

# Reconocimiento y Clasificación Dinámica de Firmas con Algoritmos de Visión

Teodoro Schmidt Flores<sup>1</sup> Vladimir Riffo Bouffanais<sup>1</sup>

Domingo Mery Quiroz<sup>1</sup> Billy Peralta Márquez<sup>1</sup>

<sup>1</sup> Pontificia Universidad Católica de Chile, PUC.

theo@uc.cl, vriffo1@uc.cl, dmery@ing.puc.cl, bmperalt@uc.cl

## Resumen

Este documento presenta un enfoque novedoso al reconocimiento de firmas, proponiendo el uso de algoritmos de reconocimiento de caras para obtener descriptores por clase y un clasificador que reconoce la firma del individuo. La propuesta presentada detecta dinámicamente la geometría y sentido de firma, aplicando una transformación lineal que lleva la representación de datos a escala de grises, procesando las imágenes mediante análisis de componentes principales (PCA) y análisis de discriminador lineal (LDA), determinando así descriptores homólogos a EigenFaces y FisherFaces, los que denominaremos EigenSignatures y FisherSignatures. Estos descriptores son analizados con un clasificador de *vecinos cercanos*. Los resultados experimentales revelan que la mejor tasa de desempeño se obtiene utilizando FisherSignatures, con un valor de 94% de rendimiento. Nuestra propuesta permite almacenar información adicional a la geometría, esto es el *sentido de firma*, robusteciendo el reconocimiento de éstas a través de la extracción de un nuevo tipo de característica (*feature*), aplicando transformaciones que permiten el tratamiento de datos como imagen en escala de grises.

*Keywords-signature recognition; on-line signatures; off-line signatures; eigensignatures; fishersignatures.*

## 1. Introducción

En el mundo moderno la interacción entre individuos se hace cada vez más imperiosa, desde el punto de vista comercial, y hasta en las acciones más rutinarias de la vida diaria. Esto refuerza la necesidad de certificar la veracidad de los entes involucrados en una transacción cualquiera. Así, en general existen dos estrategias de reconocimiento biométrico: uno basado en características fisiológicas y otro basado en características conductuales (A.K. Jain, A. Ross, y S. Prabhakar, 2004; S. Prabhakar, S. Pankanti, y A.K. Jain, 2003). Dentro de este último, la firma destaca por su gran aceptación social y su relativo bajo costo de implementación (M. Faundez-Zanuy, 2007). Actualmente, el marco regulatorio legal de gran parte de los países permite el uso de la firma como elemento discriminador e identificador de sujetos frente a la realización de transacciones de toda índole. Así, la correcta identificación del individuo es crucial para garantizar la idoneidad de la transacción (G. Agam y S. Suresh, 2007).

Este trabajo consiste en analizar, de alguna forma, la manera en que un individuo cualquiera estampa un registro gráfico único y reiterativo, conocido como *firma*, para luego poder determinar si el individuo en cuestión corresponde a la persona que dice ser, contrastando el análisis del registro gráfico frente a los resultados de un proceso de entrenamiento previo. Dada su importancia, la firma está sujeta a gran cantidad de formas de falsificación. Frente a esto, los sistemas automáticos de reconocimiento de firmas se encuentran con dos problemas principales: por una parte identificar las características intrínsecas de la firma en cuestión, como son extracción y análisis de características gráficas, proceso conocido como análisis *estático off-line*, y por otra parte la identificación de características grafológicas del individuo que firma, como son identificación de patrones únicos de movimientos manuales, velocidad, ángulo y sentido (dirección) de escritura, todos estos conocidos bajo el contexto de análisis *dinámico on-line* (B. Jayasekara, A. Jayasiri, y L. Udawatta, 2006). La problemática de identificación de personas por tanto radica en buscar algoritmos eficientes, e idealmente en tiempo real, para la identificación de las

características tanto estáticas como dinámicas de la firma y del individuo que la realiza. Finalmente, los resultados de dichos análisis en tiempo real deben ser contrastados contra una base de conocimientos de individuos, generada previamente, con el objeto de identificar positiva o negativamente al sujeto.

Este documento está organizado de la siguiente manera: la sección II detalla un estado del arte de las investigaciones actuales referentes a reconocimiento de firmas. La sección III detalla el método propuesto, basándose en el análisis de componentes principales y análisis de discriminante lineal. En esta misma sección se detallan las ecuaciones utilizadas para representar el *sentido de firma*. En la sección IV se presenta el desarrollo experimental, incluido un análisis de los resultados obtenidos. Finalmente, en la sección V se presentan las conclusiones y alcances del presente documento y se analizan los trabajos futuros de la presente investigación.

## 2. Trabajos Previos

Las investigaciones actuales han tomado dos ramas que, a pesar de traslaparse en ocasiones, son perfectamente identificables (M. Faundez-Zanuy, 2005): por un lado están las investigaciones relacionadas con el análisis de componentes dinámicos, relativos a la evolución en el dominio del tiempo de los parámetros propios del proceso de firmar, y por otra parte existe el análisis de componentes estáticos, propios de las características de la firma en cuestión. Dentro de los primeros, destacan los trabajos sobre *Dynamic Time Warping* (M. Faundez-Zanuy, 2007; C. Vivaracho-Pascual, M. Faundez-Zanuy, y J.M. Pascual, 2009), para el ajuste dinámico del largo de la firma, así como el uso de *Hidden Markov Models*, para el análisis dinámico de la estructura de la firma. El uso de teoría probabilística se manifiesta a través del uso de *Support Vector Machines* (E. Frias-Martinez, A. Sanchez, y J. Velez, 2006) y *Perceptrones Multicapa*. En este contexto, los análisis de Lógica Difusa robustecen los perceptrones multicapa (B. Jayasekara, A. Jayasiri, y L. Udawatta, 2006). Particularmente este último trabajo propone utilizar también Algoritmos Genéticos para la etapa de pruebas. En la segunda rama de investigación, relativa al análisis estático, destaca el trabajo de utilización de Momentos de Hu como entrada, *input*, de Redes Neuronales (C. Oz, 2005). En esta misma línea también se utiliza el Análisis de Componentes Principales como entrada para el análisis con Redes Neuronales (B. Erkmén, N. Kahraman, R. Vural, y T. Yildirim, 2008). Finalmente, existen propuestas de algoritmos probabilísticos para el reconocimiento estático de firmas (M.A. Ismail y S. Gad, 2000), así como también la extracción de descriptores locales sobre las firmas utilizando el algoritmo SIFT, intentando a su vez encontrar puntos invariantes que puedan ser pareados (J. Ruiz-del-Solar, C. Devia, P. Loncomilla, y F. Concha, 2008). En particular, los resultados obtenidos de esta última técnica la sitúan como complementaria de algún otro modelo más robusto.

Tradicionalmente los métodos de reconocimiento basados en correlación requieren de grandes capacidades de almacenamiento y poseen un alto costo computacional, en términos de ciclos de CPU, lo que implica buscar esquemas que permitan reducir el tiempo de cómputo así como los requerimientos de espacio (P. Belhumeur, J. Hespanha, y D. Kriegman, 1997). Dentro de las técnicas algorítmicas comúnmente utilizadas en visión por computador, particularmente para el reconocimiento de caras, destacan el Análisis de Componentes Principales (PCA) (M. Turk y A. Pentland, 1991; M. Turk y A. Pentland, 1991), y el Análisis de Discriminador Lineal (LDA). La técnica PCA, también conocida como método de Karhunen-Loeve, cambia la dimensionalidad del problema reduciendo la proyección lineal que maximiza la dispersión de todas las muestras proyectadas. De esta forma, PCA transforma las variables

correlacionadas en un pequeño número de variables no correlacionadas, a través de los vectores y valores propios. Una implementación exitosa es la extracción características basada en análisis de componentes principales para el reconocimiento de rostros, conocida como EigenFaces. Sobre el mismo contexto, el discriminante lineal LDA es una proyección sobre otro espacio, que provoca la disminución de la varianza intra-clase. Una implementación exitosa es la extracción de características en base al determinante de Fisher, conocida como algoritmo de FisherFaces. Estos métodos se explicarán en detalle en la sección III.

### 3. Método Propuesto

Como ya se ha mencionado, la acción de firmar es única y exclusiva para cada individuo, lo que reafirma la teoría de que una firma cualquiera posee características intrínsecas únicas propias del individuo que la generó. Esto se funda en la existencia de las características dinámicas del proceso de firma, como son velocidad y sentido (dirección) de la acción de firmar (M. Faundez-Zanuy, 2007; C. Vivaracho-Pascual, M. Faundez-Zanuy, y J.M. Pascual, 2009). Dado lo anterior, se hace prácticamente imposible poder replicar las características estáticas (C. Oz, 2005; B. Erkmen, N. Kahraman, R. Vural, y T. Yildirim, 2008; M.A. Ismail y S. Gad, 2000) y dinámicas de otro individuo al firmar, ni siquiera aprendiendo el *sentido de firma* u observando al sujeto generador de la firma.

Nuestra hipótesis plantea que es posible reconocer al sujeto emisor de una firma mediante la utilización de algoritmos propios del reconocimiento de caras. Nuestro modelo plantea, como propuesta novedosa, la adquisición dinámica de firmas y el posterior análisis estático de los vectores de características, propios de ellas. Estos serán denominados EigenSignatures y FisherSignatures, por sus homólogos EigenFaces y FisherFaces, y corresponderán al análisis de componentes principales y de discriminador lineal. El sistema de reconocimiento de firmas propuesto se muestra de manera esquemática en la siguiente figura:

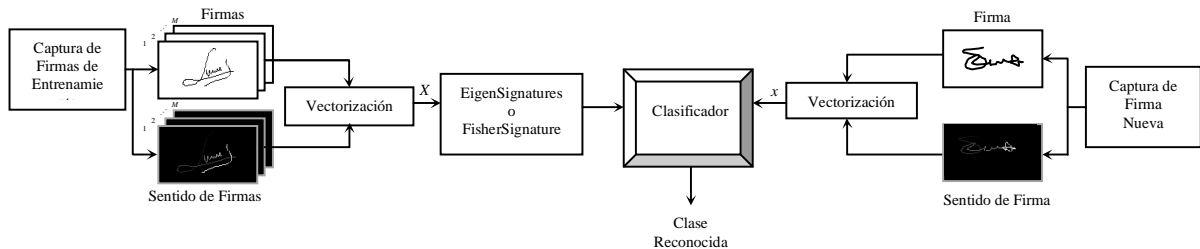


Figura 1: Sistema de reconocimiento de firmas.

### 4. Experimentos y Resultados

La presente sección detalla en profundidad los aspectos teóricos que permiten la implementación de EigenSignatures y FisherSignatures, en particular se hace referencia al extractor de características y al clasificador.

#### *Método EigenSignatures*

*Extracción de Características:* Nuestra propuesta de reconocimiento de firmas consiste en la proyección lineal de las imágenes a un espacio de baja dimensionalidad. Para realizar el cálculo de las EigenSignatures se asume conocido el conjunto de imágenes de firmas por clase  $\{I_j(x, y), j = 1, 2, \dots, M\}$ , donde cada  $I_j$  es una matriz de intensidades de orden  $N = m \times n$ , las cuales son vectorizadas y

denominadas como  $x_j, j = 1, 2, \dots, M$ . Se asume que  $N$  y  $M$  son los mismos para todas las imágenes y clases, respectivamente.

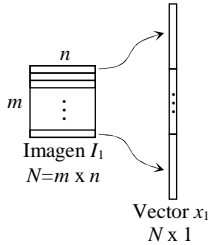


Figura 2: Vectorización de imagen.

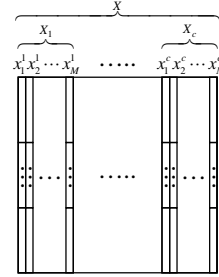


Figura 3: Formación del conjunto de entrenamiento.

Cada  $x_j$  resultante es de orden  $N \times 1$ . Luego, las imágenes de entrenamiento, concatenadas horizontalmente para la clase  $k$ , se denotan como  $X_k = [x_1^k x_2^k \dots x_M^k]$ ,  $k = 1, 2, \dots, c$ .

De esta forma, el resultado de todo el conjunto de entrenamiento vectorizado y concatenado horizontalmente es representado como  $X = [X_1 X_2 \dots X_c]$ , y escrito en detalle  $X = [x_1^1 x_2^1 \dots x_M^1 x_1^2 x_2^2 \dots x_M^2 \dots x_1^c x_2^c \dots x_M^c]$ , donde  $x_j^k$  es la imagen vectorizada  $j$  de la clase  $k$ .

El promedio de las firmas por clase, o *promedio intra-clase*, está dado por:

$$\mu_k = \frac{1}{M} \sum_{j=1}^M x_j^k, \quad k = 1, 2, \dots, c \quad (1)$$

El promedio total del conjunto de entrenamiento, o *promedio inter-classes*, está dado por:

$$\mu = \frac{1}{(M \times c)} \sum_{k=1}^c \sum_{j=1}^M x_j^k \quad (2)$$

Si se considera que todas las imágenes vectorizadas del conjunto de entrenamiento están concatenadas horizontalmente, se tendrá que  $X$  es de orden  $N \times D$ , con  $D = M \times c$ .

La diferencia entre cada imagen y el promedio *inter-clase*, se representa mediante la matriz  $A = [A_1 A_2 \dots A_D]$ , en donde cada  $A_d, d = 1, 2, \dots, D$ , se determina como:

$$A_d = x_j^k - \mu, \quad d = 1, 2, \dots, D. \quad (3)$$

así,

$$A = X - \mu \quad (4)$$

Se define  $S_T$ , como la matriz de covarianza:

$$S_T = AA^T \quad (5)$$

Se deben determinar los vectores propios  $u_i$  de  $AA^T$ . Considerando que  $A$  es de orden  $N \times D$ , se vuelve impracticable la búsqueda de  $S_T$ , dado su alto costo computacional al ser de orden  $N \times N$ . Para

soslayar lo anterior se deben encontrar los vectores propios  $v_i$  de  $A^T A$ , cuyo resultado es una matriz de orden  $D \times D$ . Entonces se tiene que:

$$A^T A v_i = \lambda_i v_i, \quad i = 1, 2, \dots, D \quad (6)$$

donde  $\lambda_i$  son los valores propios. Multiplicando por  $A$  ambos lados de la ecuación anterior, se tiene:

$$A A^T A v_i = \lambda_i A v_i \quad (7)$$

Desde la cual se observa que  $A v_i$  son los vectores propios de  $S_T = A A^T$ . Así,  $A A^T$  y  $A^T A$  tiene los mismos valores propios  $\lambda_i$  y sus vectores propios están relacionados como sigue:

$$u_i = A v_i \quad (8)$$

Para encontrar los vectores propios  $v_i$  se utiliza el método de Jacobi (V. Hari, 2005). Los  $v_i$  son ordenados de mayor a menor siguiendo el ordenamiento de los valores propios  $\lambda_i$ .

Los vectores propios  $u_i$  de  $A A^T$  obtenidos son de orden  $N \times 1$  y cada uno de ellos corresponde a una EigenSignature. Todos los  $u_i$  deben ser normalizados, de tal forma que  $\|u_i\| = 1$ . Todos los vectores propios  $u_i$  son concatenados horizontalmente para formar una matriz  $U$  de orden  $N \times D$ . entonces  $U = [u_1 \ u_2 \ \dots \ u_i] , i = 1, 2, \dots, D$ .

En PCA, la matriz  $W_E$  de proyección de las EigenSignatures queda definida como:

$$W_E = U^T A \quad (9)$$

**Clasificador:** Para reconocer una nueva imagen se utiliza un clasificador simple de vecinos más cercanos, con distancia euclidiana, y se busca, de entre todo el espacio, el vecino más cercano ( $K = 1$ ), siguiendo los pasos:

- a.- La nueva imagen  $I$  que forma parte del conjunto de prueba, debe ser vectorizada, quedando definida como  $x$ , de orden  $N \times 1$ . Se debe considerar que  $N = m \times n$ , es decir la o las imágenes de prueba deben ser de igual tamaño que las imágenes utilizadas en el proceso de extracción de características.
- b.- Se calcula  $A_2$  a partir del promedio inter-clase  $\mu$  obtenido en la extracción de características y la imagen vectorizada  $x$ , mediante:  $A_2 = x - \mu$ , siendo  $A_2$  un vector de orden  $N \times 1$ .
- c.- Se determina la proyección PCA, utilizando  $U$  obtenido en la extracción de características:  $W_p = U^T A_2$ .
- d.- Se determina la distancia euclidiana desde  $W_E$  a  $W_p$  mediante  $disEu = \sqrt{\sum |W_E - W_p|^2}$ , donde  $disEu$  corresponde a un vector desde el cual se extrae la menor distancia y se determina a que clase corresponde.

### **Método FisherSignatures**

**Extracción de Características:** La representación Fisher produce una mejor discriminación entre clases, preservando al mismo tiempo la propiedad de baja discriminación de la representación Eigen dentro de cada clase (S. Lakshmanan, P. Watta, Yu Lin Hou, y N. Gandhi, 2001). También se considera que Fisher es la aplicación del análisis de discriminante lineal (LDA) sobre el espacio generado por PCA (P. Belhumeur, J. Hespanha, y D. Kriegman, 1997; S. Lakshmanan, P. Watta, Yu Lin Hou, y N. Gandhi, 2001; M. Sharkas y M. Elenien, 2008).

En FisherSignatures se utiliza el modelo matemático desarrollado en EigenSignatures para la obtención de  $U$  la cual corresponde al conjunto de los vectores propios o EigenSignatures agrupadas. Sin embargo y debido a la dimensionalidad de  $U$ , que provoca un alto costo computacional en el cálculo posterior de dispersiones, *inter-clases* e *intra-clase*, es que se hace necesario reducir la dimensionalidad de  $U$  al valor de  $N \times D_p$ ,  $D_p = (M \cdot c) - c$ , quedando de esta manera definido como  $W_{pca}$ , el que corresponde a  $U$  con dimensionalidad reducida. La proyección de los datos en espacio PCA reducido será:

$$W_{EF} = W_{pca}^T X \quad (10)$$

así,  $W_{EF}$  quedará de orden  $D_p \times D$ . Entonces, el promedio *intra-clase* está dado por:

$$\mu_k = \frac{1}{M} \sum_{j=1}^M w_j^k, \quad k = 1, 2, \dots, c \quad (11)$$

El promedio *inter-clases* está dado por:

$$\mu = \frac{1}{(M \times c)} \sum_{k=1}^c \sum_j^M w_j^k \quad (12)$$

donde,  $w_j^k$  es la imagen (vectorizada) proyectada  $j$  de la clase  $k$ . La matriz de *dispersión inter-clases* se determina:

$$S_B = \sum_{k=1}^c (\mu_k - \mu)(\mu_k - \mu)^T \quad (13)$$

y la matriz de *dispersión intra-clase* se determina como:

$$S_W = \sum_{k=1}^c \sum_{j=1}^M (w_j^k - \mu)(w_j^k - \mu)^T \quad (14)$$

$S_B$  y  $S_W$  son matrices cuadradas de orden  $D_p \times D_p$ .

Al igual que en el caso de las EigenSignatures en FisherSignatures se deben determinar los vectores propios  $W_{fld}$  y valores propios  $\lambda$ , de manera que se cumpla la igualdad  $S_B W_{fld} = S_W W_{fld} \lambda$ . Así se obtienen las FisherSignatures:

$$P = W_{pca} W_{fld} \quad (15)$$

En LDA, la matriz  $W_E$  de proyección de las FisherSignatures queda definida como:

$$W_E = P^T A \quad (16)$$

*Clasificador:* En este caso el clasificador también es  $K$ -NN con distancia euclidiana y  $K = 1$ , similar al utilizado en EigenSignatures, y se deben seguir los siguientes pasos:

a.- La nueva imagen  $I$  que forma parte del conjunto de prueba, debe ser vectorizada, quedando definida como  $x$ , de orden  $N \times 1$ . Se debe considerar que  $N = m \times n$ , es decir las imágenes de prueba deben ser de igual tamaño que las imágenes utilizadas en el proceso de extracción de características.

- b.- Se calcula  $A_2$  a partir del promedio inter-clase  $\mu$ , obtenido en la extracción de características, ec. (2), y la imagen vectorizada  $x$ , mediante:  $A_2 = x - \mu$ , siendo  $A_2$  un vector de orden  $N \times 1$ .
- c.- Se determina la proyección LDA, utilizando  $P$  obtenido en la extracción de características:  $W_p = P^T A_2$ .
- d.- Se determina la distancia euclidiana desde  $W_E$  a  $W_p$  mediante  $disEu = \sqrt{\sum |W_E - W_p|^2}$ , donde  $disEu$  corresponde a un vector desde el cual se extrae la menor distancia y se determina a que clase corresponde.

### Sentido de Firma

Sea  $P(u,v)$  el vector de coordenadas de imagen, que representa a una firma en el orden en que fue escrita, esto es:

$$P(u,v) = p_1(u_1, v_1), p_2(u_2, v_2), \dots, p_i(u_i, v_i), \dots, p_n(u_n, v_n) \quad (17)$$

Donde,  $p_1(u_1, v_1)$  corresponde al primer pixel escrito, y  $p_n(u_n, v_n)$  al último, es decir  $i$  representa la posición cardinal en el vector  $P(u, v)$ , con  $1 \leq i \leq n$ . Se considera que:

$$p_i(u_i, v_i) = p_i = 0 \quad ; 1 \leq i \leq n \quad (18)$$

Es decir, la firma original, escrita sobre un fondo blanco, tendrá un valor de intensidad de cero, correspondiente al negro, tal como se muestra en la figura 4.

Para mostrar de manera visual el sentido o dirección de la firma, se utiliza una transformación lineal (Figura 5).

A cada pixel  $p_i$  del vector  $P$  le corresponde un nivel de gris  $I$  dado por la ecuación de la recta:

$$I = \frac{0.9i + 0.1n - 1}{n - 1} \quad (19)$$

El valor de gris para el primer pixel  $p_1$  será 0.1, esto para diferenciarlo del fondo, el cual tiene valor cero, negro. De igual manera el valor de gris para el último pixel de la firma será 1, que corresponde al blanco. El efecto de la transformación descrita se muestra en la Figura 6.

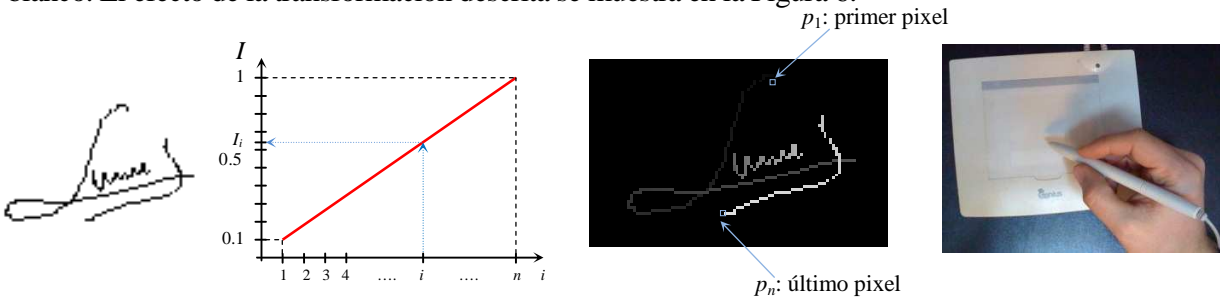


Figura 4: Firma.

Figura 5: Transformación  $p_i$ .

Figura 6: Sentido de escritura.

Figura 7: Captura.

## 5. Discusión de los Experimentos

Para este trabajo se creó la base de firmas reales SRM-SDB (*SchmidtRiffoMery-SignatureDataBase*), de 45 personas distintas, cada una de  $102 \times 64$  pixeles de tamaño y 8 bit de resolución. La base de datos SRM-SDB es de carácter experimental y está formada por 45 clases, con 10 imágenes por clase, todas ellas en escala de grises.

### Captura de Firmas

Para crear la base de datos de firmas se utilizó un dispositivo tablet, marca Genius, modelo EasyPen I (Fig. 7).

Como se mencionó anteriormente, en el desarrollo de este trabajo se implementó un algoritmo que permite establecer el sentido con la cual fue dibujada la firma, es decir las firmas capturadas quedan en escala de gris y su tonalidad varía desde 0,1 (prox. al negro) hasta 1 (blanco).




Figura 8: Firma por clase en nivel de gris original.



Figura 9: Firmas después de la transformación.

Lo anterior, por si solo constituye una implementación algorítmica para la extracción de un nuevo tipo de característica (*feature*), propia y única de cada firma, que permite hacer un reconocimiento visual y comparativo del orden en el cual fue dibujada la firma. Según se evidenció durante la creación de nuestra base de firmas SRM-SDB, una persona siempre realiza la firma en el mismo orden.

### EigenSignatures y Fishersignatures

Las imágenes resultantes de la aplicación de los algoritmos de EigenSignatures y FisherSignatures son particularmente complejas en términos visuales, ya que por sí solas no entregan información aparente. Son ponderadores que permiten hacer la proyección al espacio PCA y LDA, respectivamente.




Figura 9: FisherSignatures.

Iter.1	Iter.2	Iter.3	Iter.4	Iter.5	Iter.6	Iter.7	Iter.8	Iter.9	Iter.10
10%									
	10%								
		10%							
			10%						
				10%					
					10%				
						10%			
							10%		
								10%	
									10%

Figura 10: Validación Cruzada: 10% test y 90% clasificador.

En la representación de las FisherSignatures se ven formas semejantes a firmas en distintos niveles de gris, Figura 9. Fisher maximiza la dispersión inter-classes y minimiza la dispersión intra-clase.

### Desempeño para EigenSignatures

En esta etapa se muestran los resultados de desempeños, caracterizados por los porcentajes de aciertos del clasificador EigenSignatures, evaluando su rendimiento mediante *validación cruzada estratificada*, la cual consiste en realizar un número determinado de Iteraciones (un total de 10) y en cada una de ellas



hacer un análisis de desempeño, considerando el 10% de los datos para test y el 90% para el diseño del clasificador. En cada Iteración se seleccionan distintos conjuntos de prueba.

La estratificación asegura representatividad de cada clase en los conjuntos de prueba, es decir, en este conjunto (de prueba) deben estar representadas en igual número todas las clases disponibles, de tal forma que al evaluar el clasificador diseñado para esa iteración, sean consideradas todas las posibles opciones de clasificación. El desempeño total del clasificador será el promedio de los diez desempeños obtenidos. Los promedios de desempeño se muestran en la Tabla I.

### Desempeño para FisherSignatures

Fishersignatures hace uso de PCA, mejorando el desempeño de un clasificador, incorporando LDA. Esto se traduce en proyectar los datos en otro espacio, disminuyendo la dispersión *intra-clase* y aumentando la *interclase*.

Base de Datos	Promedio de Desempeño EigenSignatures
	Cross-Validation [%]
SRM-SDB	49 %

Tabla I. Desempeños EigenSignatures

Base de Datos	Promedio de Desempeño FisherSignatures
	Cross-Validation [%]
SRM-SDB	94 %

Tabla II. Desempeños FisherSignatures

## 6. Conclusiones

Este trabajo presenta una propuesta novedosa de reconocimiento de firmas, utilizando algoritmos propios del reconocimiento facial, como son Eigenfaces y Fisherfaces, los que hemos denominado EigenSignatures y FisherSignatures, respectivamente.

Si bien es cierto que los resultados experimentales denotan un rendimiento moderado cercano al 50% para EigenSignatures, nuestra hipótesis queda avalada a través de la utilización del algoritmo FisherSignatures al obtener un rendimiento cercano al 95%.

La obtención de imágenes binarias de firmas arrojó un rendimiento cercano a 90% utilizando FisherSignatures. Sin embargo, pese a ser un alto resultado, un análisis más riguroso mostró que la poca variabilidad entre las clases podía aún mejorarse, almacenando más información de cada firma a la imagen resultante. Dado lo anterior, se optó por hacer un pre-procesamiento de las imágenes obtenidas, que por sí solo resultó interesante, ya que entrega la información del sentido de firma de manera visual. Esto se traduce en que nuestra propuesta logró determinar una nueva característica (*feature*), propia de cada firma, que le aporta variabilidad a las imágenes entre las distintas clases, manteniendo a su vez una baja dispersión intra-clase.

El alto desempeño de FisherSignatures, con una tasa de aciertos del 94%, comparable incluso con los rendimientos obtenidos en reconocimiento de caras, nos hace pensar que la información global y de correlación es tanto o más útil que la detección de puntos específicos, para este tipo de aplicaciones.

Como trabajo futuro se plantea medir la capacidad del método para reconocer firmas falsas, pudiendo lograrse así la relación de relevancia de la nueva característica, lo que permitiría establecer el rango de aporte porcentual de la misma a todo el proceso de reconocimiento dinámico de firmas. Así mismo, dentro

del mismo contexto y a modo de expandir la generación de nuevas características, se propone incorporar información visual de la velocidad de desplazamiento en los diferentes tramos de la firma. Pruebas preliminares, demuestran viabilidad del método.

## 7. Referencias

- A.K. Jain, A. Ross, y S. Prabhakar (2004). An introduction to biometric recognition. *Circuits and Systems for Video Technology, IEEE Transactions on*, v. 14, 4-20.
- S. Prabhakar, S. Pankanti, y A.K. Jain (2003). Biometric recognition: security and privacy concerns. *Security & Privacy, IEEE*, v. 1, 33-42.
- M. Faundez-Zanuy (2007). On-line signature recognition based on VQ-DTW. *Pattern Recognition*, v. 40, 981-992.
- G. Agam y S. Suresh (2007). Warping-Based Offline Signature Recognition. *Information Forensics and Security, IEEE Transactions on*, v. 2, 430-437.
- B. Jayasekara, A. Jayasiri, y L. Udawatta (2006). An Evolving Signature Recognition System. *Industrial and Information Systems, First International Conference on*, 529-534.
- M. Faundez-Zanuy (2005). Signature recognition state-of-the-art. *Aerospace and Electronic Systems Magazine, IEEE*, v. 20, 28-32.
- C. Vivaracho-Pascual, M. Faundez-Zanuy, y J.M. Pascual (2009). An efficient low cost approach for on-line signature recognition based on length normalization and fractional distances. *Pattern Recognition*, v. 42, 183-193.
- E. Frias-Martinez, A. Sanchez, y J. Velez (2006). Support vector machines versus multi-layer perceptrons for efficient off-line signature recognition. *Engineering Applications of Artificial Intelligence*, v. 19, 693-704.
- C. Oz (2005). Signature Recognition and Verification with Artificial Neural Network Using Moment Invariant Method. *Advances in Neural Networks – ISNN 2005*, 195-202.
- B. Erkmen, N. Kahraman, R. Vural, y T. Yildirim (2008). CSFNN optimization of signature recognition problem for a special VLSI NN chip. *Communications, Control and Signal Processing, 2008. ISCCSP 2008. 3rd International Symposium on*, 1082-1085.
- M.A. Ismail y S. Gad (2000). Off-line arabic signature recognition and verification. *Pattern Recognition*, v. 33, 1727-1740.
- J. Ruiz-del-Solar, C. Devia, P. Loncomilla, y F. Concha (2008). Offline Signature Verification Using Local Interest Points and Descriptors. *Progress in Pattern Recognition, Image Analysis and Applications*.
- P. Belhumeur, J. Hespanha, y D. Kriegman (1997). Eigenfaces vs. Fisherfaces: recognition using class specific linear projection. *Pattern Analysis and Machine Intelligence, IEEE Transactions on*, v. 19, 711-720.
- M. Turk y A. Pentland (1991). Eigenfaces for Recognition. *Journal of Cognitive Neuroscience*, v. 3, 71-86.
- M. Turk y A. Pentland (1991). Face recognition using eigenfaces. *Computer Vision and Pattern Recognition, 1991. Proceedings CVPR '91., IEEE Computer Society Conference on*, 586-591.
- V. Hari (2005). Accelerating the SVD Block-Jacobi Method. *Computing*, v. 75, 27-53.
- S. Lakshmanan, P. Watta, Yu Lin Hou, y N. Gandhi (2001). Comparison between eigenfaces and Fisherfaces for estimating driver pose. *Intelligent Transportation Systems, 2001. Proceedings. 2001 IEEE*, 889-894.
- M. Sharkas y M. Elenien (2008). Eigenfaces vs. fisherfaces vs. ICA for face recognition; a comparative study. *Signal Processing, 2008. ICSP 2008. 9th International Conference on*, 914-919.