

Utilidad de la Fusión de Datos en Segmentación de Áreas Texturadas

Carlos Avilés Cruz

Universidad Autónoma Metropolitana-Azacapatzalco
Departamento de Electrónica, Área de Comunicaciones
Av. San Pablo No. 180
Col. Reynosa Tamaulipas, C.P. 02200 México D.F.
e-mail : caviles@hp9000a1.uam.mx

Artículo recibido en noviembre de 1997; aceptado el 30 de enero de 1998.

Resumen

En este artículo, se presenta una metodología para la segmentación de áreas texturadas. La metodología comprende una fase de extracción de atributos estadísticos a través de: la matriz de co-ocurrencias y los momentos de orden cuatro. Una fase más que es la fusión de datos, los atributos estadísticos se ponen en colaboración vía diferentes algoritmos de fusión, dado que una sola familia de parámetros no es suficiente para lograr la discriminación de una larga gama de texturas. Finalmente una fase de segmentación es aplicada a texturas de grano fino.

Palabras Clave: Segmentación de Texturas, Matriz de Co-ocurrencias, Estadística de Orden Superior, Fusión de Datos.

1 Introducción

El análisis y segmentación de texturas es una tarea muy importante en numerosas aplicaciones, por citar algunas, en el control de calidad, en segmentación de escenas, en aplicaciones biomédicas, en imágenes satelitales, etc. Los tipos de texturas se dividen en dos grupos, por un lado las macro-texturas o texturas de grano grueso y por otro lado, las micro-texturas o texturas de grano fino. Para la caracterización y segmentación del primer grupo, se utilizan los métodos estructurales, para el segundo grupo, se aplican métodos estadísticos. Este trabajo está orientado al estudio de micro-texturas, concretamente a la segmentación de texturas artificiales de grano fino. Los parámetros estadísticos utilizados para la discriminación son: la matriz de co-ocurrencias, los momentos de orden tres y los momentos de orden cuatro. Dado que una sola familia de parámetros no es suficiente para lograr la discriminación de una larga gama de texturas, en este artículo se utiliza una fase de fusión de datos vía diferentes algoritmos como son: la fusión de probabilidades *a posteriori*, la fusión por la teoría de Bayes y la fusión por la teoría de la Evidencia. El resto de este artículo está organizado de la siguiente forma: en la sección II se describe la fase de extracción de atributos, la fase de pre-procesamiento y la fase de fusión de datos. En la sección III se presentan los resultados sobre texturas naturales. En la sección IV se presenta la discusión y conclusiones.

2 Presentación de la Metodología

En la fase de extracción de características, los métodos estadísticos empleados son, por una parte, la matriz de co-ocurrencias, por otro lado, los momentos de orden

tres y finalmente, los momentos de orden cuatro. Estos métodos estadísticos se basan principalmente en la correlación de niveles de grises en una vecindad dada.

2.1 Extracción de Características

Matriz de Co-Ocurrencias

La matriz de co-ocurrencias representa la dependencia espacial entre dos niveles de grises. La matriz de co-ocurrencias es formada para cada vector dado, definiendo la separación espacial entre dos píxeles sobre los cuales se calcula la dependencia de niveles de grises. Esta matriz (M_{cooc}) reagrupa las estimaciones de la densidad de probabilidad conjunta de todas las parejas de puntos separados por el vector $\vec{\delta}$. Concretamente, la matriz de co-ocurrencias es una matriz cuadrada de talla menor o igual al número de niveles de grises, donde en la intersección de la línea i y de la columna j es representado el número de parejas de puntos separados por $\vec{\delta}$ tal que el primero tenga el nivel i y el segundo el nivel j . Todos los componentes son divididos por el número total de parejas analizadas (Figura 1 y Figura 2).

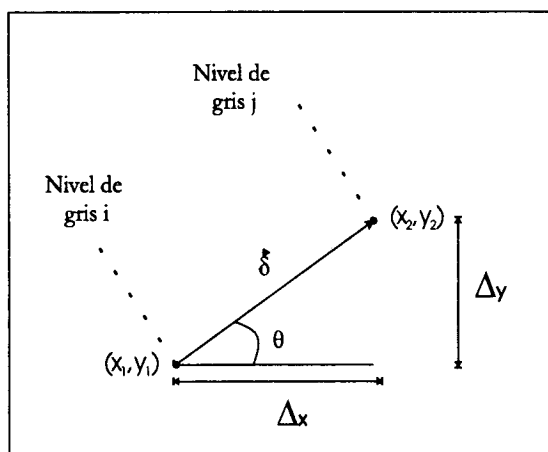


Figura 1: Principio de base para la generación de la matriz de co-ocurrencias con $\vec{\delta}$ fijo.

A partir de la matriz de co-ocurrencias, diferentes parámetros son extraídos para caracterizarla y a través de ella, la textura.

Parámetro de Contraste

El parámetro de contraste mide la repartición de los coeficientes de la matriz, con respecto a la diagonal principal.

Momento Angular de Segundo Orden

Este parámetro nos da una idea de la homogeneidad de la textura, es sensible a los valores grandes de la matriz de co-ocurrencias. La elección del parámetro está

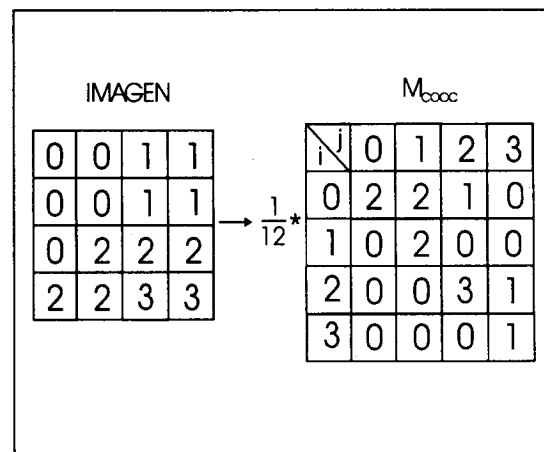


Figura 2: Ejemplo para una imagen de 4×4 sobre 4 niveles de grises. A la izquierda, una muestra de una textura en niveles de grises. A la derecha, la matriz de co-ocurrencias para el vector $\vec{\delta}(\Delta x = 1, \Delta y = 0)$.

estrechamente ligada a la granularidad y orientación de la textura.

En la bibliografía se definen más parámetros. Nosotros solamente tomamos los más discriminantes a nuestra aplicación.

Momentos de Orden 4

Con respecto a estos atributos, la textura es caracterizada a través de la correlación de tres píxeles (en la bibliografía se identifica también como "tri-correlación"), X_n , X_{n+1} y X_{n+2} para estimar los momentos de orden cuatro. Con esta restricción (vesinage: 1 y 2) y quitando los elementos redundantes, se tienen 10 momentos a estimar por orientación. Para tomar en cuenta posibles orientaciones de las texturas, la estimación se realiza en cuatro orientaciones, a 0, a 45, 90 y 135. La expresión general de momentos de orden cuatro es:

$$M_4(i, j, k) = E[X_n X_{n+i} X_{n+j} X_{n+k}] = \sum_{n=1}^{n=N} X_n X_{n+i} X_{n+j} X_{n+k} P(X) \quad (1)$$

donde i , j y k son tres desplazamientos temporales o espaciales, y $P(X)$ la probabilidad de X . Con las restricciones de vecindad, obtenemos los 10 momentos siguientes:

La expresión general para la estimación es:

$$\tilde{M}_4(i, j, k) = \frac{1}{N} \sum_{n=1}^{n=N} X_n X_{n+i} X_{n+j} X_{n+k} \quad (2)$$

Lista de momentos :

$$\tilde{M}_4(0, 0, 0) = \frac{1}{N} \sum_{n=1}^{n=N} x_n^4 \quad (3)$$

$$\tilde{M}_4(0, 0, 1) = \tilde{M}_4(0, 1, 0) = \tilde{M}_4(1, 0, 0) = \frac{1}{N} \sum_{n=1}^{n=N} x_n^3 x_{n+1} \quad (4)$$

$$\tilde{M}_4(0, 0, 2) = \tilde{M}_4(0, 2, 0) = \tilde{M}_4(2, 0, 0) = \frac{1}{N} \sum_{n=1}^{n=N} x_n^3 x_{n+2} \quad (5)$$

$$\tilde{M}_4(0, 1, 1) = \tilde{M}_4(1, 1, 0) = \tilde{M}_4(1, 0, 1) = \frac{1}{N} \sum_{n=1}^{n=N} x_n^2 x_{n+1}^2 \quad (6)$$

$$\tilde{M}_4(0, 1, 2) = \tilde{M}_4(1, 2, 0) = \tilde{M}_4(2, 0, 1) = \frac{1}{N} \sum_{n=1}^{n=N} x_n^2 x_{n+1} x_{n+2} \quad (7)$$

$$\tilde{M}_4(0, 2, 2) = \tilde{M}_4(2, 2, 0) = \tilde{M}_4(2, 0, 2) = \frac{1}{N} \sum_{n=1}^{n=N} x_n^2 x_{n+2}^2 \quad (8)$$

$$\tilde{M}_4(1, 1, 1) = \frac{1}{N} \sum_{n=1}^{n=N} x_n x_{n+1}^3 \quad (9)$$

$$\tilde{M}_4(1, 1, 2) = \tilde{M}_4(1, 2, 1) = \tilde{M}_4(2, 1, 1) = \frac{1}{N} \sum_{n=1}^{n=N} x_n x_{n+1}^2 x_{n+2} \quad (10)$$

$$\tilde{M}_4(1, 2, 2) = \tilde{M}_4(2, 2, 1) = \tilde{M}_4(2, 1, 2) = \frac{1}{N} \sum_{n=1}^{n=N} x_n x_{n+1} x_{n+2}^2 \quad (11)$$

$$\tilde{M}_4(2, 2, 2) = \frac{1}{N} \sum_{n=1}^{n=N} x_n x_{n+2}^3 \quad (12)$$

con N igual al número total de muestras. Así cada textura será caracterizada por 10 atributos sobre 4 orientaciones (40 atributos).

2.2 Fusión de Datos

Es evidente que en el dominio de la clasificación y segmentación de micro-texturas, ningún parámetro estadístico funciona al 100 %. Una solución es construir un proceso de decisión más robusto y con mayor desempeño. Esto se logrará fusionando varios descriptores. El proceso de fusionar varios captosres ha sido ya utilizado en robótica [Crowley & Demazeau, 1993; Luo *et al.*, 1987; Luo & Lin, 1988], en reconocimiento de caracteres [Xu *et al.*, 1992], en imágenes de radar y de satélite [Duvaut *et al.*, 1983; Chu & Aggrawal, 1992; Houzelle & Giraudon, 1991], en segmentación de escenas [Asar & Agrawal, 1990; Mohan & Nevatia, 1992] y en segmentación de texturas [Avilés & Guierín, 1996]. A continuación describiremos cada una de estas técnicas (técnica paralelo), así como una técnica propuesta por nosotros mismos (técnica serie).

Arquitectura Paralela

En la fusión en paralelo, todos los clasificadores están en actividad al mismo tiempo, sus salidas son combinadas para dar una decisión final. El tipo de información que los clasificadores entregan, se puede a su vez clasificar en tres grupos:

- i) En la primera categoría, la información que entregan los clasificadores son sus decisiones finales, es decir, entregan una sola etiqueta que es la clase a la cual pertenece la muestra. A partir de estas etiquetas se puede aplicar la estrategia del voto mayoritario. En nuestro caso, como únicamente trabajamos con dos clasificadores, este tipo de estrategia no es muy útil.
- ii) En la segunda categoría, la información entregada por los clasificadores es más completa que la simple etiqueta de la categoría anterior. Esta información se ubica a nivel de medidas, es decir, antes que los clasificadores tomen una decisión final. Cada clasificador k entrega un vector de probabilidad condicional, el cual mide la probabilidad de pertenecer la muestra \vec{x}_i a la clase ω_i . Con este tipo de información se aplicarán técnicas de fusión de probabilidades *a posteriori*.
- iii) Para la tercera categoría, los clasificadores entregan su decisión final, asociado a un conocimiento *a priori* de su funcionamiento. Esta información *a priori* es proporcionada por la matriz de confusión.

Notación de Base

Sea K el número de clasificadores (en nuestro caso, $K = 2$).

Sea C el número total de clases.

Sea $C+1$ la clase de rechazo.

Sea $P_k(\vec{x} \in \omega_i / \vec{x})$ la probabilidad *a posteriori* que la muestra \vec{x}_i pertenezca a la clase ω_i según el clasificador k .

Sea $E(\vec{x}_i) = j$ la decisión final de la fusión, asignando la muestra \vec{x}_i a la clase ω_j .

Fusión de Probabilidades *a Posteriori*

La fusión se efectúa de acuerdo a la información de probabilidades *a posteriori* generada por cada clasificador. Con estas probabilidades, dos tipos de combinaciones son posibles: la fusión a valor medio y la fusión a valor máximo. Estas fusiones son descritas a continuación.

Clasificador a Valor Medio

La fusión se efectúa simplemente tomando el valor promedio de las probabilidades *a posteriori* de cada clase sobre los K clasificadores.

$$P_E(\vec{x} \in w_i/\vec{x}) = \frac{1}{K} \sum_{k=1}^K P_k(\vec{x} \in w_i/\vec{x}) \quad (13)$$

La decisión final (la clase ganadora) será el valor máximo de estas probabilidades *a posteriori* promedio P_E .

$$E(\vec{x}) = j \text{ o } P_E(\vec{x} \in w_j/\vec{x}) = \max [P_E(\vec{x} \in w_i/\vec{x})] \quad (14)$$

con $i, j = 1, 2, \dots, C$, el número total de clases.

Se puede introducir un umbral de rechazo α :

$$E(\vec{x}) = \begin{cases} j & \text{si } P_E(\vec{x} \in w_j/\vec{x}) = \max [P_E(\vec{x} \in w_i/\vec{x})] \geq \alpha \\ C+1 & \text{si no} \end{cases}$$

Con $\alpha \in [0, 1]$.

Clasificador a Valor Máximo:

En este caso, la fusión se efectúa mediante la regla:

$$P_E(\vec{x} \in w_j/\vec{x}) = \underbrace{\max}_k [P_k(\vec{x} \in w_j/\vec{x})] \quad (15)$$

con $i, j = 1, 2, \dots, C$, el número total de clases y $k=1, 2, \dots, K$ el número total de clasificadores.

La clase ganadora será el valor máximo de estas probabilidades máximas.

Fusión a Través de la Teoría de Bayes

El principio de la fusión a través del formalismo de Bayes es el considerar que las fuentes que generan los datos son independientes. Es decir que los clasificadores aprenden a partir de muestras diferentes e independientes. La función de fusión es ponderada por el conocimiento *a priori* de la distribución de los errores de cada clasificador. Este conocimiento está dado por la matriz de confusión de cada clasificador.

La fusión a través de este formalismo esta basada sobre una función de creencia "Belief. Esta función de creencia es una medida de la probabilidad de un evento $P(\vec{x} \in w_i)$ condicionado a las decisiones de los K clasificadores. La creencia evaluada para un solo clasificador e_k es simplemente la probabilidad condicional de pertenecer a un clase y ésta está definida por:

$$Bel_k(\vec{x} \in w_i/e_k(\vec{x}) = j_k) = P(\vec{x} \in w_i/e_k(\vec{x}) = j_k) = P_{ij}^k \quad (16)$$

$Bel_k(i)$ significa el grado de confianza en que la muestra \vec{x} pertenezca a la clase w_i , sabiendo que el clasificador e_k ha decidido que la muestra \vec{x} pertenece a la clase j_k .

Para generar la decisión final Bel_k de los K clasificadores, se utiliza la formula de la probabilidad condicional de Bayes para descomponer la creencia global de un evento a partir de las creencias parciales de cada clasificador. Esta descomposición es válida bajo la hipótesis de independencia de las decisiones de los clasificadores.

$$\begin{aligned} Bel(\vec{x} \in w_i) &= Bel(i) = Bel[\vec{x} \in w_i / \{e_1(\vec{x}) = j_1 \text{ y } e_2(\vec{x}) = j_2 \text{ y } \dots \text{ y } e_K(\vec{x}) = j_K\}] \\ Bel(i) &= P[\vec{x} \in w_i / \{e_1(\vec{x}) = j_1 \text{ y } e_2(\vec{x}) = j_2 \text{ y } \dots \text{ y } e_K(\vec{x}) = j_K\}] \\ Bel(i) &= \frac{P[\{e_1(\vec{x}) = j_1 \text{ y } e_2(\vec{x}) = j_2 \text{ y } \dots \text{ y } e_K(\vec{x}) = j_K\} / \vec{x} \in w_i]}{P\{e_1(\vec{x}) = j_1 \text{ y } e_2(\vec{x}) = j_2 \text{ y } \dots \text{ y } e_K(\vec{x}) = j_K\}} P(\vec{x} \in w_i) \end{aligned} \quad (17)$$

Bajo la suposición de independencia entre los clasificadores, se obtiene:

$$\begin{aligned} Bel(i) &= \frac{\prod_{k=1}^K P(e_k(\vec{x}) = j_k / \vec{x} \in w_i)}{\prod_{k=1}^K P(e_k(\vec{x}) = j_k)} P(\vec{x} \in w_i) \\ Bel(i) &= \frac{\prod_{k=1}^K P(\vec{x} \in w_i / e_k(\vec{x}) = j_k) \frac{P(e_k(\vec{x}) = j_k)}{P(\vec{x} \in w_i)}}{\prod_{k=1}^K P(e_k(\vec{x}) = j_k)} P(\vec{x} \in w_i) \\ Bel(i) &= [P(\vec{x} \in w_i)]^{1-K} \prod_{k=1}^K P(\vec{x} \in w_i / e_k(\vec{x}) = j_k) \end{aligned} \quad (18)$$

En el caso general donde las probabilidades *a priori* no están disponibles, se utiliza la aproximación siguiente [Xu & Suen, 1992]:

$$Bel(i) = \eta \prod_{k=1}^K P(\vec{x} \in w_i / e_k(\vec{x}) = j_k) \quad (19)$$

Donde η es un factor de normalización el cual esta definido a partir de:

$$\sum_{i=1}^C Bel(i) = 1 \quad (20)$$

En consecuencia,

$$\frac{1}{\eta} = \sum_{i=1}^C \prod_{k=1}^K P(\vec{x} \in w_i / e_k(\vec{x}) = j_k) \quad (21)$$

Finalmente, la regla de decisión será la siguiente:

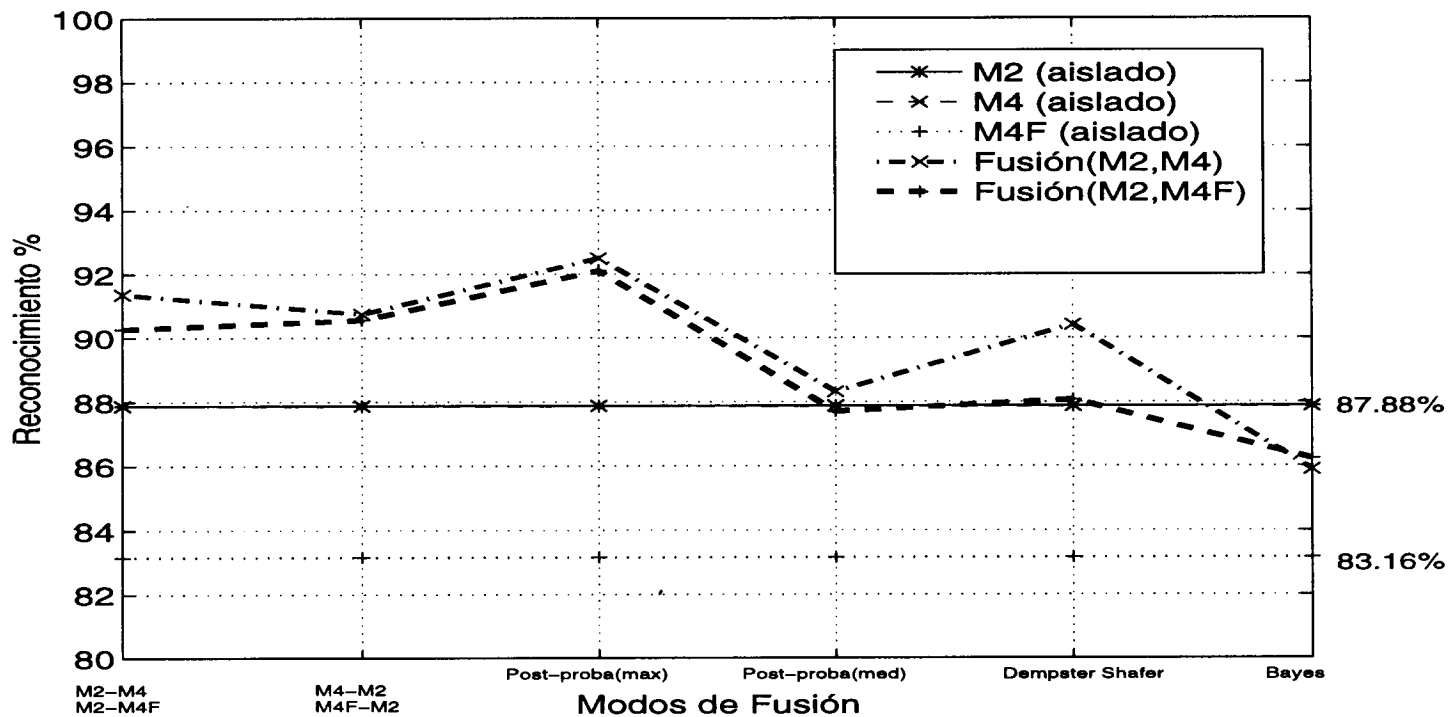


Figura 3: Fusión de momentos estadísticos generados a partir de cuatro texturas d04, d09, d24 y d57.

$$E(\vec{x}) = \begin{cases} j & \text{si } Bel(j) = \max Bel(i) \geq \alpha \\ C+1 & \text{sino} \end{cases} \quad (22)$$

con $i = 1, \dots, C$, el número total de clases y $\alpha \in [0, 1]$, el umbral de rechazo.

Fusión a Través de la Teoría de la Evidencia

La fusión por la teoría de la Evidencia fue desarrollada por Dempster y Shafer [Shafer, 1976]. El objetivo de esta teoría es combinar proposiciones o evidencias en base a un conocimiento *a priori*. Este conocimiento *a priori* está dado por la matriz de confusión.

Sea Θ el conjunto universo de todas las proposiciones mutuamente excluyentes A_i , $i = 1, \dots, C$.

Sea 2^Θ el conjunto de todos los sub-conjuntos de Θ . Por ejemplo: si $\Theta = A_1, A_2$, entonces, $2^\Theta = \phi, \Theta, A_1, A_2$. En nuestro caso, las proposiciones A_i significan que la muestra \vec{x} pertenece a la clase w_i .

Definición: Sea $Bel: 2^\Theta \leftarrow [0, 1]$ la función creencia en el sentido de Dempster y Shafer, que asocia a cada conjunto A_i de Θ un valor. En consecuencia, $Bel(A) \in [0, 1]$. Dos resultados se deducen inmediatamente $Bel(\Theta) \leq 1$ y $Bel(\Phi) = 0$, donde Φ es el elemento vacío, la suma de creencias sobre todos los elementos de 2^Θ son inferiores o iguales a uno.

El valor de $Bel(A)$ es calculado a partir de una función llamada función de masa m , la cual representa el impacto

individual de cada proposición de los elementos de 2^Θ .

En forma semejante a la función de creencia, la función de masa m está definida entre 0 y 1, es decir, $m: 2^\Theta \leftarrow [0, 1]$. La cantidad de masa $m(A)$ es una medida de creencia asociado a A . Dos condiciones son impuestas a la función de masa: $m(\Phi) = 0$ (ninguna creencia se le puede asociar al conjunto vacío) y $\sum_{A \in \Theta} m(A) = 1$, la creencia del ensamble universo es igual a 1.

La regla para combinar las K masas correspondiente a la decisión de cada clasificador está dada por la siguiente ecuación:

$$m(A) = m_1 \oplus m_2 \oplus \dots \oplus m_K \quad (23)$$

Arquitectura Serie

Una arquitectura simple pero muy eficaz si el factor preponderante es el tiempo de procesamiento, es la combinación *Maestro-Esclavo*. En este tipo de arquitectura, la decisión se efectúa en dos tiempos, en un primer tiempo, el clasificador *Maestro* da una decisión (esta será la decisión final en caso de que no haya rechazo) si esta decisión es de rechazo, el pixel bajo tratamiento será analizado por el segundo clasificador *esclavo*. La decisión del *esclavo* puede ser también un rechazo. La arquitectura *Maestro-Esclavo* aprovecha la complementariedad de los atributos estadísticos, es decir, el echo de que los atributos provenientes de la matriz de co-ocurrencias trabajen bien en un cierto tipo de región y los momentos de orden cuatro trabajan bien en otra cierta región (observar la parte correspondiente a resultados). Esta combinación

es eficaz porque el *esclavo* es llamado únicamente en las regiones donde el *maestro* no puede decidir.

3 Resultados

Una vez definida la metodología, así como el protocolo experimental, pasamos a comparar los resultados en segmentación.

Se generó un mosaico de cuatro texturas [Brodatz, 1966]. De cada textura se obtuvieron sus parámetros representativos vía la matriz de co-ocurrencias y vía los momentos de orden cuatro. La estimación se realizó tomando 100 ventanas aleatoriamente de talla 16×16 píxeles y de talla 32×32 píxeles para co-ocurrencias y momentos de orden cuatro respectivamente. Así se generaron cuatro bases de datos para el aprendizaje de un clasificador gaussiano [Fukunaga, 1990]. Este clasificador se eligió por su buen desempeño [Avilés, 1995]. El desempeño de los atributos solos fue evaluado en segmentación, como el porcentaje de una segmentación correcta en el mosaico, sabiendo la disposición de las máscaras de las texturas para este tipo de mosaico. Los resultados son mostrados en la Figura (parte derecha de la Gráfica 3). Estos resultados servirán como referencia para evaluar el proceso de fusión. Los valores denotados como M_4F corresponden a una versión filtrada al momentos de hacer la estimación de momentos de orden cuatro [Amblard *et al.*, 1994; Amblard & Brossier, 1995].

La forma de evaluar el desempeño fue a través de la matriz de confusión promediada sobre 20 realizaciones diferentes. Del total de muestras, se tomó el 50 % para el aprendizaje y el 50 % restante fue para la etapa de prueba.

En cuanto a los resultados de los atributos solos, los atributos de la matriz de co-ocurrencias y los momentos de orden cuatro generan el mismo desempeño (87.88% y 87.87% respectivamente), Figura 3.

Los resultados de las arquitecturas en paralelo (Figura 3) no son del todo superiores a los resultados de los atributos aislados. Una explicación es que los dos clasificadores (co-ocurrencias y momentos) se equivocan con una alta probabilidad, como el sistema de fusión no puede decidir a que clase pertenece, los píxeles son rechazados.

Resultado gráfico: Por motivos de espacio se muestran únicamente los resultados de segmentación con la arquitectura paralelo, fusionando las probabilidades *a posteriori* con el criterio de valor máximo (Figura 3). Sobre la figura se muestra claramente que los atributos

de la matriz de co-ocurrencias tienen problemas para discriminar en las zonas francas de un solo tipo de textura. En contraparte, los momentos de orden cuatro tienen problemas en las regiones de fronteras. La ambigüedad en las regiones de transición para los momentos de orden cuatro se debe al tamaño de la ventana dado que la talla de demasiado grande.


4 Conclusiones

En el presente artículo se implementaron varias técnicas de fusión de datos: fusión de probabilidades *a posteriori*, fusión a través de la teoría de Bayes y fusión por la teoría de la Evidencia, en aplicación a la segmentación de texturas de grano fino. De los resultados, podemos concluir que la fusión aporta una mejora de 12% en segmentación, con respecto a la segmentación utilizando los atributos aisladamente.

En fusión, el mejor resultado se obtuvo utilizando la fusión en paralelo. Este resultado era previsible si se toma en cuenta que en paralelo se cuenta con más información al mismo tiempo (2 veces más) para poder conformar un criterio de decisión más robusto. Sin embargo, los resultados con las arquitecturas serie y paralelo son completamente comparables. El mejor resultado en arquitectura en paralelo se obtuvo con la fusión de probabilidades *a posteriori* con el criterio del valor máximo.


La proximidad de los resultados en paralelo y en serie, se debe a un fenómeno de sinergia entre los atributos utilizados, es decir, los atributos de la matriz de co-ocurrencias se desempeñan bien cerca de los bordes (ventanas de estimación más pequeñas, 16×16 píxeles) pero no son muy eficaces en largas zonas correspondientes a un solo tipo de textura. Para estas últimas regiones trabajan bien los momentos de orden cuatro (ventanas de estimación de 16×16 píxeles). Como se toman en cuenta más píxeles para hacer la estimación, el rango de incertidumbre es mucho más pequeño.

Finalmente el problema que queda abierto es la localización de los bordes. Este problema se puede analizar tanto en el dominio de los atributos como en algún espacio de proyección. La continuidad de este trabajo será orientada hacia el análisis de los puntos frontera, con el fin de identificar si los puntos de transición generan clases adicionales y se enmascaran en las clases existentes.




(a)

Mosaico texturas d04, d09, d24 y d57




(b)




(c)


Maestro (M2), Esclavo (M4)



(d)




(e)



(f)

Maestro (M4), Esclavo (M2)



(g)

Figura 4: Segmentación con la arquitectura “Maestro-Eslavo” Juego de cuatro texturas d04, d09, d24 y d57 : (a) Mosaico, (b) Resultado de la segmentación, (c) Maestro (M2), (d) Esclavo (M4), (e) Resultado de la segmentación, (f) Maestro (M4), (g) Esclavo (M2).

Referencias

Amblard P.O. and J. M. Brossier, *Adaptative Estimation of the Fourth-Order Cumulant of an I.I.D. Stochastic Process*, February, 1995.

Amblard P.O., J. M. Brossier and N. Charkani, "New Adptative Estimation of the Fourth-Order Cumulant: Application to Transient Detection, Blind Deconvolution and Timing Recovery in Communication." In M.J.J. Holt, C.F.N. Cowan, P.M. Grant and W.A. Shandam, Eds. *Signal Processing VII, Theories and Applications*, Elsevier, Edinburgh, Scotland, 1994.

Asar H., N. Nandhakumar and J.K. Agrawal, "Pyramid-Based Images Segmentation Using Multi-Sensory Data," *Pattern Recognition*, 1990.

Avilés-Cruz C., et al., *Enhanced Learning for Evaluative Neural Architectures ELENA*, D Facto, ESPRIT III Basic Research Action (No. 6891). Project Results and Industrial Openings, Brussel-Belgium, 1995.

Avilés-Cruz C. and A. Guérin-Dugué, "Texture Discrimination Enhancement by Fusion with Second and Fourth Order Statistics," *Signal Processing VII, Theories and Applications*, Elsevier, 1996.

Brodatz P., *Textures: A Photographic Album for Artists and Designers*; Dover Publications, Inc., 1966.

Chu C.C. and J.K. Aggrawal, "Image Interpretation Using Multiple Sensing Modalities," *IEEE Trans. on Pattern Analysis and Machine Intelligence*, 1992.

Crowley J. L. and Y. Demazeau, "Principles and Technics for Sensor Data Fusion," *Signal Processing*, 1993.

Duvaut P., L. Hayon and J.P. Guyvarch, "Regroupement Optimal des Captures en Traitement du Signal," *Traitement du Signal*, 1993.

Fukunaga K., *Introduction to Statistical Pattern Recognition* Academic Press, INC., 1990.

Houzelle S. and G. Giraudon, "Extraction Automatique d'Objets par Fusion de Donnes d'Images de Satellites," *AF CET, 8me Congr Reconnaissance de Formes et Intlligence Artificielle*, Lyon, France, 1991.

Luo R.C. and M.H. Lin, "Robot Multisensor and Integration: Optimum Estimation of Fused Sensor Data," *Ch2555-1/88/0000/1060\$01-00 IEEE*, 1988.


Luo R.C., M.H. Lin and R.S. Scherp. "The Is-

sues and Approches of a Robot Multi-Sensor Integration," *Ch2413-3/87/0000/1941\$01-00 IEEE*, 1987.

Mohan R. and R. Nevatia. "Perceptual Organization for Scene Segmentation and Description," *Trans. on Pattern Analysis and Machine Intelligence*, 1992.

Shafer G., *A Mathematical Theory of Evidence*, N.J. USA, Princeton University Press, 1976.

Xu L., A. Krzyzak and C.Y. Suen, "Methods of Combining Multiple Classifiers and Their Applications to Handwriting Recongition," *IEEE Transaction Systems, Man. and Cybernetics*, 1992.



Carlos Avilés Cruz, obtuvo el título de Ingeniero en Electrónica especialidad en Sistemas Digitales en la Universidad Autónoma Metropolitana en 1991, el grado Maestro con especialidad en Procesamiento Digital de Señales, Imágenes y Voz en el Instituto Politécnico Nacional de Grenoble en 1993 y el grado de Doctor del Instituto Politécnico Nacional de Grenoble en 1997. Tiene el nombramiento de profesor-investigador Titular "A" en la U.A.M. de Azcapotzalco. Es autor y coautor de más de 15 artículos en revistas y congresos nacionales e internacionales, además de coautoría de un libro. Sus intereses son la visión por computadora, el procesamiento digital de imágenes, el procesamiento digital de señales y la estadística de orden superior. El Dr. Avilés es candidato a investigador del SNI.

