

RECONOCIMIENTO BIOMÉTRICO DE AUDIO Y ROSTRO: UN SISTEMA VIABLE DE IDENTIFICACIÓN

Miguel A. Carrasco, Roberto Portugal, Billy Peralta

*Departamento de Ciencia de la Computación
Pontificia Universidad Católica de Chile
Av. Vicuña Mackenna 4860(143), Santiago de Chile
{ mlcarras@puc.cl, rportug@ing.puc.cl, bmperalta@puc.cl }*

Abstract: Los sistemas biométricos se han convertido en una realidad cotidiana para las personas. Día a día vemos como su uso se ha extendido a las actividades comerciales, privadas, gubernamentales, etc. Nuestra investigación plantea el uso de dos medidas biométricas, que en general tienen un bajo rendimiento en forma independiente; sin embargo, demostramos que su utilización en forma combinada es una alternativa viable como medio de identificación. Para ello utilizamos técnicas de extracción de características en rostro y audio, algoritmos de selección y clasificación en forma independiente y combinada. Los resultados obtenidos indican que es factible identificar el 100% de las personas utilizando estas dos métricas en combinación. *Copyright © 2006*

Key Words: Biometric Recognition, Facial Features, Speaker Recognition, EigenFaces, Cepstral analysis, PCA-eigenfaces, MFCC, Stacked Generalization

1. INTRODUCCIÓN

Los seres humanos poseen una alta capacidad para reconocer rostros y voces aún en escenarios donde existan altos niveles de variabilidad y ruido. Diseñar sistemas automáticos que emulen esta propiedad natural de los humanos, constituye una tarea compleja y con muchas limitaciones. Probablemente una de las primeras interrogantes sea ¿los rostros y voces son diferenciables como medidas biométricas? Afortunadamente en los últimos años se han realizado una gran cantidad de investigaciones que afirman esta interrogante, en especial el área de la biometría.

Los sistemas biométricos se basan en el reconocimiento de patrones (Prabhakar *et al.*, 2003). Un patrón biométrico está compuesto por un conjunto de características fisiológicas y psicológicas que definen un vector asociado unívocamente a una persona. Utilizando esta información, es posible verificar e identificar un vector de características dentro de una base de datos con información de otras personas. La importancia de diseñar un sistema automático depende principalmente del contexto donde se utiliza el reconocimiento. Las aplicaciones

de estos sistemas pueden ir desde intereses gubernamentales, militares, privados o comerciales, hasta las aplicaciones forenses o policiales. Para cada uno de éstas, existe un rango asociado a la tolerancia en la cantidad de falsos positivos (FP) o falsos negativos (FN) que el sistema aceptará. Actualmente un número creciente de organizaciones privadas desean determinar características únicas de sus empleados para ser utilizada en diferentes aspectos, tales como seguridad, identificación y verificación. Según Prabhakar *et al.* (2003), los sistemas biométricos deben cumplir con los siguientes requerimientos para que sean eficientes:

- *Universalidad:* Cada persona debe tener dicha característica que se desea medir.
- *Distintividad:* Las personas deben ser diferenciadas en término de sus características.
- *Permanencia:* La característica debe ser lo suficientemente permanente para permanecer en el tiempo.
- *Colectividad:* La característica debe ser evaluable cuantitativamente. En general, para que los sistemas sean aceptados por las personas, estos deben ser eficientes, confiables y robustos.

El universo de pruebas biométricas es muy amplio y diverso, y los rendimientos tienen una alta variación dependiendo de las aplicaciones donde se prueban. Por este motivo, muchas aplicaciones están diseñadas para un contexto particular, ya que no existe una prueba biométrica con un rendimiento óptimo para todos los contextos (Prabhakar *et al.*, 2003). Algunos sistemas tienen un mejor rendimiento si funcionan en conjunción con otras, es así como la detección de huella digital e iris, tiene un mejor rendimiento respecto a la detección de voz. Este último concepto denominando biometría multimodal ha tenido muy buenos resultados, sin embargo, puede aumentar el costo en tiempo en el procesamiento y en el uso de hardware.

En la actualidad, existen diferentes instrumentos para realizar pruebas biométricas. Desde sensores táctiles de presión para medir las huellas digitales, termografía del cuerpo, verificadores de geometría de la mano, etc. Muchos de estos instrumentos tienen elevados costos para ser aplicados en pequeñas organizaciones. Por este motivo, nuestra investigación tiene como objetivo utilizar el potencial de las cámaras digitales como medio de captura biométrica para imágenes y audio de forma multimodal. Así, se espera identificar personas registradas en una base de datos con información biométrica, utilizando una fotografía digital de sus rostros, y con un segmento de audio único por cada individuo.

Este documento se divide en las siguientes secciones. La sección 2 incluye los antecedentes relacionados los sistemas de reconocimiento de rostro y audio. La sección 3 incluye una descripción del método propuesto. La sección 4 incluye los experimentos y resultados. Finalmente, la sección 5 presenta las conclusiones.

2. ANTECEDENTES

El modelo biométrico propuesto utiliza las características biométricas del rostro y el audio. Según Prabhakar *et al.* (2003), estas medidas son las que tienen la mayor aceptación respecto al reconocimiento de iris, huella digital y palma de la mano; sin embargo, tienen un bajo rendimiento para la identificación. A continuación, se presentan las principales características que fueron analizadas para reconocer el rostro y audio.

2.1 Sistema de reconocimiento del rostro

El análisis del rostro y sus características intrínsecas ha sido un tema de gran interés en estos últimos años, principalmente para determinar las medidas de seguridad en diferentes sistemas. Muchas de las aplicaciones comerciales de la actualidad se pueden encontrar en aeropuertos, hospitales, universidades, empresas privadas, etc. Sin embargo, el problema de

reconocimiento e identificación desde ya es complejo a nivel humano, debido a que no siempre es posible reconocer un rostro desde todas sus posiciones. Valentin (1997), presenta una serie de estudios psicológicos que afirman la divergencia existente en el reconocimiento del rostro para personas que son familiares y los rostros no familiares cuando se encuentran rotados; conteniendo una mayor divergencia en este último caso. Otros estudios psicológicos indican que el reconocimiento del rostro es un proceso dedicado en el cerebro y difiere del reconocimiento de otros objetos. Asimismo, nuestro cerebro percibe con mayor magnitud ciertas partes del rostro, en especial la parte superior (cerca de la nariz), recordando con mayor precisión los rostros que son considerados más atractivos (Zhao *et al.*, 2003). Desde una perspectiva computacional, las diferencias en color, textura, forma y tamaño producen graves problemas para la identificación. En este sentido, ¿es necesario almacenar todas las posiciones de un mismo rostro y generar un rostro canónico, o debemos generar un prototipo de éste para cubrir todas las posibles consultas al sistema? En general, las limitaciones se deben a la alta complejidad de captura y medición que son requeridas para determinar las principales características del rostro (Yang *et al.*, 2002).

Existen tres principales enfoques al problema del reconocimiento del rostro (Yang *et al.*, 2002; Lu, 2003); i) basados en la apariencia, ii) basados en características invariantes, y iii) basados en modelos. En el primer enfoque, existen distintos algoritmos que transforman la imagen digital en un vector de alta dimensión. En muchos casos son utilizadas herramientas estadísticas para transformar la imagen-vector a un nuevo espacio y compararlo respecto a las otras imágenes llevadas con esta misma transformación. Una de las herramientas no supervisadas más utilizadas, en general es PCA (Ruiz-del-Solar & Navarrete, 2005). Este método reduce la dimensionalidad de las imágenes de entrada y conserva aquellas que tengan la mayor cantidad de información (también conocido como técnica de compresión). Los vectores seleccionados, definen un espacio de proyección conocido como *eigenface* sobre las imágenes del entrenamiento. Cuando se requiere identificar una imagen de prueba, se transforma al espacio de proyección y se evalúan las diferencias entre los pesos de entrada y los pesos pertenecientes a las imágenes del entrenamiento. Si la diferencia entre estos es menor a cierto umbral, el rostro es identificado. Otra técnica muy utilizada es IPCA (*Incremental Principal Component Analysis*) (Dagher & Nachar, 2006). Es similar a la técnica PCA, sin embargo, calcula los nuevos vectores propios a medida que se incrementa el número de imágenes en el sistema. Otros algoritmos transforman y dividen la imagen en bloques para buscar partes representativas. El objetivo es recorrer una máscara sobre la imagen e identificar las zonas de ojos, nariz

y boca para determinar sus características (Pinto-Elias & Sossa-Azuela, 1998). El segundo enfoque, está basado en las características invariantes. Para ello utiliza la información intrínseca de la imagen, es decir, el color, la textura, forma y tamaño y sus combinaciones. El objetivo consiste en detectar patrones en la imagen para segmentar él o los rostros contenidos. Muchas veces, es necesaria una transformación a otros espacios como el YCbCr o HSV. En este último caso, es sabido que el color de la piel en otros espacios está contenido en un rango limitado del histograma, por lo tanto, gran parte de éste es segmentado (Padilla & Fan, 2003). El tercer enfoque está basado en la construcción de modelos en dos y tres dimensiones. Para ambos casos, se determinan en forma robusta puntos de control que identifican posiciones específicas del rostro. Estos puntos construyen una estructura topológica utilizando la posición de los ojos, nariz, labios, etc. Luego, se genera iterativamente una alineación y superposición sobre el rostro hasta deformar la estructura no rígida (Lu & Jain, 2005). Lamentablemente esta técnica es muy lenta y requiere la estimación de puntos de control precisos, por lo tanto, la imagen debe estar en una alta calidad. Además, debido al proceso iterativo, puede quedar atrapada en óptimos locales siendo dependiente de la posición de los puntos de control inicialmente seleccionados (Lu, 2003).

Los distintos algoritmos de reconocimiento e identificación del rostro dependen del dominio donde sea aplicado (Yang *et al.*, 2002). No existe un sistema que sea complemente eficaz en todas las condiciones, por este motivo, nuestra investigación se limita a desarrollar una técnica de identificación considerando fija la posición del rostro y única en la imagen.

2.2 Sistema de reconocimiento por voz

El reconocimiento de la voz es el proceso de reconocer automáticamente quién está hablando utilizando la información dada por las ondas de sonido emitidas (Furui, 1981; Doddington, 1985). En general, los sistemas de reconocimiento de voz tiene dos módulos principales: extracción de características y comparación de características. La extracción de características es el proceso por el cual extraemos una pequeña cantidad de datos de la señal de voz que puede ser usada para representar a cada persona. La comparación de características involucra el proceso de identificar a la persona desconocida comparando las características extraídas de su voz, con las previamente obtenidas, que corresponden a las personas conocidas por sistema.

La voz es una señal que varía lentamente en relación al tiempo. Cuando examinamos por un período

suficientemente corto de tiempo (entre 5-100ms), sus características son casi estacionarias. En cambio durante mayores períodos de tiempo (más de 0.2s) las características de la señal cambian para reflejar los diferentes sonidos cuando estamos hablando. Por lo tanto, la forma más natural de caracterizar la señal de voz es mediante un análisis espectral de corto tiempo ("*short-time spectral analysis*"). Una de las técnicas más conocidas en el reconocimiento de la voz, son los *Mel-Frequency Cepstrum Coefficients* (MFCC).

Según Campbell (1997), MFCC es una de las técnicas más aceptadas dentro de los algoritmos de identificación de voz, por lo cual es utilizada en nuestra investigación como método de identificación. Básicamente los MFCC imitan el procesamiento del oído humano en relación a la frecuencia y el ancho de banda. Utilizando filtros diferenciados linealmente en bajas frecuencias y logarítmicamente en altas frecuencias, permite capturar las principales características de la voz. Esto es expresado en la literatura como la escala "*mel-frequency*", la cual es espaciada como lineal debajo de los 1000 Hz y logarítmica sobre los 1000 Hz (Campbell, 1997).

3. MÉTODO PROPUESTO

Empleamos el esquema de reconocimiento de patrones propuesto en Jain *et al.*, (2000) para identificar los rostros y audio en la BD. El objetivo del reconocimiento de patrones es la clasificación de objetos en clases discretas mediante información extraída de los objetos. Para determinar la clasificación, es necesario utilizar un conjunto de fases en secuencia que permitan encontrar una separación óptima entre las clases. En general, las cuatro principales fases de este proceso son: preprocesamiento, extracción de características, selección de características y clasificación. A continuación, detallamos los algoritmos utilizados en cada fase de acuerdo al sistema propuesto en la figura 1.

3.1 Obtención y Preprocesamiento

La BD de rostros pertenece al grupo CVC of Yale University (McDermott, 2006). Contiene 155 imágenes en escala de grises en formato GIF de 15 individuos. De éstas, seleccionamos sólo siete imágenes por sujeto con diferentes expresiones: con lentes, sonriente, normal, triste, sorprendido, gesticulando o dormido. El audio ha sido generado a través del software AT&T Labs (2006), permitiendo elegir entre cinco diferentes acentos, tales como: inglés americano, español, francés, alemán, e inglés británico. Se generaron siete versiones distintas para cada voz, siendo complementarias con las imágenes del rostro.

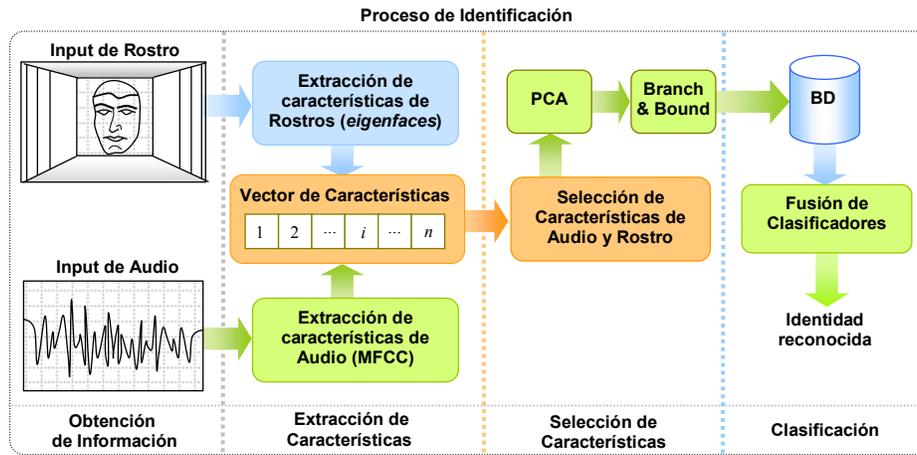


Fig. 1. Proceso de identificación y clasificación de una persona en el sistema.

3.2 Extracción de características

Utilizamos dos algoritmos conocidos en la literatura para extraer características del rostro y audio. Para el rostro, empleamos el algoritmo PCA-*eigenfaces* (Yamgor, 2000). Para el audio, empleamos los MFCC (Campbell, 1997). Ambas técnicas han sido utilizadas en diferentes experimentos de identificación, obteniendo un bajo rendimiento en general para PCA (Dagher & Nachar, 2006), y un rendimiento medio para los MFCC sin combinación (Openshaw *et al.*, 1993). Nuestra hipótesis es que una combinación de estas dos medidas biométricas permitirá aumentar el rendimiento en la identificación de una persona.

3.3 Selección de Características

Desarrollamos un esquema combinado de selección de características. Primero, empleamos el algoritmo PCA para reducir la dimensionalidad del problema debido a la complejidad de la base de datos. Esta herramienta es conocida como una técnica de compresión ya que al reducir la cantidad de atributos, tiene una baja pérdida de información, eliminando los atributos que no tengan una fuerte correlación (Jolliffe, 1986). Segundo, utilizando el conjunto de características anterior, reducimos este número a través del algoritmo Branch & Bound (B&B) (Somol *et al.*, 2004). Básicamente B&B es un algoritmo de búsqueda que tiene por objetivo encontrar la mejor solución en el espacio de combinaciones del problema. Éste realiza una búsqueda exhaustiva y sistemática sobre un espacio de soluciones, el cual es representado como estructura tipo árbol. Nuestra investigación ha utilizado una variante del método básico del B&B. En ella asignamos inicialmente un valor a la variable *bound*, utilizando una combinación de características elegida en forma aleatoria. Adicionalmente, utilizamos el discriminante de Fisher (Duda *et al.*, 2001), para evaluar el rendimiento de cada hijo.

3.4 Algoritmos de Clasificación

El objetivo del clasificador es diseñar una función que clasifique una instancia dentro de muchas clases predefinidas (Jain *et al.*, 2000). En nuestra investigación se emplea la técnica de ensamble de clasificadores. Esta consiste en utilizar distintos algoritmos de clasificación que deciden en conjunto la clase de una instancia (Dzeroski & Zenki, 2000). Existen varias razones que justifican el ensamble de clasificadores. Algunas de éstas, son por ejemplo: i) los datos para el entrenamiento pueden no proveer suficiente información para elegir un único mejor clasificador, debido a que el tamaño disponible en estos datos es pequeño en comparación al espacio de hipótesis (Dietterich, 2000); ii) la combinación redundante y complementaria de clasificadores mejora la robustez, exactitud y generalidad de toda la clasificación (Kotsiantis & Pintelas, 2004); iii) diferentes clasificadores utilizan diferentes técnicas y métodos de representación de los datos, lo que permite obtener resultados de clasificación con diferentes patrones de generalización; iv) los ensambles son frecuentemente mucho más exactos que los clasificadores individuales (Dzeroski & Zenki, 2000).

Uno de los métodos existentes para la construcción de ensambles es el método *Stacked Generalization*, conocido también como *Stacking*. Este método combina varios clasificadores para inducir un clasificador de nivel más alto, con un incremento en el rendimiento (Ting & Witten, 1999). Este algoritmo de aprendizaje trata estos datos como otro problema, y la salida que genera es la predicción final del ensamble. Dentro de los clasificadores utilizados para la fusión, utilizamos los siguientes cinco algoritmos: Redes Bayesianas (BN) (Heckerman *et al.*, 1995); Naive Bayes (NB) (Singh & Provan, 1995); *k*-Vecinos Cercanos (*k*-NN) (Jain *et al.*, 2000); Redes Neuronales (RN) (Verma, 1997) y Árboles de decisión J4.8 (Ding & Perrizo, 2002).



Fig. 2. BD de imágenes compuesta por 15 individuos con siete diferentes expresiones faciales o configuración con lentes, sorprendido, gesticulando, sonriente, normal, triste o dormido (McDermott, 2006).

4. EXPERIMENTOS Y RESULTADOS

Nuestra fase experimental fue dividida en tres análisis independientes. Primero, se seleccionaron las diez mejores características del audio; Segundo se seleccionaron las diez mejores características del rostro; y Tercero, se seleccionan las cinco mejores características del audio y del rostro, para luego combinarlas en una única BD con un total de diez características. Estas últimas no necesariamente pertenecen a los datos contenidos en las dos primeras bases de datos. El propósito de esta separación, es medir el rendimiento individual de cada una de estas medidas biométricas, y su análisis combinado.

En la fase de clasificación se utilizaron los cinco clasificadores en forma independiente para determinar el rendimiento individual. Luego se utilizó el método *Stacking* y *Vote*, descrito anteriormente, para determinar si existen cambios en el rendimiento con las técnicas de fusión. Para evaluar el rendimiento de los clasificadores, se empleó el método de selección de datos *k-cross validation* (Mitchel, 1997). En particular, utilizamos este algoritmo con $k=10$ (Fig. 3).

Inicialmente se evaluó el rendimiento individual de los cinco clasificadores del estudio (NB, BN, RN, k -NN y J4.8) (ver Tabla 1). Posteriormente se generaron dos grupos de fusión. El primero utiliza cinco clasificadores mencionados anteriormente; el segundo sólo utiliza los clasificadores NB, k -NN y J4.8. (ver Tabla 2).

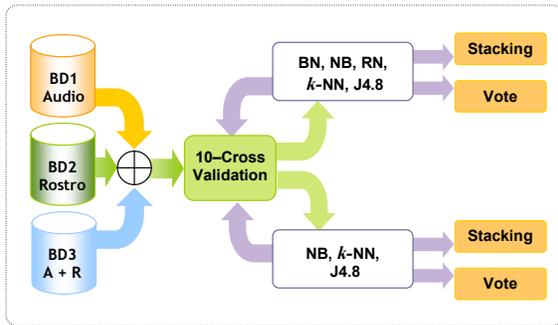


Fig. 3. Esquema de clasificación en las tres BD generadas con variación en la selección de características, y selección individual de las mejores características.

Los resultados de los clasificadores sin técnicas de fusión son adecuados, en especial cuando se usan las RN (Tabla 1). En el caso del audio, estos rendimientos se deben a la baja varianza entre las distintas versiones del audio para un mismo individuo. Respecto al rostro, los rendimientos son cercanos al 90%, sin embargo, cuando se utiliza la combinación de audio y rostro, vemos que las RN alcanzan el 100%.

Tabla 1. Rendimiento de los cinco clasificadores empleados sobre la selección rotativa con método *k-cross-validation* ($k=10$).

Database	Naive Bayes	Bayes Net	Neural Net	k -NN (5)	Tree J4.8
BD1. Audio	99.1	91.5	100	97.2	81.7
BD2. Rostro	88.5	84.8	90.4	88.6	84.5
BD3. A+R	98.1	84.7	100	88.6	84.5

Dentro de los dos grupos de clasificadores utilizados, observamos que el rendimiento obtenido es el mismo, aunque no utilizemos las RN (tabla 2). No obstante, la BD de audio y rostro no alcanza con ninguna de las dos técnicas de fusión (*Stacking* o *Vote*) un rendimiento óptimo. También destacamos que el rendimiento del rostro se ha incrementado a 92.3%, respecto a 90.4% de las RN sin fusión. Esto implica que efectivamente que las técnicas de fusión permiten incrementar el rendimiento de los clasificadores si son utilizados en combinación.

Tabla 2. Rendimiento de los clasificadores fusionados con las técnicas de *Stacking* y *Vote* con dos grupos de fusión de clasificadores con método *k-cross validation* ($k=10$).

Grupos de fusión	RN+BN+NB k -NN (5)+J4.8		NB+ k -NN (5) +J4.8	
	<i>Stacking</i>	<i>Vote</i>	<i>Stacking</i>	<i>Vote</i>
BD1. Audio	98.1	100	98.1	99.1
BD2. Rostro	87.5	92.3	90.4	92.3
BD3. A+R	98.1	99	99	99

5. CONCLUSIONES

Esta investigación presenta el desarrollo de la metodología de reconocimiento de patrones aplicado al reconocimiento biométrico de audio y rostro. Los resultados demuestran que un sistema biométrico de audio y rostro es viable, principalmente porque los

algoritmos de extracción de características como PCA-*eigenfaces* y MFCC han demostrado ser efectivos en identificar una persona si son utilizados en combinación. No obstante, se debe considerar algunas limitantes antes de diseñar este tipo de sistemas. La detección de rostros tiene una alta variabilidad frente a diferentes condiciones de luz y posición. Por este motivo, los sistemas biométricos requieren mantener algunas condiciones controladas. Estas mínimas condiciones deben ser cumplidas por todos los usuarios, ya que evitan aumentar la complejidad y tiempo de procesamiento necesario para el reconocimiento biométrico. Como trabajo futuro resta utilizar bases de datos de rostro y audio con una mayor cantidad de individuos. Adicionalmente los efectos de emplear otros métodos de selección de características y diferentes números de atributos de audio y rostro combinados.

6. REFERENCIAS

- AT&T Labs Inc., R. (2006). "Text-to-Speech (TTS)." Retrieved July, 2006, 2006, from <http://www.research.att.com/~ttsweb/tts/demo.php>.
- Campbell, J. P. (1997). *Speaker Recognition: A Tutorial*. Proc. of the IEEE.
- Campbell Jr., J. P. (1997). *Speaker Recognition: A Tutorial*. Proc. of the IEEE.
- Dagher, I. and R. Nachar (2006). "Face Recognition Using IPCA-ICA Algorithm." *IEEE Trans. Pattern on Analysis and Machine Intelligence* **28**(6): 996-1000.
- Dietterich, T. G. (2000). Ensemble Methods in Machine Learning. *First International Workshop on Multiple Classifier Systems*. I. J. K. a. F. Roli, New York: Springer Verlag. **1857**: 1-15.
- Ding, Q. and W. Perrizo (2002). *Decision Tree Classification of Spatial Data Streams Using Peano Count Trees*. Proc. of the ACM 124 Symposium on Applied Computing, Madrid, Spain.
- Doddington, G. R. (1985). *Speaker Recognition – Identifying people by their Voices*. Proc. of the IEEE.
- Duda, R. O., P. E. Hart and D. G. Stork (2001). *Pattern Classification* (Second), John Wiley & Sons, Inc., New York.
- Dzeroski, S. and B. Zenki (2000). "Is Combining Classifiers Better than Selecting the Best One." *International Conference on Machine Learning (ICML)*: 123-130.
- Furui, S. (1981). "Cepstral analysis technique for automatic speaker verification." *IEEE Transactions on acoustic, speech and signal processing* **29**(2): 254-277.
- Heckerman, D., D. M. Chickering and D. Geiger (1995). "Learning bayesian networks, the combination of knowledge and statistical data." *Machine learning* **20**(3): 197-243.
- Jain, A. K., R. P. Duin and J. Mao (2000). "Statistical Pattern Recognition: A Review." *IEEE Transactions on Pattern Analysis and Machine Intelligence* **22**(1).
- Jolliffe, I. T. (1986). *Principal component analysis*, Springer - Verlag, New York.
- Kotsiantis, S. and P. Pintelas (2004). "Selective Voting." *IEEE 4th International Conference on Intelligent Systems Design and Applications (ISDA)*: 397-402.
- Lu, X. (2003). "Image Analysis for Face Recognition: a brief survey." *Dept. of Computer Science & Engineering, Michigan State University, East Lansing*.
- Lu, X. and A. K. Jain (2005). *Deformation Analysis for 3D Face Matching*. Proc. 7th IEEE Workshop on Applications of Computer Vision WACV.
- McDermott, D. (2006). "The Yale Face Database. Center for Computational Vision and Control (CVC) at Yale University." Retrieved July, 2006, 2006, from <http://cvc.yale.edu/projects/yalefaces/yalefaces.html>.
- Mitchel, T. M. (1997). *Machine Learning*, McGraw-Hill, Boston.
- Openshaw, J. P., Z. P. Sun and J. S. Mason (1993). *A comparison of composite features under degraded speech in speaker recognition*. Proc. of the IEEE international conference on acoustics, speech and signal processing.
- Padilla, M. and Z. Fan (2003). Digital Image Processing Project-Automatic Face Detection Using Color Based Segmentation and Template/Energy Thresholding, Department of Electrical Engineering, Stanford University.
- Pinto-Elias, R. and J. H. Sossa-Azuela (1998). "Automatic facial feature detection and location." *IEEE Pattern Recognition, Proceedings. Fourteenth International Conference 2*: 1360-1364.
- Prabhakar, S., S. Pankati and A. K. Jain (2003). *Biometric Recognition: Security and Privacy concerns*. Proc. of the IEEE Security and Privacy.
- Ruiz-del-Solar, J. and P. Navarrete (2005). "Eigenspace-based Face Recognition: A comparative study of different approaches." *IEEE Trans. on Systems, Man and Cybernetics* **16**(7): 817-830.
- Singh, M. and G. M. Provan (1995). Efficient Learning of Selective Bayesian Network Classifier. *International Conference on Machine Learning*. Philadelphia, PA., Computer and Information Science Department, University of Pennsylvania.
- Somol, P., P. Pudil and J. Kittler (2004). "Fast Branch & Bound Algorithms for optimal Feature Selection." *IEEE Transactions on Pattern Analysis and Machine Intelligence* **26**(7): 900-912.
- Ting, K. M. and I. H. Witten (1999). "Issues in stacked generalization." *Journal of Artificial Intelligence Research* **10**: 271-289.
- Valentin, D., H. Abdi and B. Edelman (1997). "What represents a face: A computational approach for the integration of physiological and psychological data." *Perception* **26**: 1271-1288.
- Verma, B. K. (1997). "Fast Training of Multilayer Perceptrons (MLPs)." *IEEE Transactions on Neural Networks* **8**(6): 1314-1321.
- Yambor, W. S. (2000). Analysis of PCA-based and fisher discriminant-based image recognition algorithms. *Computer Science Department*. Fort Collins, Colorado, Colorado State University. **Master of Science**.
- Yang, M.-H., D. J. Kriegman and N. Ahuja (2002). "Detecting Faces in Images: A Survey." *IEEE Trans. on Pattern Analysis and Machine Intelligence* **24**(1): 34-58.
- Zhao, W., R. Chellappa, A. Rosenfeld and P. J. Phillips (2003). Face Recognition: A Literature Survey. *UMD CfAR Technical Report CAR-TR-948*.