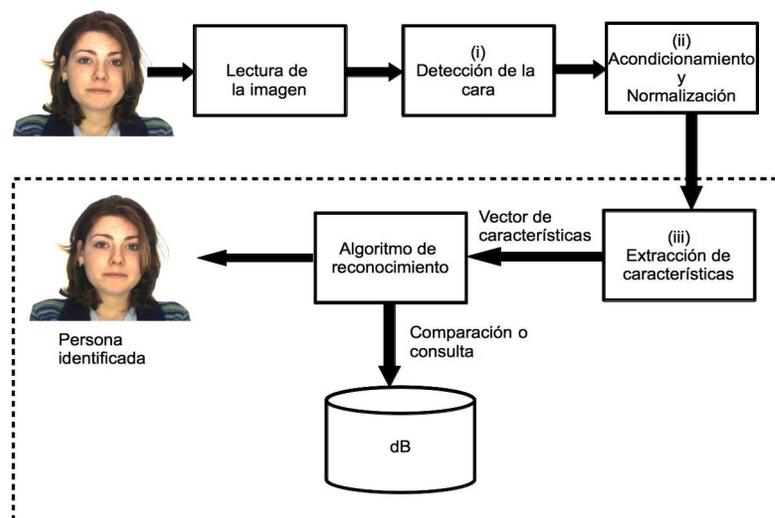


Fig. 1. Metodología clásica del reconocimiento de rostros.

En el presente proyecto se utiliza la técnica SURF la cual considera que todos estos factores no afectan el resultado del análisis ya que son invariantes a iluminación, rotación, escala, y no se utiliza el análisis de textura. Para la extracción de características solo es necesario el análisis de la región de interés, compuesta por una de las rejillas ver Fig. 2 considerado en [18].

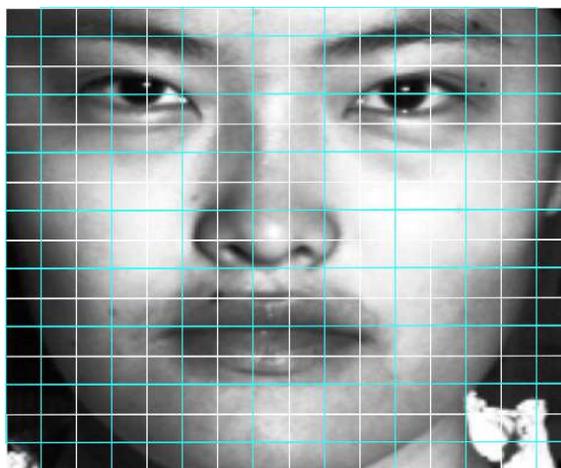


Fig. 2. Imagen del rostro descompuesta en regiones de análisis.

El uso e implementación de los atributos SURF en la metodología que planteamos, consta de una entrada, y una salida al sistema. En nuestra propuesta el sistema de

identificación y clasificación consta de dos etapas: entrenamiento y recuperación. El sistema propuesto ver Fig. 3, junto con su operación.

Entradas al sistema:

- Entrenamiento del sistema SURF propuesto con imágenes de rostros: Bases de imágenes de rostros en condiciones ideales.

Salidas del sistema:

- Recuperación: Las tres o cinco imágenes de las bases de datos que más se aproximen o parezcan a la imagen de consulta.

A. Entrenamiento

La arquitectura de entrenamiento consta de las siguientes partes:

- dB: Contiene las imágenes de rostros en condiciones ideales

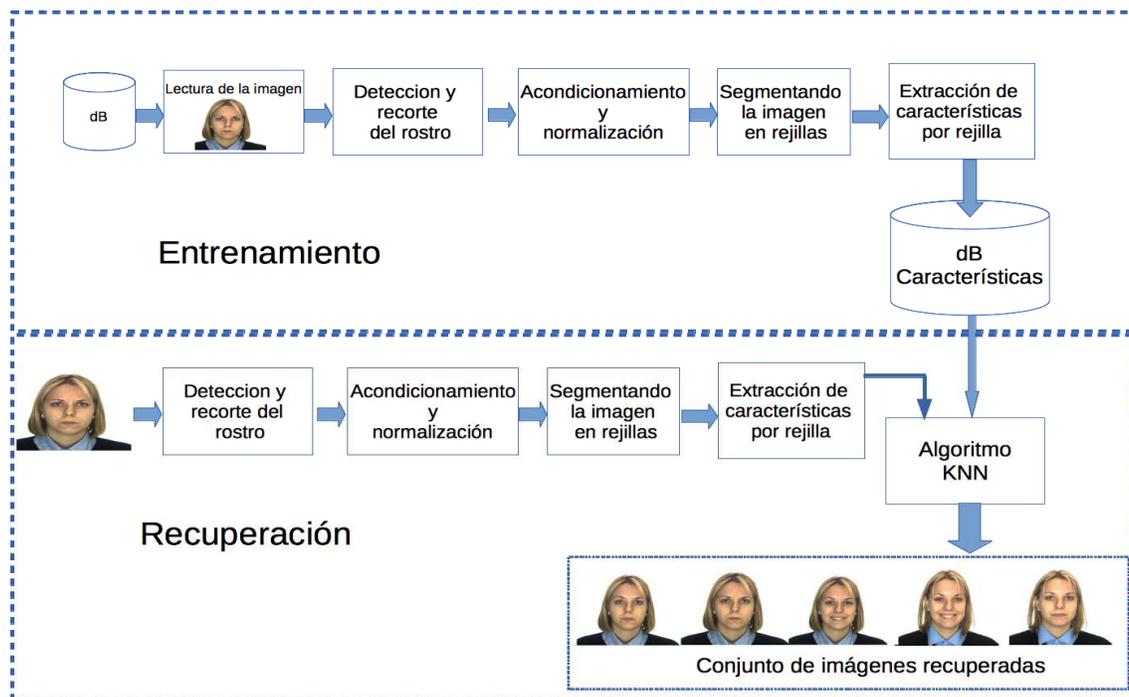


Fig. 3. Arquitectura del sistema SURF.

- Lectura de Imágenes: Lee las imágenes que serán procesadas.
- Detección y recorte del rostro: Utiliza el algoritmo de detección de rostro de la biblioteca OpenCV, una vez detectado el rostro se recorta de la imagen y se realiza un ajuste de tamaño las imágenes.
- Acondicionamiento y normalización: Realiza el acondicionamiento de las imágenes, tratando de eliminar impurezas que contengan las imágenes.
- Segmentando la imagen en rejillas: Se realiza una segmentación de la imagen en rejillas del mismo tamaño pasando una ventana deslizante de tamaño 40x40 pixeles, en total se generan 225 rejillas para cada imagen.
- Extracción de características por rejilla: A cada una de las rejillas de la imagen se le extraen los puntos de interés y el descriptor SURF para cada uno de esos puntos. Para cada imagen se obtendrán 225 contenedores de puntos de interés y 225 descriptores.
- dB Características: contiene la información de los puntos de interés y los descriptores de cada una de las imágenes, por lo que al final se tendrá un arreglo de puntos de interés y un arreglo de descriptores SURF: $VectorKeyPoins[Nimags*225]$ y $VectorDescriptors[Nimags*225]$

B. Recuperación

La arquitectura del sistema en la recuperación consta de una esquema similar al de entrenamiento, el cual se describe de la siguiente manera:

- Los bloques de las primeras cinco etapas se ejecutan de la misma manera que en la etapa de entrenamiento, hasta la parte de la extracción de características por rejilla.

- Aplicar algoritmo k -NN con $N=5$. Los 255 descriptores generados, son comparados uno a uno con el descriptor correspondiente en cada una de las imágenes en la base de datos de características y al final se extraen las imágenes más cercanas a la imagen de consulta que tuvieron el máximo número de puntos que realizaron el mejor "matching" en cada una de las rejillas. El resultado de los puntos que hacen "matching" se les aplica una operación de distancia Euclidiana para los puntos de interés involucrados, por medio de un radio mínimo para tener una tolerancia y asegurarse que la comparación realizada corresponde con la región analizada y no esta en una región más alejada ver Fig. 4, donde se observa un punto que esta dentro de la zona de búsqueda.

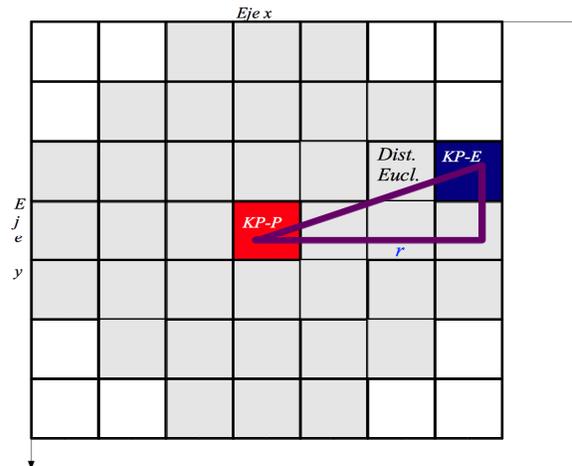


Fig. 4. "Matching" entre punto de interés de prueba y puntos de interés de entrenamiento.

C. Aceleración de la construcción de datos de entrenamiento.

El tiempo de construcción de la base de datos de entrenamiento depende principalmente del procesamiento de las N imágenes de una base de datos específica. Para reducir este tiempo, desarrollamos un algoritmo paralelo que utiliza las herramientas de OpenMP y OpenCV con las cuales el proceso de la extracción de características se paraleliza, por lo que podemos acelerar el

análisis de las imágenes ya que se procesan n-rejillas en paralelo, en lugar de hacerlo de la forma serial, es decir una tras de otra.

El algoritmo paralelo consta esencialmente de los siguientes pasos.

1. El proceso principal lee una de las imágenes a procesar.
2. Se generan 15 hilos los cuales procesan 15 rejillas de 40x40 pixeles cada uno, se extraen los puntos de interés y descriptores de cada rejilla y guardan esa información en el arreglo correspondiente.
3. Al final del proceso de entrenamiento se tienen dos arreglos: uno contiene los puntos de interés de todas las imágenes $VectorPuntosInterés[Nimag*225]$ y el otro contiene todos los descriptores $VectorDescriptores[Nimag*225]$.

D. Pruebas

Esta metodología se probó con las bases de datos de imágenes de rostros: ArDatabase [19], BioID [20], ExtendedYaleFaces [21] y YaleFaces [22]. Algunos ejemplos de los rostros de las bases de datos ver Fig. 5 se muestran respectivamente. Estas bases de datos no tienen el mismo tipo de resolución, así como el formato de la imagen, por lo que los programas se ajustaron para cada una de ellas. La cantidad de imágenes por cada base de datos, así como sus características se describe de manera detallada, para su completo entendimiento ver Tabla 1.

Para la versión de programación secuencial y paralela se implementó sobre una computadora tipo WorkStation en lenguaje C++, en una computadora tipo WorkStation, con sistema operativo Linux de 64 bits, con 16Gb de ram, procesador intel Xeon E5-2620 con 12 núcleos a una velocidad de 2Ghz, así como el uso de las herramientas OpenMPI, OpenMP y OpenCV, para el manejo de hilos en memoria compartida y procesamiento digital de imágenes respectivamente.



Fig. 5. Ejemplo de imágenes de las bases de datos: (a) Yale Faces, (b) Extended Yale, (c) AR, (d) BioID.

Para cada base de datos se extraerán dos mediciones en base a los porcentajes de recuperación:

1. Precisión

$$\text{precisión} = \frac{\text{No_imagenes_recuperadas}}{\text{total_imagenes_por_persona}} \times 100\% \quad (1)$$

2. Recuperación

$$\text{recuperación} = \frac{\text{No_imagenes_recuperadas}}{\text{total_img_en_la_dB}} \times 100\% \quad (2)$$

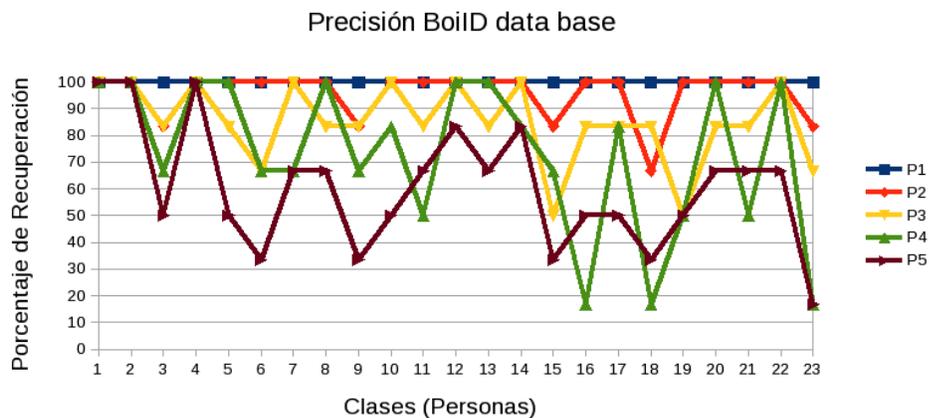
dB	Número de imágenes	Tipo de imagen	Formato	Resolución
AR data base	4000	Color	Jpg	768x576
BioID	1521	Gray Scale	Pgm	648x286
Extended Yale data base	16128	Gray Scale	Pgm	640x480
Yale data base	165	Gray Scale	Gif	320x243

Tabla 1. Descripción de las bases de datos.

3. Resultados

En esta sección se presentan los resultados generados por la metodología propuesta anteriormente. Se trabajó con las bases de datos BioID, AR data base, Yale Faces data base y Extended Yale Faces data base. La programación se realizó en C, C++ y OpenCV.

Para cada una de las bases de datos, se seleccionaron las imágenes que cumplen con la descripción de condiciones ideales mencionadas anteriormente, a cada una de estas bases de datos por el momento solo se seleccionaron 6 imágenes por clase (persona), se extrajeron las características descriptivas de cada una de las imágenes. A partir de este análisis se obtuvieron las k imágenes más cercanas a la imagen de consulta para el algoritmo k - MN , usando la métrica Euclidiana en las pruebas. Usando la matriz de confusión podemos analizar el porcentaje de clasificación para los experimentos realizados, como se muestra en los resultados que se obtuvieron de clasificación para las bases de datos ver Fig. 6; teniendo que para el método de validación por resustitución el 100% de recuperación para la 1er imagen más parecida y los porcentajes de recuperación para las siguientes imágenes más parecidas va en disminución como se observa en las gráficas obtenidas para cada una de las bases de datos.



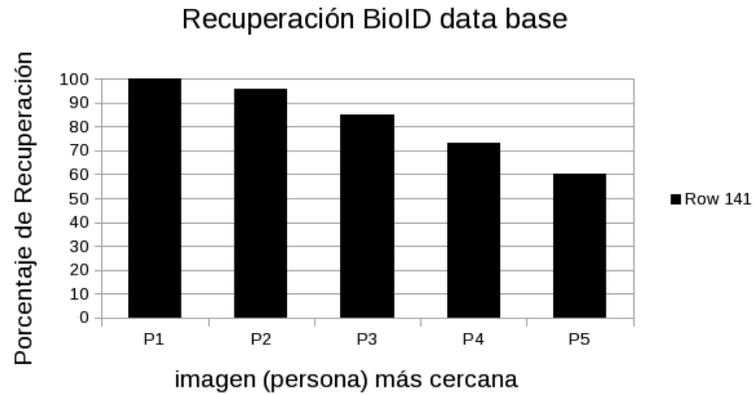


Fig. 6. (a) Gráficas de recuperación y precisión para la base de datos Biold.

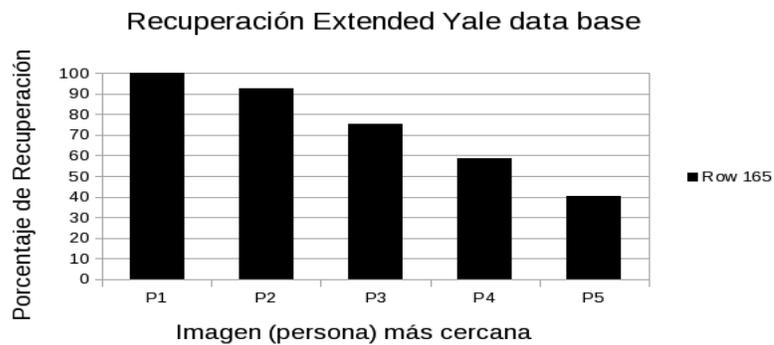
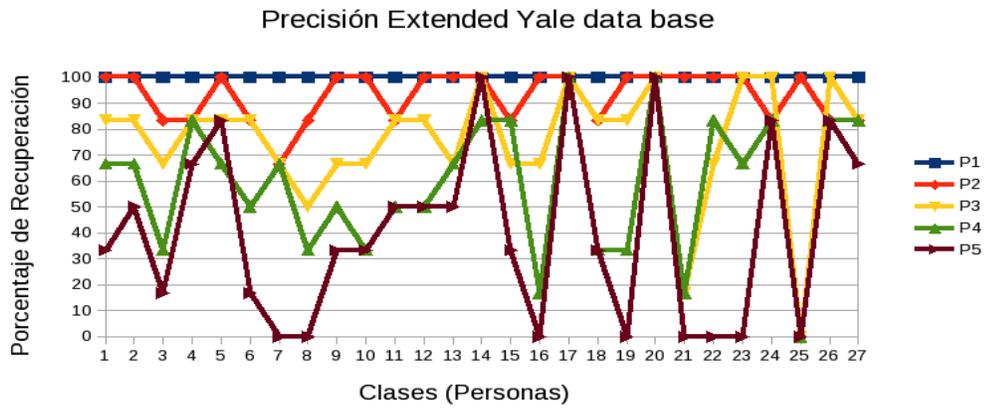


Fig. 6. (b) Gráficas de recuperación y precisión para la base de datos Extended Yale.

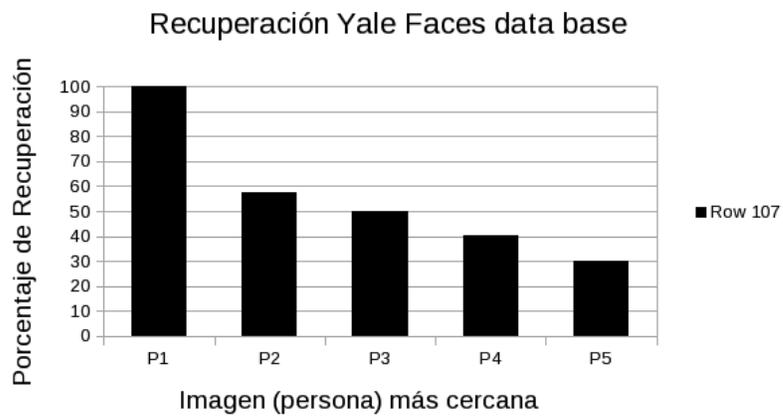
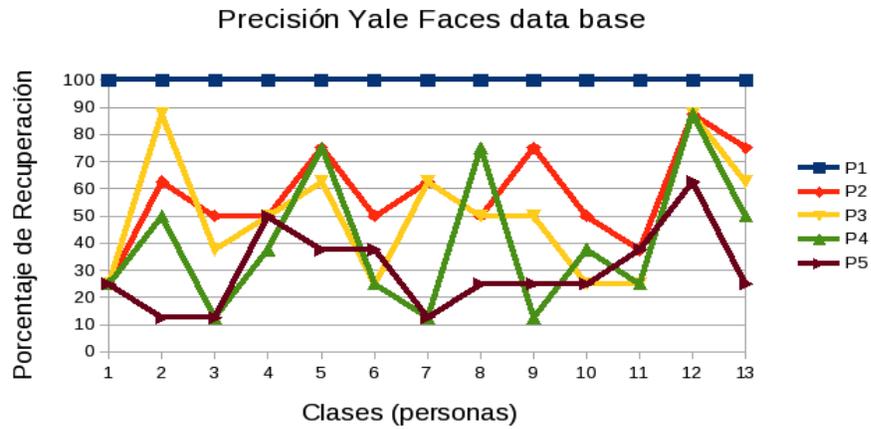
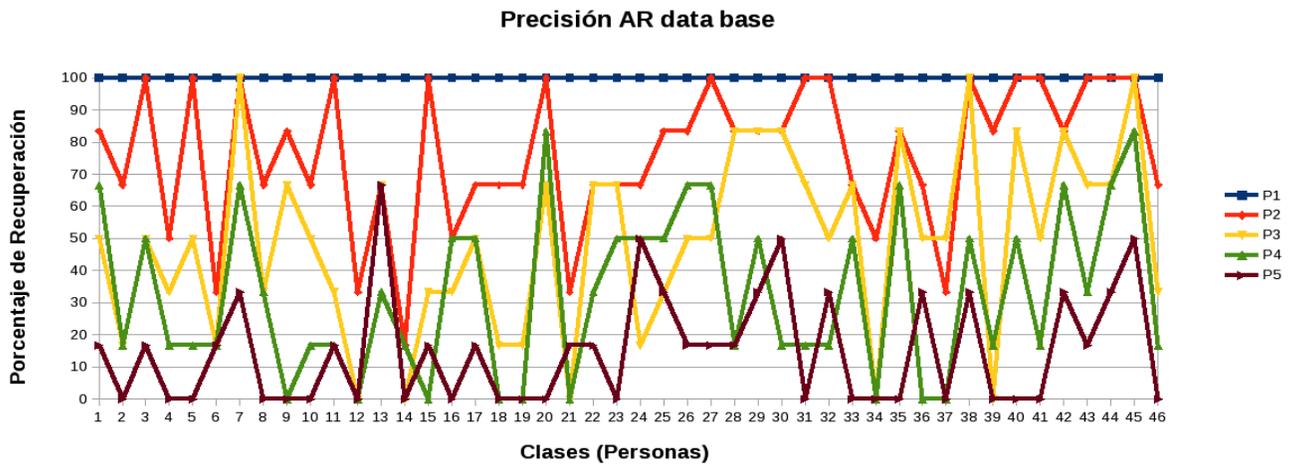


Fig. 6 (c) Gráficas de recuperación y precisión para la base de datos Yale Faces.



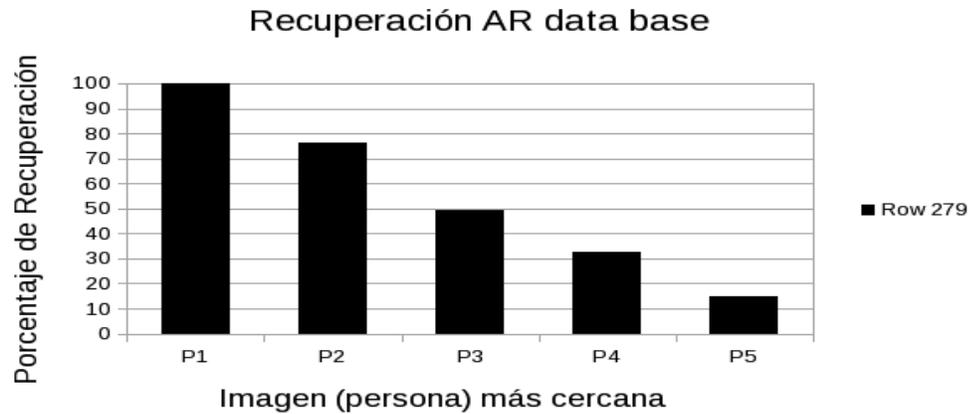


Fig. 6 (d) Gráficas de recuperación y precisión para la base de datos AR.

4. Discusión

En las gráficas de recuperación vemos en el eje y el porcentaje de recuperación y en el eje x , la imagen recuperada más cercana p_1 es la primera más parecida, p_2 la segunda y así sucesivamente hasta p_5 , para el valor de $k=5$ en $k-NN$.

En las gráficas de precisión vemos en el eje y el porcentaje de recuperación y en el eje x el número de clases (personas) que contiene la base de datos, y las series de la gráfica representan los porcentajes generados para cada una de las clases, ya que cada base de datos contiene por persona el mismo número de imágenes, en este caso 6 imágenes por persona. Por lo que para la 1er imagen recuperada se tiene de nuevo el 100% de recuperación para las 6 imágenes esperadas, y el porcentaje varía para las imágenes siguientes {2, 3, 4, 5} de cada persona como se observa en las gráficas de precisión de cada base de datos.

En la gráfica ver Fig. 6 (a) se observan los porcentajes de recuperación obtenidos de las 5 personas identificadas más cercanas a una de las imágenes de consulta, cada una de las líneas representa el porcentaje de clasificación, al modificar el valor de k en el algoritmo de $k-NN$, donde $k=\{1,2,3,4,5\}$, lo mismo pasa en la en las gráficas de las

demás bases de datos ver Fig. 6 (b), ver Fig. 6 (c) , ver Fig. 6 (d), para el calculo de la recuperación.

En la gráfica de barras ver Fig. 6 (a), se observa el porcentaje total promedio (precisión), que se obtiene para las k imágenes más cercanas ala imagen de consulta, donde se observa que con forme se piden más imágenes recuperadas el porcentaje de clasificación disminuye considerablemente, lo mismo en las gráficas de las demás bases de datos ver Fig. 6 (b), ver Fig. 6 (c) , ver Fig. 6 (d), para el calculo de precisión.

Ejemplos de recuperación de imágenes por consulta de la propia imagen ver Fig. 7, para cada una de las bases trabajadas respectivamente.

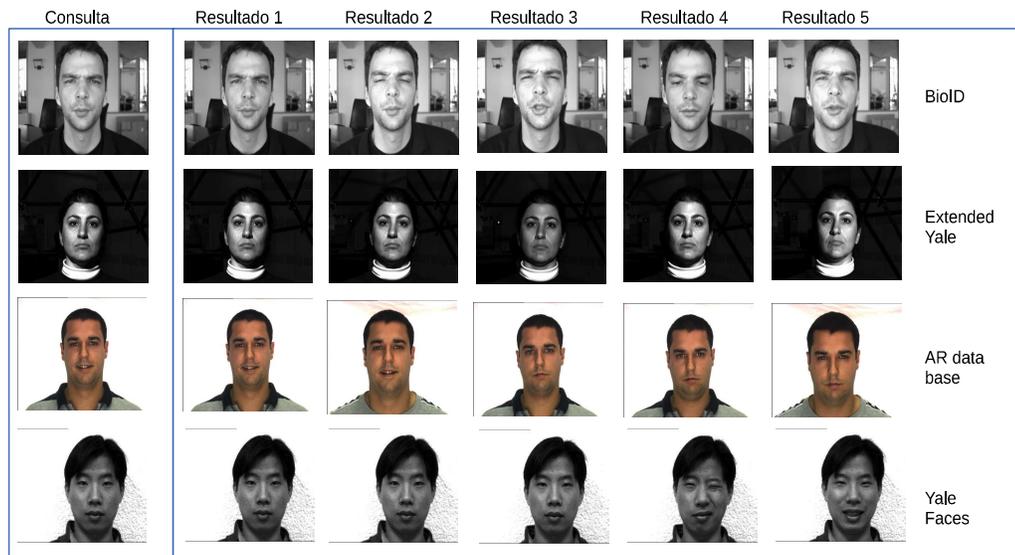
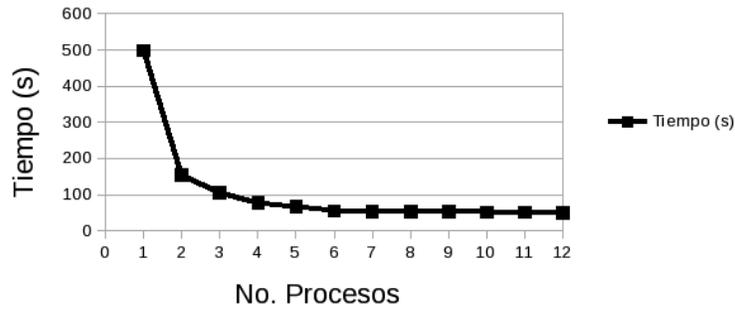


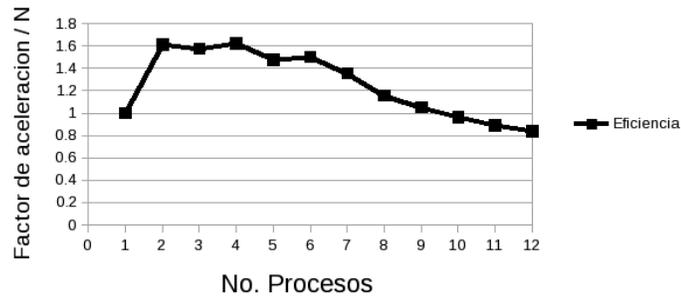
Fig. 7. Resultado para cada una de las bases de datos.

Tiempo Total Vs No. Procesos



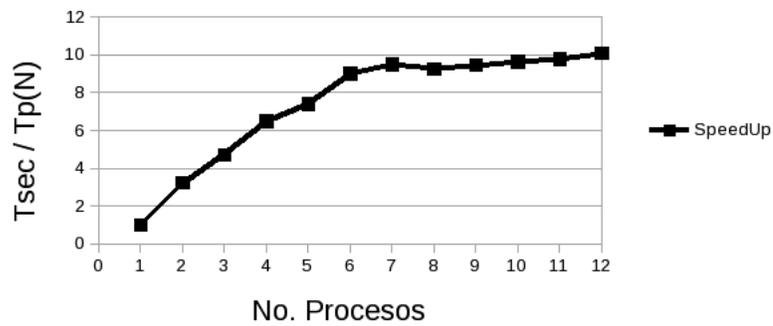
(a)

Eficiencia



(b)

Factor de Aceleración



(c)

Fig. 8. Graficas de análisis computacional: (a) Tiempo paralelo vs procesos, (b) Eficiencia, (c) Factor de aceleración.

Se observó que el tiempo de ejecución tuvo una reducción considerable mientras aumentaba el número de procesos ver Fig. 8 (a). El factor de aceleración (FA) ver Fig. 8 (b) de la ecuación (3), el cual va aumentado de manera lineal hasta el punto 6 donde se observa una caída y se vuelve a incrementar a partir del proceso 9.

$$FA = \frac{T_{sec\ uencial}}{Tp(N)} \quad (3)$$

Por último eficiencia ver Fig. 8 (c) la cual es calculada como se ve en la ecuación (4):

$$Eficiencia = \frac{FA}{Tp(N)} \quad (4)$$

En donde se observa que la eficiencia decrece de manera considerable a partir del proceso 6 y después del proceso 9 esta se mantiene estable.

Aunque en el análisis del desempeño se observa que a partir del proceso 6 el rendimiento decrece un poco, tanto en el factor de aceleración como en la eficiencia, por lo que parece que la máquina simula tener 12 núcleos y que se trata de un sistema Hyper Threading, por lo que tendría 6 microprocesadores reales y por este motivo, se observa un decremento en la evaluación de nuestro sistema dentro de esta máquina.

5. Conclusiones

Se propuso una nueva implementación a la técnica SURF, utilizada ahora para el reconocimiento de rostros. Se tuvo que esta técnica genera muy buenos resultados cuando las imágenes con las que se trabaja cumplen con las condiciones ideales, como lo es la iluminación, la resolución y que las imágenes son de la misma sesión o tiempo, como en el caso de las bases de datos BioID y MUCT, no así en AR data base puesto que algunas imágenes son tomadas en diferentes temporadas y las resoluciones de ellas hacen que el análisis de puntos surf tenga demasiadas variaciones.

Como trabajo futuro se planean dos tareas inmediatas: (i) aumentar el número de imágenes para poder medir el desempeño de la metodología propuesta en grandes volúmenes de información, y (ii) complementar esta técnica enriqueciéndola con el análisis de textura local del rostro a partir de los puntos de interés, usando la técnica CBIR, la cual se ha estudiado que funciona muy bien para la recuperación de escenarios naturales, y así generar un patrón descriptivo más robusto el cual disminuya los errores de recuperación y al mismo tiempo aumente los porcentajes de clasificación.

Con base a las estimaciones experimentales con las bases de datos hasta ahora probadas, será interesante reportar el desempeño de reducción de tiempo de cómputo con bases de datos mucho mayores, sobre la versión de programación paralela, y estudiar el nivel de recuperación sobre un número mucho mayor de imágenes.

6. Bibliografía

- [1] T de la Luz-Raul, "System de reconocimiento facial por medio de eigenfaces y redes neuronales". M.S. thesis. Esime IPN. Junio 2009.
- [2] A-González and F-Prieto, "Extracción de puntos característicos del rostro para medidas antropométricas". *Revista Ingenierías Universidad de Medellín*. Vol. 9. No. 17. Julio-diciembre 2010. 139–150 pp.
- [3] K-A-Kim. Facial feature extraction using pca and wavelet multi-resolution images. sixth IEEE International Conference on Automatic Face and Gesture Recognition. Mayo 2004. 17–19 pp.
- [4] Y-Zaho, Part-based pca for facial feature extraction and classification. International Workshop in Haptic Audio visual Environments and Games. Noviembre 2009. 99–104 pp.
- [5] B-Amarapur, N-Patil, The facial texture extraction for face recognition based on geometrical approach. IEEE CCECE/CCGEI. Mayo 2006. 1936–1939 pp.

- [6] G-G-Yen, N-Nithianandan, Facial feaature extraction using genetic algorithm. Congress on Evolutionary Computation, 1895–1900. Mayo 2002.
- [7] M-H-Mahoor, M-Abdel-Mottaleb, Facial features extraction in color images using enhanced active shape model. 7th International Conference on Automatic Face and Gesture Recognition. 2006. 10–12 pp.
- [8] T-F-Cootes, “Active appearance models”. IEEE Transactions on Pattern Analysis and Machine Intelligence. Vol. 23. No. 6. 2001. 681–685 pp.
- [9] Y-Yokogawa, “A proposal of improved lip contour extraction method using deformable template matching and its application to dental treatment”. Sys-tems and Computers in Japan. Vol. 38. No. 5. 80–89 pp.
- [10] H. K. Ekenel, R. Stiefelhagen, Why is facial occlusion a challenging problem? In International Conference on Biometrics. Sassari, Italy. June 2009.
- [11] A. M. Martinez, “Recognizing imprecisely localized, partially occluded and expression variant faces from a single sample per class”. IEEE Transactions on Pattern Analysis and Machine Intelligence. Vol. 24. No. 6. 2002. 748–763 pp.
- [12] L. Wolf, T. Hassner, Y. Taigman. Descriptor based methods in the wild. In ECCV, 2008.
- [13] M. Turk, A. Pentland, “Eigenfaces for recognition”. Journal of Cognitive Neuroscience. Vol. 3. 1991. 71–86 pp.
- [14] Surf: Speeded up robust features. Computer Vision and Image Understanding (CVIU). <http://www.vision.ee.ethz.ch/~surf/>.
- [15] A performance evaluation of local de- scriptors. IEEE Transactions on Pattern Analysis and Machine Intelligence. <http://dx.doi.org/10.1109/TPAMI.2005.188>.

- [16] Javier Ruiz del Solar, Rodrigo Verschae, Mauricio Correa, Face recognition in unconstrained environments: A comparative study. In ECCV Workshop on Faces in 'Real-Life' Images: Detection, Alignment, and Recognition, Marseille, France, October 2008.
- [17] Donghoon Kim, Rozenn Dahyot, Face components detection using surf descriptors and svms. In International Machine Vision and Image Processing Conference. Portrush, Northern Ireland. September 2008. 51–56 pp.
- [18] Philippe Dreuw, Pascal Steingrube, Harald Hanselmann, Hermann Ney, "SURF-Face: Face Recognition Under Viewpoint Consistency Constraints". 2009. In A. Cavallaro, S. Prince and D. Alexander, editors. Proceedings of the British Machine Conference. September.
- [19] A.M. Martinez, R. Benavente, "The AR Face Database". CVC Technical Report No. 24. June 1998.
- [20] O. Jesorsky, K. Kirchberg, R. Frischholz, In J. Bigun, F. Smeraldi, editors, Audio and Video based Person Authentication - AVBPA. Springer, 2001.
- [21] Athinodoros Georghiades, Peter Belhumeur, David Kriegman's paper, "From Few to Many: Illumination Cone Models for Face Recognition under Variable Lighting and Pose". PAMI. 2001.
- [22] Yale University, Yale Face Database. URL:<http://vision.ucsd.edu/content/yale-face-database>. 5/06/2015.

7. Autores

Ing. Cesar Benavides Alvarez recibió su título de Ingeniero en Electrónica en 2012 en la Universidad Autónoma Metropolitana Campus Iztapalapa (UAM-Iztapalapa). Actualmente está estudiando una Maestría en Ciencias y Tecnologías de la Información en la Universidad Autónoma Metropolitana. Sus intereses de investigación son: Visión por Computadora, Reconocimiento de Patrones y Sistemas Distribuidos.

Dr. Juan Villegas Cortez es profesor-investigador en el Departamento de Electrónica de la Universidad Autónoma Metropolitana desde 2010 su intereses actuales de investigación incluyen reconocimiento de Patrones, Visión por Computadora, Computación Evolutiva, Memorias Asociativas y procesamiento digital de señales.

Dra. Graciela Román Alonso es profesora-investigadora en el Departamento de Ingeniería Eléctrica en la UAM Iztapalapa. Sus áreas de investigación son sistemas distribuidos, cómputo paralelo y programación avanzada.

Dr. Carlos Avilés Cruz Actualmente se desempeña como profesor-Investigador Titular de tiempo completo en el departamento de Electrónica de la UAM-Azcapotzalco, donde desarrolla trabajos de investigación en las áreas de Reconocimiento de Patrones, visión artificial e Interfaces Cerebro Computadora BCI.