

TRANSFORMADA DISCRETA BIDIMENSIONAL DE GABOR PARA EL ANALISIS DE IMAGENES DE TEXTURAS

Margarita Fernández, Adriana Mavilio, Manuel Tejera y Raúl Lorenzo

Laboratorio de Optica Coherente, Dpto. de Física, Instituto Superior Politécnico "José A. Echeverría"

RESUMEN

En este trabajo la transformación bidimensional de Gabor es implementada a través de una notación matricial (Jie Yao, 1993). A partir del espectro de potencia de la imagen y de los correspondientes a los patrones que definen el conjunto de clases, se realiza la clasificación y segmentación por textura. Se estudia el efecto que sobre el análisis de la textura tienen los valores del ancho de la ventana y de la σ de la gaussiana.

ABSTRACT

In this paper, the 2-D Gabor transformation is implemented through a matrix notation (Jie Yao, 1993). The classification and segmentation by texture is done using the power spectrum of the image and of the patterns, which define the set of classes. The effect of the window's dimensions and the σ value of the gaussian function on the analysis of texture is studied.

INTRODUCCION

El análisis de texturas es útil en muchas aplicaciones de procesamiento de imágenes, como: la visión robótica, la inspección industrial, la interpretación de datos sísmicos y el fotoanálisis (Wu, 1992; Vinther, 1995; Tejera, 1996). En los últimos años se ha reportado un gran número de trabajos que utilizan diferentes métodos con el fin de realizar la identificación de los patrones visuales sobre la base de su textura. Cada método es generalmente más eficiente para un conjunto particular de clases de texturas, pues hace uso de los descriptores que mayor información brindan para discriminarlas (Haralick, 1979).

Entre las técnicas más usuales se encuentran las de las transformadas digitales, las cuales se relacionan directamente con la determinación de la composición en frecuencias espaciales de la imagen. Un caso particular es el de la Transformada de Gabor 2-D, que resulta de utilidad en los problemas de análisis y segmentación de imágenes, ya que extrae localmente la información espectral bidimensional concerniente a la textura, cosa que no es posible lograr con la Transformada de Fourier (Daugman, 1985). En el trabajo de Daugman, 1988 se realiza la segmentación de una imagen que representa un mosaico de campos de ruido blanco filtrados, de manera que cada zona corresponde a diferentes orientaciones del filtro, para lo cual se hace uso del espectro de potencia de Gabor, obtenido a través de una red neuronal

por un método de optimización. Aquí se demuestra la posibilidad de utilizar el espectro de Gabor con estos fines, pero no se hace énfasis en esto, sino en el trabajo de la red neuronal para calcular los coeficientes de la expansión de Gabor, que se propone en este artículo.

En el trabajo de Manian y otros (Manian, 1997) se utilizan diferentes funciones bases, entre ellas la de Gabor, para la segmentación de imágenes sobre la base a su textura utilizando descriptores clásicos de textura (media, desviación estándar, etc.), calculados sobre la base de los coeficientes de la expansión.

En nuestro trabajo se lleva a cabo la clasificación y segmentación de imágenes sobre la base de las características del espectro de potencia de Gabor obtenido por el método matricial propuesto por Jie Yao (Yao, 1993), que utiliza un algoritmo rápido para el cálculo de los coeficientes correspondientes a la Transformada 2-D Discreta de Gabor. Se estudia el efecto que sobre el análisis de la textura tienen los valores del ancho de la ventana y de la σ de la gaussiana.

TRANSFORMADA DISCRETA 2-D DE GABOR

Para una imagen 2-D discreta $f(x,y)$, $x = \{0,1,2,\dots, X-1\}$, $y = \{0,1,2,\dots, Y-1\}$, la Transformada Discreta 2-D de Gabor se expresa según:

$$f(x,y) = \sum_{m=0}^{K-1} \sum_{n=0}^{L-1} \sum_{r=0}^{M-1} \sum_{s=0}^{N-1} a_{mnrs} g_{mnrs}(x,y) \quad (1)$$

Siendo $X = KM$ y $Y = LN$, , donde K y L son el número de ventanas en que se divide la imagen, según los ejes x y y , M y N son las cantidades de pixeles que contienen estas ventanas; a_{mnrs} son los coeficientes de Gabor, en tanto que $g_{mnrs}(x,y)$ son las funciones elementales de Gabor dadas por:

$$g_{mnrs}(x,y) = \exp \left\{ -\pi \left[\frac{(x - mM)^2}{\sigma_x^2} + \frac{(y - nN)^2}{\sigma_y^2} \right] \right\} \times \exp \left\{ -2\pi i \left[r \frac{x}{M} + s \frac{y}{N} \right] \right\} \quad (2)$$

De manera semejante a como se realiza para la Transformada Ventana de Fourier, se obtiene el espectro de potencia para la región de la imagen contenida en cada ventana de Gabor:

$$P_{mnrs} = a_{mnrs} a_{mnrs}^* \quad (3)$$

La transformación completa de Gabor puede ser expresada en notación matricial. Los coeficientes de Gabor se hallan mediante multiplicaciones de la matriz imagen por las matrices inversas de Gabor (Jie Yao, 1993).

INFLUENCIA DE LA CONSTANTE σ DE LA GAUSSIANA SOBRE EL ESPECTRO DE GABOR

Para llevar a cabo este estudio se modeló una imagen formada por dos regiones, cuyas características texturales eran periódicas en el eje x , con frecuencias espaciales $f_x = 0.2$ y $f_x = 0.35$ respectivamente, y constantes en el eje y . Se obtuvieron los espectros de potencia de Gabor de la imagen para $K = 4$, $M = 100$ para diferentes valores de la constante σ de la función ventana. A partir de las matrices de dichos espectros de potencia, realizando un barrido por columnas, se construyeron los vectores de potencia P_x , seleccionando el valor máximo por filas, para cada una de las ventanas de la muestra.

En la Figura 1 se muestra el barrido del espectro de potencia para las ventanas ubicadas a ambos lados de la frontera que separa las regiones de diferente textura para valores de (a) $\sigma = 100$, (b) $\sigma = 150$ y (c) $\sigma = 50$. En las Figuras 1a) y 1b) se observa claramente la contribución de ambas frecuencias dentro del espectro de cada zona, siendo el aporte relativo de las frecuencias no deseadas mayor en el caso (b), lo cual ocurre debido a que en este caso es mayor la penetración de la función ventana en las zonas vecinas. Se observa además la degradación del espectro correspondiente al caso (c), debido a

la alteración que sufre la información que porta la imagen, provocada por la gaussiana, que en este caso cae más bruscamente.

Es notorio que mientras mayor es σ mejor es la calidad del espectro, pero al mismo tiempo se pueden introducir aportes de frecuencias no deseadas que provengan de las ventanas vecinas; por otra parte, mientras menor es el valor de este parámetro, mayor es la degradación del espectro de la zona.

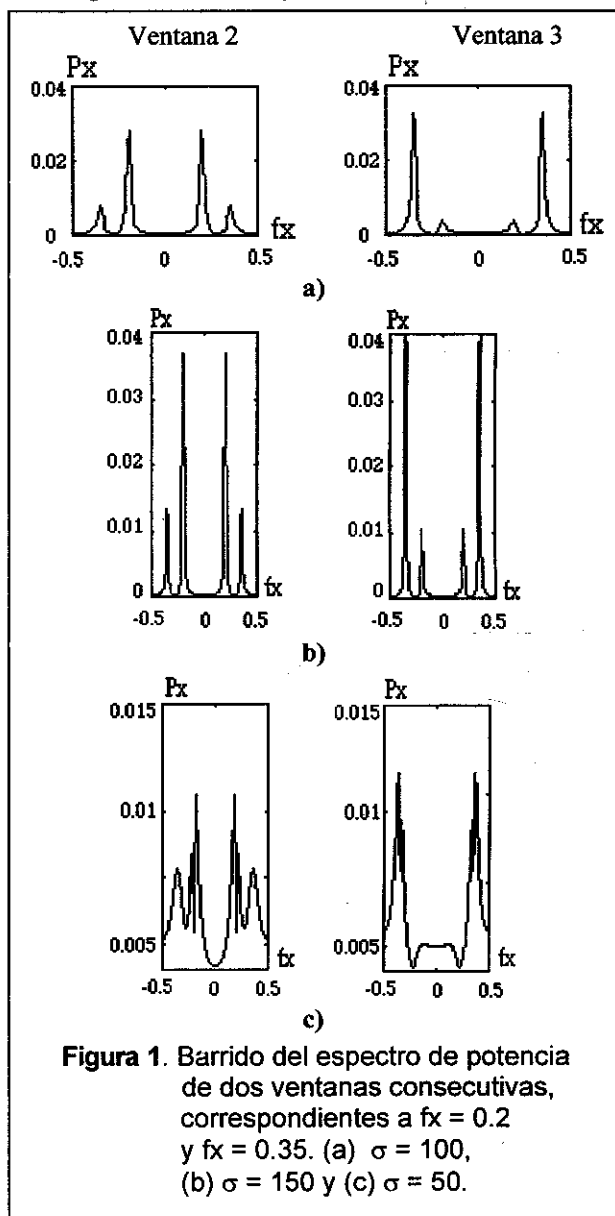



Figura 1. Barrido del espectro de potencia de dos ventanas consecutivas, correspondientes a $f_x = 0.2$ y $f_x = 0.35$. (a) $\sigma = 100$, (b) $\sigma = 150$ y (c) $\sigma = 50$.

INFLUENCIA DEL TAMAÑO DE LA VENTANA EN LA CALIDAD DE LA SEGMENTACION

Para realizar las segmentaciones de las imágenes utilizamos como descriptores a los elementos de la matriz del espectro de potencia de

Gabor. El proceso de segmentación se realizó clasificando cada porción de la imagen contenida en una ventana, mediante la correlación de su espectro de Gabor con el de cada patrón, siendo el criterio de selección el de máxima correlación. Los patrones empleados presentan características texturales similares a las de las imágenes a segmentar.

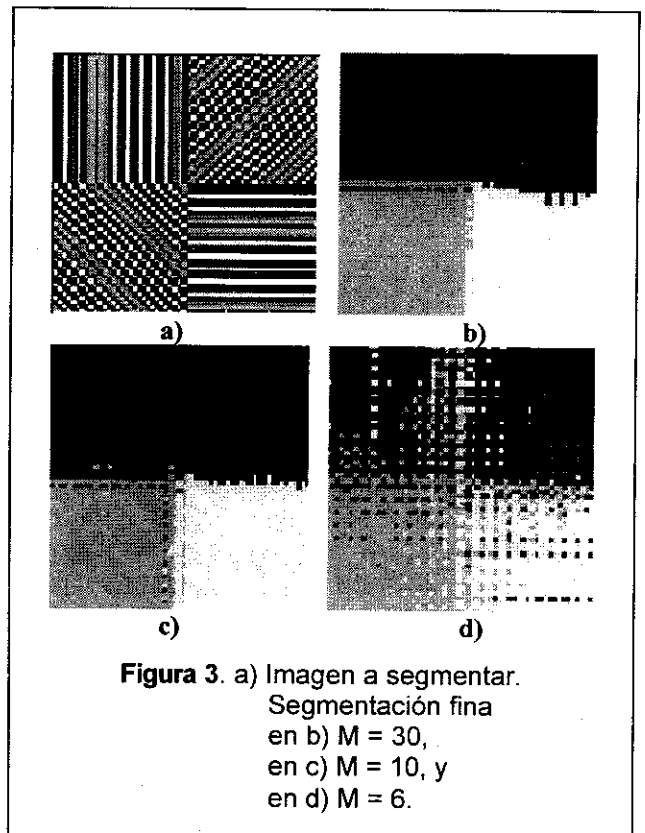
Se analizaron dos variantes para la realización de la segmentación a las que podemos denominar segmentación gruesa y segmentación fina. La diferencia entre ambas consiste en que en la primera se divide toda la imagen en ventanas de Gabor, todos los puntos de las cuales se identifican con el patrón correspondiente a la clasificación de la región contenida en la ventana. En la segmentación fina, se cubre con ventanas de Gabor un área de tamaño menor al de la imagen a segmentar, la cual se selecciona de tal forma que, desplazándola pixel a pixel hasta completar las dimensiones de una ventana ($M \times N$ píxeles), se logre barrer la imagen en su totalidad. El resultado de la clasificación de cada ventana se le asigna al pixel central de la misma.



En la Figura 2a) se presenta una de las imágenes modeladas, similar a la empleada en el experimento del epígrafe anterior. El resultado de la segmentación fina, para un área de Gabor de 30×60 píxeles y empleando ventanas de diferentes tamaños, es mostrado en 2b) ($M = 30$ y $M = 10$) y en 2c) ($M = 6$). De igual manera, la figura 2b), muestra el comportamiento de la segmentación gruesa para los dos valores mayores de ventana. Para $M = 6$ la segmentación resultó deficiente con ambos procedimientos, lo cual es imputable al hecho de ser el tamaño de la ventana comparable al período espacial de la imagen.


En la Figura 3a) se muestra una imagen modelada periódica compuesta por cuatro zonas que se caracterizan por tener las mismas componentes de frecuencias espaciales ($f = 0$, $f = 0.35$) pero arregladas de tal manera que resultan texturas con diferentes orientaciones en el espacio bidimensional. En las Figuras 3b), c) y d) se presentan los resultados de la segmentación fina para valores de $M = 30$, 10 y 6 respectivamente, utilizándose un área de Gabor de 60×60 píxeles. Se observa cómo en el caso $M = 10$ mejora la definición de la frontera con relación al caso $M = 30$, lo cual es un resultado a esperar pues la indeterminación espacial disminuye. Sin embargo en el caso d) $M = 6$ la segmentación es deficiente, debido a que ahora el período espacial es comparable con el tamaño de la ventana y la indeterminación en el espectro de frecuencia es mayor que en los casos anteriores.

Es de destacar que el resultado de la segmentación gruesa de la imagen mostrada en la Figura 3a), para $M = 30$ y $M = 10$ resultó excelente (no se muestra), es decir, la clasificación fue exitosa y con las fronteras bien delimitadas. Para este tipo de imágenes, que pueden ser divididas de manera que las ventanas de Gabor encajen perfectamente en zonas características texturales bien definidas, es suficiente con la segmentación gruesa.



CLASIFICACION Y SEGMENTACION DE IMAGENES DE TEXTURA ALEATORIA


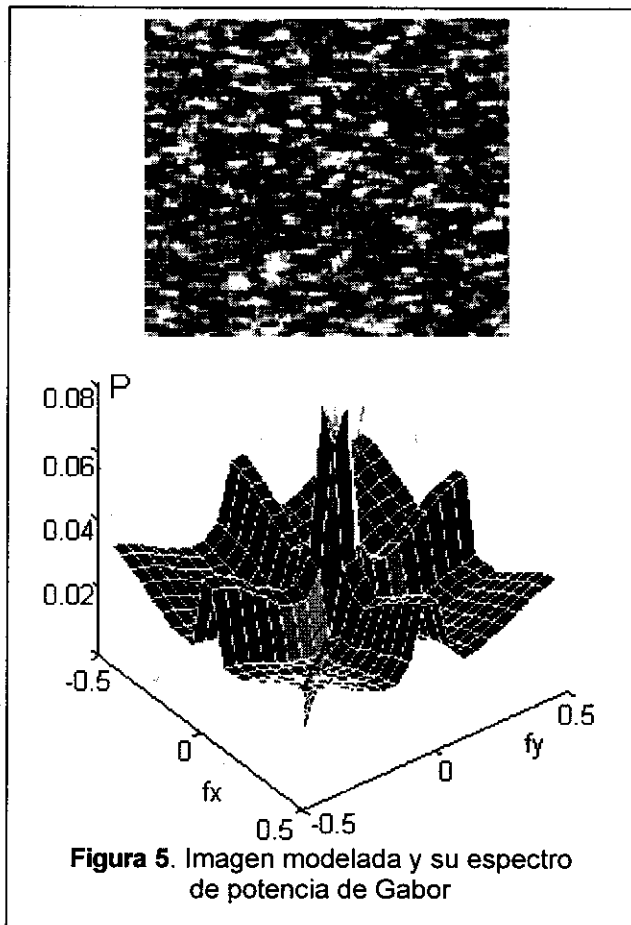
En esta sección mostraremos los resultados obtenidos con imágenes modeladas de textura aleatoria, generadas empleando la teoría de los filtros lineales, lo cual nos permitió controlar parámetros de la estadística de segundo orden tan importantes como la función de autocorrelación.



Específicamente se eligió una función de autocorrelación del tipo mostrado en la Figura 4, fijando valores particulares de las longitudes de correlación en los ejes x y y .

La Figura 5 muestra la imagen modelada, a la cual pertenecen las funciones de correlación presentadas, y su espectro de potencia de Gabor.

A partir de estas texturas modeladas se crearon mosaicos a los que les fue aplicado el método de segmentación gruesa. En la Figura 6 se aprecia uno de dichos mosaicos de dimensiones 120×120 píxeles y los resultados de las segmentaciones empleando ventanas de ancho $M = 30$, $M = 24$ y $M = 20$.



Al emplearse ventanas de ancho $M = 24$, los puntos frontera entre las dos zonas de diferentes texturas se sitúan en el centro de una ventana, por lo que es de esperar que, con independencia del resultado de la clasificación de esta zona, la frontera aparezca desplazada de su posición real. El efecto mencionado no se presenta en los casos donde se emplean ventanas con $M = 30$ y $M = 20$. Observamos que al disminuir el número de píxeles de las ventanas empeora el resultado de la segmentación, lo cual evidentemente se relaciona con la pérdida de información sobre la textura.

CONCLUSIONES

El estudio de la influencia del valor σ en la composición del espectro corroboró que existe un compromiso al establecer el valor de esta constante en relación con las dimensiones de la ventana. Valores de σ pequeños implican degradación del espectro, por dejar de considerarse la información contenida en parte de la ventana; en cambio, valores grandes, introducen información espectral correspondiente a las ventanas vecinas. Es recomendable emplear valores de σ aproximados al ancho de la ventana al segmentar imágenes.

Las dimensiones de la ventana deben ser mayores que las de los elementos texturales, de tal forma que en la región contenida en la misma exista

la información suficiente como para caracterizar una textura. Para la segmentación se debe tomar en cuenta el compromiso existente entre una mejor caracterización de la textura en una ventana grande y una peor calidad en la definición de los bordes entre zonas de texturas diferentes.

La segmentación gruesa aventaja a la fina en cuanto a costo computacional; no obstante, esta es sólo recomendable para imágenes en las cuales las zonas de igual textura puedan contener un gran número de ventanas cuyas dimensiones permiten una eficiente caracterización de la textura. Obviamente, la condición anterior se cumple cuando los elementos texturales son mucho menores que las zonas de igual textura de menor tamaño presentes en la imagen. La segmentación fina, a pesar del mayor volumen de cálculo que requiere, permite una mejor definición de los bordes.

En este trabajo se ha demostrado que la transformación discreta de Gabor puede ser utilizada efectivamente para la clasificación y segmentación de imágenes de textura, tomando como descriptores los elementos matriciales de su espectro de potencia. La transformada de Gabor es especialmente útil para discriminar regiones texturales que se caracterizan por tener diferentes orientaciones de sus elementos estructurales.

REFERENCIAS

1. CH, WU (1992): "Statistical Feature Matrix for Texture Analysis". CVGIP: Graph. Models Imag. Process. 54(5), 407.
2. VINTHER, R. (1995): "Seismic texture classification: To computer-aided approach to stratigraphic analysis, 65th Annual Internat. Mtg; Soc. Expl. Geophys; Expanded Abstracts, 153-155.
3. TEJERA y otros (1996): "Dimensiones promediadas como descriptores de la textura". Memorias del Foro Iberoamericano de Procesamiento de Imágenes. Valencia.
4. _____ (1996): "Aplicación del Método de Histogramas Suma y Diferencia para la clasificación de texturas en la medicina y la metalografía". Memorias del Foro Iberoamericano de Procesamiento de Imágenes. Valencia.
5. HARALICK, R.M. (1979): "Statistical and Structural Approaches to texture". Proc. IEEE. 67(5), 786.
6. DAUGMAN, J.G. (1988): "Complete Discrete 2-D Gabor Transforms by Neural Networks for Image Analysis and Compression". IEEE Trans. on Acoustics, Speech and Signal Processing 36(7), 1169.
7. YAO JIE (1993): "Complete Gabor transformation for signal representation", IEEE Trans. on Imag. Proces. 2(2), 152.
8. MANIAN, O. (1997): "On scaled and rotated texture segmentation using a class of basis functions. SPIE 3078. 0277-786X/97.