

# Reconocimiento biométrico entrenando y testeando con diferentes bases de datos de caras

Joan Fàbregas, Marcos Faundez-Zanuy

Escola Universitària Politècnica de Mataró (Adscrita a la UPC)  
08303 MATARO (BARCELONA), Spain  
[fabregas@eupmt.es](mailto:fabregas@eupmt.es), [faundez@eupmt.es](mailto:faundez@eupmt.es)  
<http://www.eupmt.es/veu>

**Resumen.** El reconocimiento biométrico presenta un amplio conjunto de fuentes de variabilidad. Si bien algunas bases de datos públicas contemplan diversas variabilidades, se trata de condiciones de laboratorio y por tanto pertenecen a un entorno idealizado. En este artículo presentamos una serie de experimentos en los que los modelos de una determinada característica biométrica se han obtenido con una base de datos y el test se realiza con otra diferente. Para poder llevar a cabo este tipo de experimentos no se calcula un modelo por persona, sino un clasificador con dos clases: iguales y diferentes. Por tanto, durante el test basta con presentar al clasificador la imagen de la identidad declarada y la imagen de test para que el sistema decida si ambas medidas biométricas pertenecen a la misma persona o no. De esta forma, el clasificador puede tratar muestras pertenecientes a personas no usadas durante el entrenamiento. La realización de tests con datos biométricos de personas extraídos de bases de datos distintas de la de test puede ser considerado una prueba más alejada de las condiciones ideales de laboratorio y por tanto, son más realistas de cara a probar la bondad de un sistema en un funcionamiento más real.

## 1 Introducción

La mayor parte de estudios en reconocimiento biométrico de personas contienen una parte experimental basada en una única base de datos. En el mejor de los casos, proporcionan resultados con dos o tres bases de datos, con la finalidad de demostrar que el algoritmo propuesto puede funcionar satisfactoriamente en diversos escenarios y que no está sobre-entrenado (adaptado a una base de datos en concreto).

En este artículo presentamos una serie de experimentos usando varias bases de datos de forma conjunta. La sistemática consiste en entrenar con una base de datos y testear con otra que contiene personas distintas. Para poder llevar a cabo este tipo de experiencias no entrenaremos un modelo por persona, sino que usaremos un único clasificador con dos clases: iguales (genuino) y diferentes (impostor). Por tanto, el clasificador se entrena para decidir si dos muestras de entrada (una de “entrenamiento” o plantilla modelo y otra de test) pertenecen al mismo usuario.

Si bien en principio este tipo de clasificador está adaptado a problemáticas de verificación (comparaciones 1:1) se puede extender fácilmente a aplicaciones de identifi-

cación (comparaciones 1:N) mediante la verificación contra todos los usuarios presentes en la base de datos. Por tanto, el problema de identificación se convierte en N verificaciones consecutivas.

### 1.1 La problemática de los sistemas biométricos

Los sistemas de seguridad biométrica [1] ofrecen un buen conjunto de ventajas frente a los sistemas clásicos (passwords, llaves, etc.) Sin embargo, existen una serie de problemáticas no resueltas todavía. En [2] dividimos estos problemas en cuatro categorías principales. En este artículo, presentamos un Nuevo mecanismo que puede aliviar dos de estos problemas:

- a) Precisión: Cómo representar de forma precisa y eficiente los patrones biométricos.
- b) Escala: Cómo medir de forma repetible y distintiva patrones biométricos de una población amplia.

La mayor parte de la investigación biométrica comienza con la adquisición de una base de datos biométrica o con la utilización de una base de datos disponible, como las descritas en [3]. Esto supone una primera aproximación válida. Solventa el problema de disponer de una cantidad elevada de voluntarios para testear el sistema cada vez que se modifican los parámetros del algoritmo, pero presenta inconvenientes. Algunos de ellos han sido expuestos de forma irónica, por ejemplo, por Naggy en “Candide’s practical principles of experimental pattern recognition” [4]. Una regla, que ciertamente tiene que ser evitada por los investigadores honestos, es la siguiente:

- a) Teorema: Existe un conjunto de datos para los cuales un algoritmo candidato es superior a cualquier otro algoritmo rival. Este conjunto puede ser construido omitiendo de la base de datos aquellas muestras que son incorrectamente clasificadas por el algoritmo candidato.
- b) Precaución “Casey”: Nunca pongas tus datos experimentales disponibles a otros investigadores; alguien puede encontrar una solución obvia que tu fuiste incapaz de hallar.

Por consiguiente, la disponibilidad de la base de datos es importante de cara a validar un algoritmo dado, permitir la comparación entre diferentes algoritmos, así como el desarrollo de algoritmos. Este tipo de evaluaciones se conocen como evaluación de tecnología [16]. El objetivo de la evaluación de tecnología es comparar diferentes algoritmos de forma que el test de todos los algoritmos se lleva a cabo sobre una base de datos estandarizada, recogida mediante un sensor “universal”. El test se lleva a cabo mediante procesado offline. Dado que la base de datos es fija, los resultados serán repetibles.

Algunos aspectos importantes de la base de datos son:

- a) Número de usuarios (Un número elevado de usuarios permite estudiar la capacidad discriminativa de un determinado rasgo biométrico).
- b) Número de sesiones de grabación (varias sesiones realizadas en diferentes días permiten estudiar la variabilidad inter-sesión).
- c) Número de muestras diferentes por sesión (varias adquisiciones por sesión permiten estudiar la variabilidad intra-sesión).

Una ventaja principal de la disponibilidad de bases de datos es que las condiciones de los experimentos suelen estar fijadas, de forma que se evitan algunos de los errores principales del diseño de sistemas [5]:

- a) “Testing on the training set”: las puntuaciones del test se obtienen usando los datos de entrenamiento, lo cual es una situación óptima y nada realista.
- b) “Overtraining”: La base de datos es usada de forma intensiva para optimizar el comportamiento. Este problema se puede identificar cuando un algoritmo concreto proporciona un comportamiento excepcionalmente bueno sobre una base de datos, pero dichas prestaciones no se mantienen al cambiar la base de datos.

Las bases de datos incluyen materiales diferentes para entrenar y testear con la finalidad de evitar el primer problema. Adicionalmente, la disponibilidad de varias bases de datos ayuda a testear el algoritmo sobre nuevos datos y, por tanto, a comprobar si los algoritmos desarrollados por un determinado laboratorio son generalizables (se mantienen al cambiar de base de datos). Por consiguiente, se solventa el segundo problema.

En [13,página 161] se encuentra una afirmación interesante, en el contexto de reconocimiento de firmas on-line [17]: “for any given database, perhaps a composite of multiple individual databases, we can always fine tune a signature verification system to provide the best overall error trade-off curve for that database –for the three databases here, I was able to bring my overall equal-error rate down to about 2.5%- but we must always ask ourselves, does this fine tune make common sense in the real world? If the fine tuning does not make common sense, it is in all likelihood exploiting a peculiarity of the database. Then, if we do plan to introduce the system into the market place, we are better off without the fine tuning.” Nosotros hemos tomado en especial consideración esta observación, y para llevarla plenamente a cabo:

- No hemos realizado ningún ajuste fino que, aunque hubiera mejorado los resultados, hubiera proporcionado tasas de error poco o nada realistas.
- Hemos ido un paso más allá: hemos entrenado y ajustado el sistema con una base de datos y hemos realizado el test con dos bases distintas que contienen diferentes usuarios, zooms, panorámicos, rotaciones, dispositivos de adquisición y, en definitiva, diferentes casuísticas.

Usualmente, en los sistemas clásicos de reconocimiento de patrones, existe un número limitado de clases y una cantidad muy elevada de muestras de entrenamiento. Por ejemplo, en el sistema de reconocimiento de dígitos manuscritos en el servicio postal de los Estados Unidos descrito en [6] únicamente hay 10 clases (dígitos) y miles de muestras por clase. En biometría la situación es justamente la contraria, puesto que normalmente tenemos un número elevado de clases (personas) de las que únicamente se toman de tres a cinco muestras durante el entrenamiento [7]. En estas condiciones no hay suficiente número de muestras para entrenar un modelo demasiado sofisticado para cada persona.

En este artículo presentamos:

- a) Una aproximación nueva [19] capaz de gestionar un número elevado de clases con pocas muestras por clase.
- b) Algunos experimentos de reconocimiento de caras entrenando con una base de datos y testeando con otra diferente.

## 2 Estrategia de entrenamiento para un número pequeño de muestras de entrenamiento.

En general, el reconocimiento de patrones se puede llevar a cabo desde dos puntos de vista distintos [8]:

- a) **Generativo (también llamado informativo):** El clasificador aprende las densidades de probabilidad de la clase, examina la probabilidad de cada clase para producir las características medidas y les asigna la clase más probable. Dado que cada densidad de clase se considera a parte de las otras, el modelo para cada clase es relativamente simple de entrenar. En el caso biométrico, corresponde a un modelo por persona. Únicamente se usan muestras pertenecientes a la persona. En este caso, el principal problema es el pequeño número de muestras disponibles por usuario. Por ejemplo, es típico un valor de 5 fotografías de entrenamiento en un sistema de reconocimiento de caras. Algunos ejemplos incluyen el Linear Discriminant Analysis (LDA) y los Hidden Markov Models (HMM).
- b) **Discriminativo:** El clasificador no modela las densidades de las características de la clase, sino que modela los límites de la clase o las probabilidades de pertenencia a la clase directamente. En el caso biométrico, corresponde a entrenar el clasificador para que aprenda a diferenciar a un usuario de los restantes. Esto significa que el algoritmo requiere muestras de un usuario dado pero también necesita muestras de los otros. En esta aproximación el número de muestras para entrenar un modelo es más elevado, pero la mayor parte de las muestras son inhibitorias (comparativamente existe un número pequeño de muestras pertenecientes a un usuario dado, respecto al número de muestras de los otros usuarios). Estos modelos son más difíciles de entrenar y a menudo suponen el uso de algoritmos complejos. Algunos ejemplos son las redes neuronales y los support vector machines.

En el primer caso (modelos generativos), cuando se quiere añadir un nuevo usuario, basta calcular su modelo asociado. En el segundo caso se debe reentrenar el sistema completo, lo cual requiere tiempo y esto puede ser un serio inconveniente en aplicaciones funcionando en tiempo real. Especialmente cuando las altas y bajas de usuarios son frecuentes. La tabla 1 resume las principales características de las dos aproximaciones [8].

**Tabla 1:** Comparación entre las aproximaciones generativa y discriminativa al reconocimiento de patrones.


|                          | Generativo                              | Discriminativo  |
|--------------------------|---|---|
| Presunciones del modelo  | Densidades de clase                     | Fronteras de las clases (funciones discriminantes)                          |
| Estimación de parámetros | “fácil”                                 | “Complicado”  |
| Ventajas                 | Más eficiente si el modelo es correcto. | Más flexible y robusto, puesto que realiza pocas presunciones.              |
| Inconvenientes           | Bias si el modelo es incorrecto.        | También puede tener bias. Ignora información de la distribución subyacente. |

Con la finalidad de evitar estos inconvenientes presentamos un método alternativo denominado ‘dispersion matcher’ (ajuste por dispersión), que es especialmente útil en los sistemas biométricos. Entrenaremos un único clasificador para resolver la dicotomía: ¿pertenecen estos dos vectores de características a la misma persona? De esta forma resolvemos el problema relativo al número de muestras por clase. Dado que no entrenamos el clasificador con todos los individuos presentes en la base de datos, será capaz de clasificar en un entorno de mundo abierto (“open world”). De hecho, el sistema biométrico, a diferencia de los algoritmos clásicos generativos y discriminativos, no aprende ningún modelo específico para el usuario, y presenta una mayor capacidad de generalización.

Cuando el usuario desea ser autenticado por el sistema, simplemente tiene que presentar su muestra biométrica y el ‘dispersion matcher’ compara la muestra biométrica a autenticar con las muestras usadas como referencia para dicha persona (adquiridas durante el proceso de enrolamiento). El usuario será aceptado si la fusión de puntuaciones [15] obtenida en cada comparación es mayor que un umbral predefinido. Por ejemplo se puede usar como método de fusión la media de las puntuaciones obtenidas al contrastar la muestra de test con cada una de las muestras de entrenamiento.

Al medir cualquier característica fisiológica de una persona, como por ejemplo la longitud de un dedo, el proceso está sujeto a errores y no siempre se obtiene el mismo resultado. La estadística nos dice que si repetimos la medida diversas veces los valores estarán distribuidos según una distribución gaussiana normal  $\mathcal{N}(x | \mu_i, \sigma_i^2)$ , la cual está caracterizada por la media ( $\mu_i$ ) y la variancia ( $\sigma_i^2$ ) de las medidas. En muchas situaciones, la distribución de la media de la característica fisiológica sobre el total de la población es también otra distribución normal,  $\mathcal{N}(x | \mu_p, \sigma_p^2)$  caracterizada por la media ( $\mu_p$ ) y la variancia ( $\sigma_p^2$ ) de la población. El ‘dispersion matcher’ está basado en el hecho de que la variancia  $\sigma_i^2$  siempre es menor que  $\sigma_p^2$ . Al plantear la diferencia entre dos muestras de esta medida fisiológica, su valor será normalmente menor cuando se trate de muestras de la misma persona que cuando se trate de personas distintas. Esto se puede representar esquemáticamente en la figura 1, con dos gaussianas: una para las diferencias correspondientes a pares de muestras genui-

nas y otra para pares correspondientes a diferencias de muestras entre impostores y genuinos.



**Fig. 1:** Ejemplo de dos gaussianas. La punteada corresponde a diferencias de muestras genuinas ( $\mathcal{N}(x | 0, 0.25)$  en este ejemplo), y la continua a diferencias entre pares de muestras genuinas e impostoras ( $\mathcal{N}(x | 0, 1)$  en este ejemplo).

Para resolver la dicotomía planteada anteriormente (iguales versus diferentes) usaremos un clasificador discriminante cuadrático (Quadratic Discriminant Classifier, QDC) [9], dado que en la práctica las distribuciones de cada característica fisiológica tienen forma de campana y presentan correlaciones lineales.

Para comprender la diferencia entre un clasificador dicotómico y las otras aproximaciones clásicas al reconocimiento de patrones analizaremos un ejemplo sencillo. La base de datos ORL [10] contiene 40 usuarios y 10 capturas por usuario. Una partición típica consiste en usar cinco imágenes por persona para entrenar y las otras cinco restantes para testear. La tabla 2 muestra los datos disponibles para cada tipo de clasificador en esta situación. Se puede observar que la diferencia entre las distintas estrategias radica en el número disponible de muestras para entrenar, mientras que el número de muestras de test es el mismo en todos los casos. Por lo tanto, la significancia estadística de los resultados experimentales es la misma para todos ellos.

Obsérvese que en los sistemas generativo y discriminativo cada clase suele equivaler a una persona, mientras que en un clasificador dicotómico sólo hay dos clases, iguales y diferentes, que se corresponden con el resultado de la verificación biométrica aceptar y rechazar.

**Tabla 2:** Ejemplo de muestras de entrenamiento y test para una base de datos con  $n$  individuos y  $s$  muestras por individuo, usando la mitad de las muestras para entrenar y la otra mitad para testear.

| Estrategia              | Muestras por clase para entrenar   | Muestras por persona para testear |                    |
|-------------------------|--|-----------------------------------|--------------------|
|                         |  | genuino                           | impostor           |
| Generativo              | $\frac{s}{2}$ muestras genuinas  | $\frac{s}{2}$                     | $(n-1)\frac{s}{2}$ |
| Discriminativo          | $\frac{s}{2}$ muestras genuinas<br>$(n-1)\frac{s}{2}$ impostores                                       | $\frac{s}{2}$                     | $(n-1)\frac{s}{2}$ |
| Clasificador dicotómico | $n\frac{s(s-1)}{2}$ pares genuino-genuino<br>$n(n-1)\left(\frac{s}{2}\right)^2$ pares genuino-impostor | $\frac{s}{2}$                     | $(n-1)\frac{s}{2}$ |

Ciertamente, existen dependencias lineales entre los distintos pares de entrenamiento considerados en el caso del clasificador dicotómico. Sin embargo, dependiendo del tipo de clasificador, podemos sacar partido de estas muestras redundantes (por ejemplo al entrenar una red neuronal, esto supone una alternativa a la estrategia habitual de añadir ruido a los patrones de entrenamiento para incrementar su número) [20]. Para el caso particular del ‘dispersion matcher’ considerado en este artículo se calculan las matrices de covarianza, que equivalen a considerar los  $n\left(\frac{s}{2}-1\right)$  pares genuino-genuino independientes y los  $n\frac{s}{2}-1$  pares genuino-impostor independientes.

### 3. Resultados experimentales de reconocimiento de caras

Una forma de testear un algoritmo concreto de reconocimiento de caras en condiciones difíciles, alejadas de la situación ideal de condiciones de laboratorio, consiste en usar simultáneamente varias bases de datos. Entrenaremos el sistema con una base de datos y haremos el test con otra diferente, que ha sido adquirida en un entorno distinto, con usuarios distintos, etc.

El clasificador se entrena para comprobar si dos muestras de entrada pertenecen a la misma clase (usuario genuino) o no (impostor). Por tanto, al tratar de verificar una persona cuyos datos biométricos no han sido usados para entrenar el sistema, únicamente será necesario introducir la siguiente información dentro del clasificador:

- La muestra o muestras adquiridas durante el proceso de enrolamiento y que pertenezcan a la identidad declarada por el usuario. Estas muestras estarán almacenadas en la base de datos.
- La muestra de test de entrada, que acaba de ser adquirida conjuntamente con la identidad declarada por el usuario.

Será irrelevante si la persona en concreto fue usada o no para entrenar el clasificador, ya que no se asigna ningún modelo a cada persona. Este es el punto clave del algoritmo propuesto que permitirá obtener una mejora más significativa respecto a los modelos clásicos generativo y discriminativo.

### 3.1 Base de datos

Hemos usado las bases de datos ORL [10], AR [11] y JAFFE [12]. Las figuras 2, 3 y 4 muestran capturas de un usuario de cada base de datos. Las características principales de estas bases de datos son:

- a) ORL: 10 capturas diferentes de 40 personas. Para algunos sujetos, las imágenes fueron adquiridas en tiempos diferentes, variando la iluminación, expresión facial (ojos abiertos /cerrados) y detalles faciales (con y sin gafas). Ver la figura 2.
- b) AR: 126 individuos, 26 imágenes de cara individuo, tomadas en dos sesiones diferentes, variando la iluminación y la expresión facial. Se han usado 6 de las 26 imágenes, excluyendo las sobre-expuestas y aquellas con oclusiones parciales (gafas, bufandas). Dado que 9 individuos no estaban completos sólo se han usado 117. Ver la figura 3.
- c) JAFFE: Contiene imágenes de expresión facial de 10 mujeres japonesas (6 emociones diferentes más la expresión neutra). Ver la figura 4. Las expresiones faciales corresponden a las 6 emociones primarias, o emociones básicas. Existen varias capturas para cada persona y emoción (2 o 3 imágenes).



**Fig. 2:** Imágenes de muestra del primer usuario de la base de datos ORL.





Fig. 3: Imágenes de muestra de la primera persona de la base de datos AR.




Fig. 4: Imágenes de muestra de la primera persona de la base de datos JAFFE (Japanese Female Facial Expression).

### 3.2 Experimentos

En primer lugar se realiza una extracción de características, a partir de las imágenes, basada en la DCT. Puede encontrarse en nuestros trabajos previos [14] y [18].

La tabla 3 presenta los resultados experimentales con diferentes combinaciones de entrenamiento y test. Se puede observar que los mejores resultados se obtienen cuando los experimentos se realizan sobre la misma base de datos. Además, los resultados obtenidos al entrenar y testear con bases distintas también son suficientemente satisfactorios, y la degradación de las tasas de reconocimiento es pequeña. Por otra parte, las tasas de reconocimiento son competitivas respecto al estado del arte en sistemas de reconocimiento de caras. Hemos usado tres muestras de referencia por cara y el método de fusión  $\max\{\cdot\}$  [15]. Para la base de datos JAFFE se han escogido tres fotos de cara neutra como muestras de enrolamiento, de forma que los tests se realizan en condiciones “difíciles” (existe una expresión facial marcadamente distinta de la usada como plantilla de referencia o modelo de esa persona).

En las aplicaciones de verificación se ha evaluado el mínimo de la función de detección de coste (minimum Detection Cost Function, minDCF) [1], que es una medida parecida al Equal Error Rate. Por consiguiente, cuanto menor sea este valor, mejores son las prestaciones del sistema.

**Tabla 3:** Minimum detection cost function (%) para algunas bases de datos. A=Anger, D=disgust, F=Fear, H=Happy, Sa=Sad, Su=Surprise. Al entrenar con la base de datos JAFFE se han usado todas las fotografías. Dado que no es realista, no se presentan los resultados de testear con el conjunto de entrenamiento.

| Training database | Testing database |      |       |       |      |      |      |       |
|-------------------|------------------|------|-------|-------|------|------|------|-------|
|                   | OR L             | AR   | JAFFE |       |      |      |      |       |
|                   |                  |      | A     | D     | F    | H    | Sa   | Su    |
| ORL               | 2.30             | 3.08 | 20.7  | 17.78 | 11.5 | 6.85 | 5.93 | 18.15 |
| AR                | 6.82             | 3.42 | 12.0  | 12.96 | 8.52 | 6.48 | 7.96 | 16.67 |
| JAFFE             | 16.5             | 5.84 | --    | --    | --   | --   | --   | --    |

Es importante destacar que el clasificador dicotómico propuesto puede gestionar un conjunto importante de situaciones en las cuales los sistemas clásicos experimentan problemas. Se trata, principalmente, de los siguientes aspectos:

- a) Puede decidir si dos fotografías (imágenes de modelo y test) pertenecen a la misma persona. No es necesario que la información de dicha persona participara en el proceso de entrenar el sistema.
- b) No es necesario reentrenar el sistema al añadir un usuario nuevo. Esto ha sido experimentalmente comprobado a partir del buen comportamiento mostrado al verificar personas que pertenecen a una base de datos no usada durante el entrenamiento del clasificador. Únicamente en algunas expresiones faciales existe un incremento en las tasas de error (principalmente enfado y disgusto).

## 4. Conclusiones

En este artículo hemos realizado una serie de experimentos consistentes en entrenar y testear un clasificador biométrico con diferentes usuarios extraídos de bases de datos

diferentes. Esto ha sido posible porque no se calcula un modelo por persona sino que se simplifica el problema de clasificación a un problema con únicamente dos clases (genuinos e impostores), de forma que se entrena un “clasificador universal” que nos dice si dos muestras pertenecen a la misma persona o no. Los resultados experimentales son similares a los sistemas reconocedores de caras del estado del arte, e incluso funciona satisfactoriamente cuando existen expresiones faciales no presentes en el ni en el entrenamiento del clasificador ni en las muestras enroladas. Consideramos que nuestra propuesta, al poder gestionar problemáticas de gran variabilidad, es adecuada para entornos de aplicaciones reales.

## AGRADECIMIENTOS

Este trabajo ha sido financiado por FEDER y MEC, TEC2006-13141-C03-02/TCM

## Referencias

1. M. Faundez Zanuy “Biometric security technology” IEEE Aerospace and Electronic Systems Magazine, Vol.21 n° 6, pp.15-26, June 2006.
2. M. Faundez-Zanuy “Biometric recognition: why not massively adopted yet?” IEEE Aerospace and Electronic Systems Magazine. Vol.20 n° 8, pp.25-28, August 2005.
3. M. Faundez-Zanuy, J. Fierrez-Aguilar, J. Ortega-Garcia y Joaquin Gonzalez-Rodriguez “Multimodal biometric databases: an overview”. IEEE Aerospace and electronic systems magazine. Vol. 21 n° 9, pp. 29-37, August 2006.
4. Nagy G. “Candide’s practical principles of experimental pattern recognition”. IEEE Trans. On Pattern Analysis and Machine Intelligence Vol. 5 No. 2, pp.199-200, March 1983.
5. Bolle R. M., Ratha N. K., Pankanti S., “Performance evaluation in 1:1 Biometric engines”. Springer Verlag LNCS 3338, pp.27-46 S. Z. Li et al. (Eds.) Sinobiometrics 2004.
6. T. Hastie, R. Tibshirani, J. Friedman, The Elements of Statistical Learning. Data Mining, Inference, and Prediction. Springer, 2001
7. R.M. Bolle, J.H. Connell, S. Pankanti, N.K. Ratha, A.W. Senior, Guide to Biometrics, Springer, 2004
8. Y.D. Rubinstein, T. Hastie, Discriminative vs Informative Learning, Knowledge Discovery and Data Mining, 1997, pp. 49-53.
9. R.O. Duda, P.E. Hart, D.G. Stork, Pattern Classification, Second Edition, Wiley-Interscience, 2001.
10. F. Samaria & A. Harter "Parameterization of a stochastic model for human face identification". 2nd IEEE Workshop on Applications of Computer Vision December 1994, Sarasota (Florida).
11. A. M. Martinez “Recognizing Imprecisely Localized, Partially Occluded, and Expression Variant Faces from a Single Sample per Class IEEE Transaction On Pattern Analysis and Machine Intelligence, Vol.24, N.6, pp. 748-763, June 2002
12. Lyons M., Akamatsu S., Kamachi M., and Gyoba J. “Coding Facial Expressions with Gabor Wavelets”. In Third IEEE International Conference on Automatic Face and gesture.
13. Biometrics, personal identification in networked society. Edited by Anil K. Jain, Ruud Bolle and Sharath Pankanti. Kluwer academic publishers 1999.

14. Marcos Faundez-Zanuy, Josep Roure-Alcobe, Virginia Espinosa-Duró, Juan Antonio Ortega "An efficient face verification method in a transformed domain" Pattern recognition letters. Vol.28/7 May 2007 pp.854-858.
15. Faundez-Zanuy M. "Data fusion in biometrics". IEEE Aerospace and Electronic Systems Magazine. Vol. 20 n° 1, pp.34-38, January 2005
16. Mansfield A. J., Wayman J. L., "Best Practices in Testing and Reporting Performance of Biometric Devices". Version 2.01. National Physical Laboratory Report CMSC 14/02. August 2002.
17. Faundez-Zanuy M. "Signature recognition state-of-the-art". IEEE Aerospace and Electronic Systems Magazine. Vol.20 n° 7, pp 28-32, July 2005.
18. Faundez-Zanuy M, Fabregas J., "On the relevance of facial expressions for biometric recognition" Aceptado para su publicación en ICTAI 2007, Patras, LNCS Springer.
19. Fabregas J., Faundez-Zanuy M. "Biometric dispersion matcher" Pattern Recognition. doi:10.1016/j.patcog.2008.04.020
20. Faundez-Zanuy M., "On the usefulness of almost-redundant information for pattern recognition". Nonlinear Speech Modeling, LNAI 3445, pp. 357-364. Springer 2005.