

ALGORITMOS PARA EL RECONOCIMIENTO DE IMÁGENES DE HUELLAS DACTILARES

Jorge L. Aching Samatelo, David A. Rojas Vigo
davidrojasv@yahoo.es

*Bachilleres de la Facultad de Ingeniería Electrónica de la Universidad Nacional Mayor de San Marcos
 Lima-Perú*

RESUMEN

En este artículo se presenta los algoritmos de extracción de características, clasificación y verificación de imágenes de huellas dactilares en grandes bases de datos, los cuales han sido implementados en nuestro trabajo de tesis. Se ha empleado técnicas sofisticadas de procesamiento de imágenes en las diferentes etapas del sistema, en la etapa de extracción de características se ha localizado el punto central de la huella a través del índice de Poincaré y usando un banco de filtros de Gabor 2D se ha obtenido su representación característica denominada FingerCode; en la etapa de clasificación se ha utilizado algoritmos de k-vecindad y redes neuronales y en la etapa de verificación se ha utilizado el algoritmo de distancia de Euclides. Se han realizado pruebas del sistema en la base de datos denominada Fingerprint Verification Competition (FVC).

ABSTRACT

In this article it is presented the extraction algorithms of characteristic, classification and verification of images of fingerprints in big databases, which have been implemented in our thesis work. It has been used sophisticated techniques of image processing in the different stages of the system, in the extraction stage of characteristic the central point of the print has been located through the index of Poincaré and using a bank of filters of Gabor 2D its denominated characteristic representation FingerCode has been obtained; in the classification stage it has been used k-nearest neighbor and neural networks, and in the verification stage the algorithm of distance of Euclides has been used. It has been carried out tests of the system in the denominated database Fingerprint Verification Competition (FVC).

Palabras Claves: Índice de Poincaré, Filtros de Gabor, FingerCode, Clasificación, Verificación, FVC, Huellas, Dactilares.

I. INTRODUCCIÓN

La huella dactilar es uno de los identificadores de mayor éxito frente a otras tecnologías biométricas existentes. Por este motivo, vienen siendo utilizadas con mucha fiabilidad para establecer la identidad de las personas en las áreas: policial, civil y comercial.

Los sistemas de identificación basados en huellas dactilares actuales hacen uso de una de sus características conocidas como minucias, las cuales son utilizadas por los expertos forenses para el reconocimiento automático de la identidad de un individuo. Sin embargo, los algoritmos para el reconocimiento automático de huellas dactilares basados en las minucias no son eficientes por el alto costo computacional, la sensibilidad al ruido de la imagen y porque sólo consideran la información singular de la huella, dejando de lado la información global que ésta presenta. Por consiguiente, ha surgido la necesidad de explorar nuevas representaciones de huellas dactilares basadas principalmente desde la perspectiva de la visión computacional y del reconocimiento de patrones [Pajares & De la Cruz, 2002].

El trabajo presentado en este artículo, utiliza la representación basada en la investigación pionera de Salil Prabhakar, en donde se analizan las huellas dactilares como patrones de texturas orientadas, desde donde se extraen representaciones de texturas invariantes combinando la información discriminativa global y local. Se presenta la aplicación de esta representación para la

implementación de un sistema automático de identificación de impresiones dactilares (AFIS); un AFIS está compuesto de varias etapas de procesamiento, siendo las más resaltantes: la extracción de características, la clasificación y la coincidencia.

En la etapa de extracción de características se obtiene un vector denominado FingerCode cuyos valores representan a la huella dactilar. En la etapa de clasificación, el FingerCode, obtenido de la etapa anterior, es clasificado en una de entre cinco clases, para lo cual se utiliza dos clasificadores. En la etapa de coincidencia, haciendo uso del cálculo de la distancia Euclídea, se determina el grado de similitud que existe entre el FingerCode de entrada con el conjunto de los FingerCodes de la clase a la que pertenece. En un sistema AFIS el sistema automáticamente selecciona un determinado número de huellas coincidentes para que posteriormente el perito forense determine la huella dactilar perteneciente al individuo por identificar.

II EXTRACCIÓN DE CARACTERÍSTICAS

En el esquema propuesto de texturas orientadas primero se determina el punto central en la imagen de la huella dactilar y una región circular alrededor de este se define como la región de interés, la cual es dividida en sectores; cada sector se normaliza a una media y varianza constante, la región de interés normalizada es filtrada usando un banco de filtros de Gabor 2D; la varianza de los niveles de gris en un sector cuantifica la subyacente estructura de cresta y se define como una característica. La unión de estas características constituyen un vector, denominado FingerCode. Así, las características capturan la información local y la enumeración ordenada en la sectorización captura las relaciones globales invariantes entre los patrones locales. La simbología utilizada en este trabajo se explica a continuación:

Una imagen digital de una huella dactilar en escala de grises I , está definida como una matriz $M \times N$, donde $I(u,v)$ representa la intensidad del píxel de la u -ésima fila y la v -ésima columna. El campo direccional Φ , es definido como una matriz $P \times Q$, donde $\Phi(i,j)$ representa la dirección promedio normal a las crestas del bloque (i,j) de la imagen original, $P \leq M$ y $Q \leq N$. Una imagen es dividida en un conjunto de bloques no traslapados $w \times w$ y una única orientación local de cresta es definida para cada bloque; $P = \lfloor M/w \rfloor$ y $Q = \lfloor N/w \rfloor$.

La imagen de regiones R , es definida como una imagen $P \times Q$ donde $R(i,j)$ indica la categoría del bloque (i,j) de

la imagen original: Un bloque (i,j) con valor 0 indica una región no recuperable. Un bloque (i,j) con valor 1 indica una región recuperable. El punto de referencia o punto central (u_c, v_c) , es definido como el punto de máxima curvatura en la imagen de huella dactilar. La región de Interés S , es definida como la colección de todos los sectores circulares alrededor del punto central.

2.1 Cálculo del FingerCode

Los cinco principales pasos son:

- Encontrar el punto central en la imagen de la huella dactilar.
- Sectorizar la imagen en regiones circulares.
- Normalizar cada una de las regiones o sectores circulares.
- Filtrar la imagen en cuatro direcciones usando un banco de filtros de Gabor 2D.
- Calcular la varianza de los niveles de gris en los sectores alrededor del punto central en las imágenes filtradas para definir el vector de características (FingerCode).

2.1.1 Localización del Punto Central

Las huellas dactilares tienen muchos hitos de importancia y cualquier combinación de ellos deberá ser usado para establecer el punto de referencia. Se define el punto de referencia como el punto de máxima curvatura de la concavidad de las crestas en las imágenes de huellas dactilares, como se muestra la figura 1.




Figura 1 - Crestas convexas y cóncavas

Para detectar el punto central (u_c, v_c) se implementa el algoritmo basado en la relación que presenta el punto central con el punto singular core de una imagen de huella dactilar, propuesto en [Jain, et al., 1999]. El procedimiento se describe a continuación:

- Se divide la imagen I , en bloques no traslapados de tamaño $w \times w$.

- Se estima la orientación local de cada bloque, implementando el algoritmo que calcula el promedio del gradiente cuadrado desarrollado en [Bazen & Gerez, 2000], obteniendo así el campo direccional de la imagen de la huella dactilar Φ .
- Se obtiene la imagen de regiones R de la imagen de la huella dactilar.
- Se determina a través del cálculo del índice de Poincaré el punto core de la huella dactilar, siguiendo los pasos descritos en [Jain & Karu, 1996].
- Si son detectados dos core, el centro es asignado a la coordenada del punto core con el menor valor de u (core superior). Si únicamente es detectado un core se toma a éste como punto central. Si no se detectan puntos core (huella tipo Arch) se calcula la transformada de covarianza de Φ para determinar el centro de la huella, siguiendo los pasos siguientes:
- Para cada punto (i,j) de Φ perteneciente a una región reconocible de la imagen de la huella dactilar, se toma una sub matriz de dimensiones qxq centrado en (i,j) denotada por I_{ij} . Todos los puntos de la sub matriz I_{ij} deben pertenecer a una región reconocible.
- Se calcula la matriz de covarianza de I_{ij} y se determina el máximo eigenvalor que presente. Este será el valor de la transformación de covarianza en (i,j) .
- Los dos pasos anteriores son repetidos para los valores de i y j pertenecientes a una región reconocible, obteniendo así la transformación de covarianza Ψ .
- La matriz Ψ es umbralizada, obteniéndose la imagen binarizada Ψ_U , de donde determinamos sus componentes conectados [Gonzales & Wintz, 1974]. Se considera que el centro de la imagen de la huella dactilar es el centro geométrico del componente conectado de mayor área [Jain, et al., 1999].
- El centro hallado es a continuación corrido 40 pixeles hacia abajo para futuros procesamientos basados en el hecho que la mayoría de la información de importancia de una huella dactilar reside en la parte inferior. Ver figura 2.

2.1.2 Sectorización

Luego de obtener el punto central de la imagen, se extrae una región circular a la cual se ha denominado región de interés conformada por un número determinado de bandas. Cada banda está a su vez subdividida

en un número de sectores S_i , donde el sector i -ésimo es calculado en términos de los parámetros (r,θ) , a través de la ecuación 1.




Figura 2 - Pasos para la detección del punto central de la imagen

$$S_i = \{(u,v) | b(T_i + 1) \leq r < b(T_i + 2), \theta_i \leq \theta < \theta_{i+1}, 1 \leq u \leq N, 1 \leq v \leq M\} \quad 1$$

donde:

$$T_i = \lfloor i / k \rfloor$$

$$\theta_i = (i \% k)(2\pi / k)$$

$$r = \sqrt{(u - u_c)^2 + (v - v_c)^2}$$

$$\theta = \tan^{-1}((u - u_c)/(v - v_c))$$

Para todo $i = \{0, \dots, B.k - 1\}$

El parámetro b define el ancho de las bandas concéntricas dependiendo de la resolución (en dpi) de la imagen. El parámetro k es el número de sectores considerados en cada banda y controla la captura de la información global versus la información local dependiendo de la aplicación. El parámetro B es el número de bandas concéntricas consideradas alrededor del punto de referencia y depende del tamaño de la imagen y de la resolución dpi que presente. Los valores para los parámetros B , b y k son determinados empíricamente; el valor de B debe ser establecido de tal manera que capture la máxima cantidad de detalles de crestas y valles.

El valor de k debe ser escogido basado en el intercambio entre la información local y global requeridas para una particular aplicación, el valor de b debe ser escogido basado en la resolución dpi de la imagen y la distancia promedio entre crestas en una imagen de huella dactilar. Una vez que los valores de los parámetros son escogidos para una aplicación, éstas se definen como

constantes. La banda más profunda (círculo) no es usada para la extracción de características debido a que los sectores en esta región están próximos al punto de referencia conteniendo muy pocos píxeles y por consiguiente, la extracción de características en esta región no es muy fiable. En la figura 3, se muestra los pasos necesarios para la sectorización circular de la imagen de la huella dactilar.




Figura 3 - Obtención de la región de interés

2.1.3 Normalización

Antes del filtrar la imagen de la huella dactilar, se normaliza las intensidades de los niveles de grises de cada sector a una media y varianza constante, la normalización es realizada para remover los efectos del ruido y la distorsión no lineal debido a las diferentes presiones de la huella al ser impresa. Si M_i y V_i indican la varianza y la media estimada para el sector S_i respectivamente, y $N_i(u, v)$ el valor normalizado del nivel de gris del píxel (u, v) . Para el sector S_i , la imagen normalizada es definida como:

$$N_i(u, v) = \begin{cases} M_0 + \frac{V_0}{V_i} [I(u, v) - M_i] & , \text{si } I(u, v) > M_i \\ M_0 - \frac{V_0}{V_i} [I(u, v) - M_i] & , \text{caso contrario.} \end{cases} \quad 2$$

Donde M_0 y V_0 son los valores de la media y varianza deseados respectivamente, estos deberán tener los mismos valores a través de todos los conjuntos de entrenamiento y de prueba. La normalización es una operación realizada píxel por píxel la cual no cambia la claridad de las estructuras de crestas y valles, sino únicamente permite la supresión de ruido.

2.1.4 Filtrado

El proceso es representado en la figura 4.




Figura 4 - Diagrama de filtrado de la huella dactilar

La región de interés normalizada es filtrada en diferentes direcciones usando un banco de filtros de Gabor 2-D simétricos [Prabhakar, 2001], los cuales son de pasa banda de orientación y frecuencia selectiva y tienen en el dominio espacial, la siguiente forma general:

$$G(x, y; f, \theta) = \exp \left\{ -\frac{1}{2} \left[\frac{x'^2}{\delta_x^2} + \frac{y'^2}{\delta_y^2} \right] \right\} \cos(2\pi f \cdot x') \quad 3$$

Donde,

$$\begin{aligned} x' &= x \cdot \text{sen}(\theta) + y \cdot \text{cos}(\theta) \\ y' &= x \cdot \text{cos}(\theta) - y \cdot \text{sen}(\theta) \end{aligned}$$

Para aplicar los filtros de Gabor 2D a una imagen, se requiere especificar tres parámetros: La frecuencia de la onda sinusoidal f , la orientación de los filtros θ , las desviaciones estándar de las envolventes Gaussianas δ_x y δ_y . La frecuencia, f es establecida como la inversa del valor promedio de la distancia (periodo) entre crestas es decir a $1/8$, para imágenes tomadas a 500dpi. La orientación θ determina el número de imágenes filtradas; así un filtro de Gabor 2D orientado a 0° acentúa las crestas que son paralelas al eje x y suaviza las crestas en otras direcciones. Los filtros orientados a otras direcciones trabajan de una manera similar. Los valores para δ_x y δ_y , son establecidos a 4.0 (sobre la mitad del promedio de la distancia entre crestas), el filtraje se realiza en el dominio espacial con una máscara de tamaño 33×33 y es la que mayor tiempo consume en la fase de extracción de características.

2.1.5 Vector de Características

Sea $F_{i\theta}(u, v)$ el píxel en la posición (u, v) de la imagen filtrada en la dirección θ perteneciente al sector S_i ; el valor de la característica $V_{i\theta}$, es calculado a través de la relación:

$$V_{i\theta} = \sqrt{\sum_{u=u_1}^{u_{K_i}} \sum_{v=v_1}^{v_{K_i}} (F_{i\theta}(u, v) - \mu_{i\theta})^2} \quad 4$$

donde

K_i es el número de píxeles en S_i

$\mu_{i\theta}$ es el promedio de los valores de los píxeles de $F_{i\theta}$ en S_i .

$V_{i\theta}$ define los componentes del vector de características FingerCode, semejante al IrisCode introducido por Daugman [Daugman, 1993].

III. CLASIFICACIÓN DE HUELLAS DACTILARES

3.1 Introducción

Una estrategia convencional para reducir el número de comparaciones cuando se está frente a una base de datos de gran tamaño es agrupar la misma en un número preestablecido de subconjuntos de huellas con características similares, de modo que la comparación de la huella de entrada se realice con el subconjunto al que pertenece en lugar de compararlo con todo el universo de huellas de la base de datos, mejorando así el tiempo de respuesta en el proceso de reconocimiento.

Un número considerable de técnicas de clasificación han sido desarrolladas [Leong, 2001], entre las más importantes se tiene:

- Basada en reglas.- es comúnmente usada por los expertos para clasificación manual, en donde las huellas son clasificadas de acuerdo al número y la posición de los puntos singulares.
- Sintáctica.- describe a los patrones a través de símbolos terminales y reglas de producción, es necesaria la aplicación de un lenguaje formal para la descripción y el reconocimiento de patrones relacionados con las imágenes.

- Estructural.- está basada en la organización relacional de las características de bajo nivel en estructuras de mayor nivel. Esta organización puede representarse a través de estructuras de datos simbólicos que permitan una organización estructural de la información.
- Estadística.- usa vectores de características y atributos espaciales de la huella para desarrollar una visión geométrica de un patrón, produciendo un espacio de medidas multidimensionales.
- Basada en redes neuronales.- en donde un sistema de auto-aprendizaje utiliza las direcciones de las crestas y otros aspectos en imágenes de huellas dactilares como entrada de entrenamiento para diferenciar las diversas clases.
- Basada en múltiples clasificadores.- en donde se utilizan dos o más clasificadores para ejecutar la tarea de clasificación.

El problema de la clasificación automática de huellas dactilares consiste generalmente en asignar una de cinco clases predeterminadas conocidas como: Arch (A), Tented Arch (T), Left Loop (L), Right Loop (R) y Whorl (W), tal como se muestra en la Figura 5.



Figura 5 - El Sistema de Clasificación Henry

Sin embargo, la dificultad de este esquema consiste en que el número de clases no está uniformemente distribuido en las bases de datos (aproximadamente 90% de huellas dactilares pertenecen a sólo tres clases: R, L y W) y la existencia de huellas ambiguas que hacen que el sistema los clasifique erróneamente.

La tarea de clasificación requiere una asignación consistente y fiable, basada generalmente en la extracción de macro-características, tales como la estructura global de las crestas y singularidades; es un complejo problema de reconocimiento de patrones debido a la pequeña variabilidad entre clases diferentes y la gran variabilidad entre huellas de la misma clase. Además, las imágenes usualmente contienen ruido, haciendo este proceso aún más difícil.

3.2 Algoritmo de Clasificación

El esquema mostrado en la figura 6, fue propuesto por [Jain, et al., 1999], que considera la extracción de características multicanal o basadas en filtros (FingerCode) dándole prioridad a las características estructurales de la huella dactilar, junto con un clasificador de dos bloques o etapas, considerando su versatilidad y posibilidad de cualquier combinación entre otros métodos.

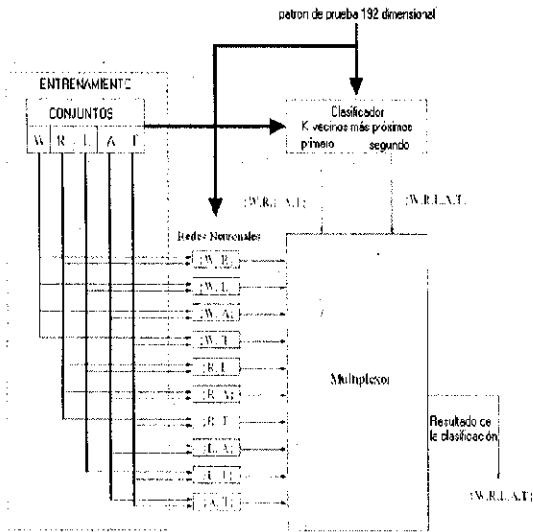


Figura 6 - Esquema de clasificación.

Las características del FingerCode utilizado para el proceso de clasificación son: 8 sectores por banda, 6 bandas, 4 orientaciones, resultando un vector de características de 192 valores. Para hacer la clasificación más sencilla, se considera el doble del número de clases, de manera que se discriminen las cinco clases en pares. Como primera etapa se utiliza un clasificador “k-vecinos cercanos” para lograr las dos clases más probables y luego en la segunda etapa un banco de diez redes neuronales clasificadoras de dos clases para manejar más sutiles discriminaciones.

3.2.1 Primera Etapa - Clasificador K-Vecinos Cercanos (k-NN)

El clasificador k-NN es ampliamente usado debido a su alta precisión y simplicidad. La idea básica detrás del k-NN es la ubicación de sus vecinos cercanos. Se determinan las dos clases más probables de una huella de entrada acuerdo a las dos clases más comunes de las huellas que se encuentran cercanas de ésta. La regla de decisión primero encuentra las k huellas del conjunto de entrenamiento más cercanas al FingerCode de entra-

da, donde k es un número natural especificado por el usuario. Una vez que las huellas cercanas han sido obtenidas, el número de puntos de cada clase en éste subconjunto es contado. La clase que más tiene ocurrencia es la asignada a la imagen de entrada.

Dado un patrón de entrada X a clasificar, la regla de clasificación k-NN está basada en aplicar el siguiente algoritmo:

- Paso 1.- Encontrar los k patrones más cercanos a X en el conjunto de prototipos que pertenecen a una clase, a través del uso de una métrica de distancia (Euclídea) entre la huella de entrada y las de entrenamiento.
- Paso 2.- Contabilizar las dos clases más probables del subconjunto obtenido del paso anterior y asignar las dos clases más probables por mayoría de votos entre las k huellas vecinas.

Estos clasificadores tienen varias opciones de diseño que deben ser ajustadas automáticamente de los datos (preferiblemente) tales como la métrica, el número k de vecinos, el conjunto de prototipos y su tamaño.

3.2.2 Segunda Etapa - Clasificador Basado en Redes Neuronales

Muchos de los métodos propuestos para esta tarea están basados en el uso de redes neuronales, como la mostrada en la figura 7, debido a su capacidad de aprender de ejemplos, a su habilidad de operar en paralelo y a su superior desempeño para trabajar con datos ruidosos e incompletos. Las redes neuronales implementadas para la segunda etapa de clasificación son diez redes multicapa con conexiones hacia adelante o feedforward, entrenadas con el algoritmo de aprendizaje de retropropagación de errores [J. Freeman & Skapura, 1993].

Las redes neuronales están basadas en un modelo matemático de elementos de procesamiento no lineales denominados neuronas. Estas redes presentan dos fases de operación: La fase de propagación en la que se aplica el FingerCode se aplica a las neuronas de entrada cuyas respuestas se va propagando hasta la salida para obtener la clase asignada. La fase de entrenamiento en el que el algoritmo de aprendizaje emplea que una técnica de búsqueda del gradiente que minimice el error esperado entre el FingerCode actual y su clase correspondiente.

Un teorema trascendental fue realizado por Kolmogorov, el que demuestra que un perceptrón de 3 capas con $N(2N + 1)$ nodos no lineales que se incrementan de

manera continua puede ser usado para generar cualquier función continua requerida por un clasificador. A continuación se describen los pasos del algoritmo de aprendizaje de la red neuronal para la tarea clasificación, una descripción más detallada sobre este algoritmo se describe en [Martín del Brío & Molina, 2003].




Figura 7 - Estructura de red neuronal multicapa implementada.

- Paso 1.- Inicializar los pesos y los umbrales, ajustar todos los pesos y los umbrales a valores aleatorios pequeños (± 0.5).
- Paso 2.- Presentar una entrada y la salida deseada, presentar un vector de entrada formado por valores continuos y los valores de salida asociados (en este caso todas las salidas excepto una tendrán valores de 0).
- Paso 3.- Calcular las salidas actuales para cada nodo
- Paso 4.- Adaptar los pesos, usar un algoritmo recursivo iniciando con los nodos de salida y regresando hacia la primera capa oculta.
- Paso 5.- Repetir el Paso 4 hasta la convergencia, si la diferencia entre algún elemento de la salida deseada y la salida actual es mayor que un cierto valor de error E entonces volver al Paso 4 hasta que se tenga un valor de E aceptable; si no ir al paso 6.
- Paso 6.- Repetir a partir del Paso 2

Cada red tiene 192 neuronas de entrada, de 20 a 40 neuronas en la capa oculta y dos neuronas de salida. Cada red es entrenada usando solamente los patrones correspondientes a dos clases del conjunto de entrenamiento. Por ejemplo, la red que distingue entre R y W es entrenada usando solo los patrones etiquetados con R y W en el conjunto de entrenamiento.

IV. COINCIDENCIA DE HUELLAS DACTILARES

Aunque las crestas poseen información discriminatoria, el diseño de un algoritmo fiable para analizar la coincidencia de huellas dactilares en forma automática es muy desafiante, debido a las deformaciones no lineales y ruido presentes en las imágenes de huellas dactilares. Las técnicas más populares para la coincidencia de huellas dactilares pueden ser clasificadas en dos categorías: basadas en minucias y basadas en correlación. Las técnicas basadas en minucias típicamente analizan la coincidencia de dos conjuntos de minucias realizando primero la alineación de los dos conjuntos y luego contando el número de minucias coincidentes. Una de las principales dificultades es la extracción fiable de las minucias en imágenes de impresiones dactilares de pobre calidad. Las técnicas basadas en correlación analizan la coincidencia del patrón global de crestas y valles viendo si las crestas se alinean. La técnica más simple es alinear las dos imágenes de huellas dactilares y substrair la entrada de la plantilla para ver si las crestas se corresponden; sin embargo, esta técnica presenta muchos problemas. La representación basada en banco de filtros no se incluye en estas categorías, esta técnica captura los detalles locales y globales a través del FingerCode. El algoritmo de coincidencia para esta representación está basado en el cálculo de la distancia euclídea entre los correspondientes FingerCodes siendo el proceso de comparación sumamente rápido.

Se ha utilizado los parámetros descritos a continuación para obtener la representación del FingerCode para el proceso de coincidencia tomando en cuenta que las imágenes son de tamaño 256×256 píxeles, escaneada a 500 dpi. El número de bandas concéntricas fue de 5, cada una con un ancho de 15 píxeles y segmentada en dieciséis sectores ($k=16$). Así, se tuvo un total de $16 \times 5 = 80$ sectores (S0 hasta S79) y la región de interés es un círculo de radio 75 píxeles, centrado en el punto de referencia. Ochenta características para cada una de las ocho imágenes filtradas proporcionan un total de 640 (80×8) características por imagen de huella dactilar.

La coincidencia de las huellas dactilares está basada en la determinación de la distancia euclídea entre los correspondientes FingerCodes, la invarianza a la traslación es establecida por la identificación del punto de referencia. Sin embargo, la aproximación para la invarianza a la rotación es lograda por la rotación cíclica de las características en el FingerCode. Un único paso de rotación corresponde a un vector de características rotado 22.5° , una rotación por R pasos corresponde a un vector de características rotado $R \times 22.5^\circ$. El FingerCo-

de obtenido después de R pasos de rotación es dado por:

$$V_{i\theta}^R = V_{i\theta^0} \quad 5$$

$$i' = (i + k - R) \% k + \lfloor (i/k) \rfloor k$$

$$\theta' = (\theta + 180^\circ + 22.5^\circ \times (-R)) \% 180^\circ$$

$$i \in [0, 1, 2, L, 79],$$

$$\theta \in [0^\circ, 22.5^\circ, 45^\circ, 67.5^\circ, 90^\circ, 112.5^\circ, 135^\circ, 157.5^\circ]$$

$V_{i\theta}^R$ es el FingerCode rotado, $V_{i\theta^0}$ es el FingerCode original.

Para cada huella en la base de datos, se almacena cinco plantillas correspondiente a las siguientes cinco rotaciones del correspondiente FingerCode: $V_{i\theta}^{-2}, V_{i\theta}^{-1}, V_{i\theta}^0, V_{i\theta}^1, V_{i\theta}^2$. El FingerCode de entrada es comparado con las cinco plantillas almacenadas en la base de datos para obtener cinco diferentes puntuaciones de coincidencia. La mínima de estas cinco puntuaciones de coincidencia corresponde al mejor alineamiento de la huella dactilar de entrada con las huellas dactilares de la base de datos. Puesto que la generación de plantillas y almacenamiento en la base de datos es un proceso off-line la tarea de coincidencia es extremadamente rápida, el tiempo de verificación todavía depende del tiempo tomado para generar una plantilla para la imagen de prueba.

V. MEDIDAS DE RENDIMIENTO

El comportamiento de un sistema biométrico basado en huellas dactilares con un umbral de decisión específico, puede ser mostrado a través de las siguientes tasas básicas de medida:

- FAR.- Es una medida de la probabilidad que la huella dactilar de un impostor sea aceptada por el sistema. Hace referencia a la situación donde el sistema biométrico verifica erróneamente la legitimidad del individuo, es decir representa el porcentaje de usuarios no autorizados que son incorrectamente identificados como usuarios válidos y por lo tanto aceptados por el sistema.
- FRR.- Es una medida de la probabilidad que la huella dactilar de un individuo autorizado sea rechazado, no está influenciado por una coincidencia de uno a muchos. Hace referencia a la situación donde el sistema biométrico rechaza erróneamente la legitimidad del individuo, o sea representa el

porcentaje de usuarios autorizados que son incorrectamente rechazados por el sistema.

Ambos parámetros son funciones del grado de seguridad deseado. Para una aplicación determinada el grado de seguridad deseado se define mediante el umbral de decisión. Por ejemplo, para el ingreso a una instalación militar se exige un alto valor para el umbral de decisión, implicando que pocos impostores sean aceptados como personal autorizado (FAR muy pequeña) y muchas personas autorizadas sean rechazadas (FRR muy alto). Por otro lado, el acceso a una máquina ATM requiere un valor pequeño para el umbral de decisión, implicando que una fracción pequeña del personal autorizado sea rechazada (FRR muy bajo), mientras que un número mayor de impostores será aceptado (FAR muy alto).

Las medidas de rendimiento para los sistemas de clasificación consisten fundamentalmente de dos indicadores:

- Matriz de Confusión.- describe los errores cometidos para cada clase, es una matriz comparativa entre la clase verdadera (filas) versus las clases asignadas (columnas) por el clasificador. Una matriz de confusión de un clasificador ideal contendrá valores numéricos altos solamente en la diagonal principal, siendo los valores restantes cero.
- Precisión.- es un indicador global que nos muestra el porcentaje de la base de datos que ha sido correctamente clasificada, éste valor depende de si se ha considerado algún criterio de rechazo a las imágenes de huellas que contienen información muy pobre para ser clasificada.

VI. RESULTADOS EXPERIMENTALES

Las pruebas de los algoritmos descritos en las secciones anteriores fueron realizadas utilizando las imágenes de huellas dactilares del Fingerprint Verification Competition (FVC) [Maio, et al., 2002], el cual contiene cuatro bases de datos identificadas como: DB1 capturadas por un sensor óptico TouchView II de Identix, DB2 capturadas por un sensor óptico FX2000 de Biométrica, DB3 capturadas por un sensor capacitivo 100 SC de Precise Biometrics y DB4 huellas sintéticas generadas. Cada una de las bases de datos contiene 880 imágenes de huellas dactilares. Hemos trabajado fundamentalmente con la base de datos DB1, cuyas imágenes han sido recortadas a 256x256 píxeles, para obtener mayor velocidad de procesamiento, utilizando el programa de edición de imágenes PhotoShop.

En la etapa de clasificación es necesario determinar experimentalmente el valor de k para el pre-clasificador k -NN, éste valor depende fuertemente de la base de datos a emplear, respecto a la calidad de las imágenes y a la cantidad de imágenes presentes. En el esquema implementado, las diez redes neuronales requieren diferentes cantidades de neuronas en la capa oculta para el entrenamiento, según la complejidad de la discriminación de las huellas dactilares. Una desventaja del sistema de clasificación implementado es que al no estar uniformemente distribuidas las clases preestablecidas de las huellas se tiene un número no uniforme de muestras de entrenamiento para las redes neuronales, lo que da como consecuencia una pobre generalización para ciertas clases. Por lo tanto, para obtener una adecuada generalización de las redes implementadas se requiere un número de huellas en la base de datos de acuerdo a la arquitectura de la red. Para la base de datos utilizada se requiere de una arquitectura pequeña para asegurar una adecuado error de generalización, la figura 8 muestra una curva de error al entrenar una de las diez redes neuronales, estos resultados fueron obtenidos después de aproximadamente una hora de entrenamiento.




Figura 8 - Curva de entrenamiento de la red neuronal que discrimina entre W y R.

El clasificador de dos etapas implementado ha obtenido una precisión del 90% sin la opción de rechazo. Aunque este clasificador es robusto al ruido y es capaz de clasificar correctamente muchas de las huellas de baja calidad, falla sobre algunas huellas de muy baja calidad donde no hay información de crestas en la parte central de la huella. En huellas de baja calidad es muy difícil detectar correctamente el punto de referencia.

En la figura 9 se muestra la grafica de la FRR y la FAR obtenidas de la etapa de coincidencia con diferentes umbrales de decisión.




Figura 9 - Curva experimental de comparación entre los indicadores FAR y FRR.

La FRR es creciente y la FAR es decreciente y ambas presentan como rango $[0, 1]$ puesto que son probabilidades. El umbral de decisión correspondiente a la intersección de ambas graficas es conocido como tasa de cruzamiento o EER (Equal Error Rate) y en nuestra experiencia toma el valor de 0.1. Estas graficas han sido obtenidas sin la habilitación de la opción de rechazo, es decir, ninguna huella ha sido rechazada por no haberse obtenido una adecuada región de interés, logrando un 85% de acierto en todos los procesos de coincidencia realizados.

Los resultados experimentales tanto para la coincidencia como para la clasificación fueron obtenidos en una PC Pentium I de 130MHz y 256 RAM, los programas fueron implementados en Matlab 5.3, tomando en cuenta que la coincidencia se realiza con los FingerCode de las huellas dactilares, el tiempo de comparación mínimo es alrededor de 0.1 s, el tiempo de clasificación es aproximadamente 5 s. El mayor tiempo computacional es invertido al momento de obtener el FingerCode, alrededor de 45 s.

VII. CONCLUSIONES

Se ha realizado el estudio e implementación de algoritmos eficientes para el reconocimiento de imágenes de huellas dactilares basados en el vector de características denominado FingerCode, mostrando su robustez y eficiencia, además de sus puntos más débiles, tales como la correcta localización de la región de interés.

El desarrollo de éstos algoritmos nos permite la búsqueda de nuevas alternativas y mejoras a los sistemas de identificación biométrica basada en huellas dactilares, así como el estudio de técnicas de paralelización de éstos algoritmos utilizando procesadores digitales de señal, dispositivos lógicos programables complejos e incluso clusters de computadores.

VIII REFERENCIAS BIBLIOGRÁFICAS

- Andreu G., J. Valiente. Análisis de imágenes binarias. Univ. Politécnica de Madrid.
- Bazen, A., S. Gerez. Directional field computation for fingerprints based on the principal component analysis of local gradients. 11th Annual Workshop on Circuits, Systems and Signal Processing, Veldhoven, 2000.
- Bazen, A., S. Gerez. Segmentation of fingerprint images. 12th Annual Workshop on Circuits, Systems and Signal Processing, Veldhoven, 2001.
- Blue, J., G. Candela, P. Grother, R. Chellappa, C. Wilson. Evaluation of Pattern Classifiers for Fingerprint and OCR Applications, 1993
- Bobung, S. Evaluation of transformation methods to detect structure in fingerprints.
- Bonato, V. Proposta de um Sistema para Processamento de Impressões Digitais Implementado em Hardware. Departamento de Informática – UNISC Brasil 2003.
- Chung, L.E., Ghazali Sulong. Fingerprint Classification Approaches: An Overview. Faculty of Computer Science and Information System, University Technology Malaysia, 81310 Skudai, 2001.
- Daugman, J. High confidence recognition of persons by a test of statistical independence, IEEE trans. Pattern Anal. and Machine Intelligence, Vol 16, No. 11, pgs. 1148-1161. 1993.
- Freeman, J., D. Skapura. Redes Neuronales: Algoritmos, aplicaciones y técnicas de programación. Addison Wesley Iberoamericana S.A., 1993.
- Gonzales, R., P. Wintz, Digital Image Processing. Addison-Wesley Publishing Company, 1974.
- Jain, A., F. Farrokhnia. Unsupervised texture segmentation using Gabor filters. Pattern Recognition, Vol. 24, No.12, pgs. 1167-1186, 1991.
- Jain, A., Kalle Karu. Fingerprint Classification. Pattern Recognition, Vol. 29, No 3, pgs.389-404, 1996.
- Jain, A., S. Prabhakar, L. Hong, S. Pankanti. FingerCode: A Filterbank for Fingerprint Representation and Matching. Proc. of IEEE Computer Society Conf. On Computer Vision and Pattern Recognition, Fort Collins, 1999
- Jain, A., S. Prabhakar, L. Hong. A Multichannel Approach to Fingerprint Classification. IEEE Trans. Pattern Anal. And Machine Intelligence, Vol 21, No.4, pgs. 348-359, 1999
- Jain, R. Duin, J. Mao Statistical Pattern Recognition: A Review. IEEE Transactions on Pattern Analysis and Machine Intelligence, Vol. 22, 2000.
- Kung, S.. Digital Neural Networks. Prentice Hall, 1993.
- Lee, H., R. Gaensslen. Advances in Fingerprint Technology. Elsevier, 1991
- Luca, M.G., F. Roli, y A. Serrau. Fusion of Statistical and Structural Fingerprint Classification. Department of Electrical and Electronic Eng. – University of Cagliari Italy
- Lumini, A., D. Maio, D. Maltoni Continuous vs exclusive classification for fingerprint retrieval. Pattern Recognition Letters; pgs.1027-1034, 1997.
- Maio, D., D.Maltoni, R.Cappelli, J.Wayman, A. Jain FVC2002: Second Fingerprint Verification Competition. Biometric System Lab, Biometric Test Center, Michigan State University 2002.
- Martín del Brío, B., A. Sanz Molina. Redes Neuronales y Sistemas difusos 2da Edición. Alfaomega Grupo Editor S.A., 2002.
- Pajares, G., J. De la Cruz. Visión por Computador: Imágenes digitales y aplicaciones. Alfaomega Grupo Editor S.A., 2002.
- Prabhakar, S. Fingerprint Classification and matching using a filterbank, Tesis Doctoral, Michigan State University, 2001
- Sierra, B.. Aportaciones metodológicas a la Clasificación Supervisada. Dpto. de Ciencias de la Computación e Inteligencia Artificial. University of the Basque Country, 2000.