



**I
N
A
D
E**

Componente Determinista de la Descomposición de Wold 2-D para Obtener Descriptores de Textura y Descubrir Geometría

Erika Danaé López Espinoza, Leopoldo Altamirano Robles

**Reporte Técnico No. CCC-07-001
24 de Septiembre del 2007**

©Coordinación de Ciencias Computacionales
INAOE

Luis Enrique Erro #1
Sta. Ma. Tonantzintla,
72840, Puebla, México



Componente Determinista de la Descomposición de Wold 2-D para Obtener Descriptores de Textura y Descubrir Geometría

Erika Danaé López Espinoza Leopoldo Altamirano Robles

Coordinación de Ciencias Computacionales

Instituto Nacional de Astrofísica, Óptica y Electrónica

Luis Enrique Erro # 1, Santa María Tonantzintla, Puebla, 72840, México

E-mail: {danae, robles}@inaoep.mx

Abstract

En este trabajo el componente determinista de la descomposición de Wold 2-D es empleado para obtener descriptores de textura en imágenes industriales y descubrir geometría de corona de árbol en imágenes de percepción remota. La imagen es descompuesta en dos campos de textura: uno determinista y otro no-determinista. Con el objetivo de obtener descriptores de textura, un conjunto de características discriminantes es seleccionado a partir de la imagen del componente determinista. Los descriptores de textura obtenidos son empleados para clasificar tres tipos de calidad de plástico industrial. Estos descriptores son comparados contra los descriptores de textura obtenidos a partir de la imagen original. Con el objetivo de encontrar la geometría presente de diferentes coberturas terrestres, en imágenes satelitales y aéreas, el componente determinista de la imagen es analizado. La geometría observada es comparada contra la geometría modelada en la literatura de procesos puntuales marcados.

1 Introducción

Los métodos de análisis de textura pueden ser divididos en dos enfoques [1, 2]: el *enfoque estadístico o estocástico* y el *enfoque estructural*.

La primera categoría trata a la textura como fenómeno estadístico. La textura es descrita mediante las propiedades estadísticas de las intensidades y posiciones de los píxeles. La formulación estocástica de una textura se basa en un modelo en el cual la textura es vista como un proceso estocástico bi-dimensional descrito por sus parámetros estadísticos.

La segunda categoría llamada, el enfoque estructural, introduce el concepto de primitivas de textura, a veces llamadas textels¹ o textons. Para describir una textura es necesario un vocabulario de textels y una descripción de sus relaciones. El objetivo es entonces describir estructuras complejas mediante primitivas simples. Los modelos de texturas estructural trabajan mejor con texturas con construcciones claras. Estos modelos basados en primitivas han sido ampliamente empleados para explicar la percepción humana de las texturas

¹Un texel (del inglés, texture element o también texture pixel) es la unidad mínima de una textura aplicada a una superficie, empleada en gráficos por computadora. De la misma forma, que una imagen digital se representa mediante una matriz de píxeles, una textura se puede representar mediante un matriz de texels.

[1].

En el enfoque estructural, se destaca la estructura espacial de la textura; de acuerdo a Faugeras y Pratt [3], el enfoque determinista considera a la textura de un patrón local básico que periódicamente o cuasiperiódicamente es repetido en una región. Cross y Jain [4] definen al enfoque estructural como un conjunto de reglas que especifican las posiciones de las primitivas sobre la imagen y con respecto a otras primitivas. Sin embargo, el problema de tener dos tipos de enfoques es que: “Las texturas contienen características regulares y estadísticas. En la práctica uno puede encontrar texturas desde completamente periódicas hasta completamente aleatorias. Por esto es difícil clasificar a las texturas por medio de algún sólo método [5].” De esta forma, se han propuesto modelos unificados en los cuales se separan la parte determinista y no-determinista del campo de textura. La *Descomposición de Wold* [2, 6, 7, 8, 9, 10], es uno de los métodos que lleva a cabo esta separación. El modelo de textura unificado propuesto por Francos *et al.* [2] proporciona un medio para analizar la parte determinista o estructural y la parte estocástica o no-determinista de la textura. La descomposición de Wold 2-D ha sido aplicada en diversas tareas, desde la recuperación de imágenes [11] hasta para estimar y codificar la textura [10]. En [8] es empleada la Transformada de Hough para detectar los componentes evanescentes espectrales, mientras que en [9] se da un nuevo algoritmo de estimación del campo evanescente. Este nuevo método requiere de un conjunto de direcciones de proyección las cuales son obtenidas empleando la serie de Farey. Trabajo actual propone un nuevo algoritmo de segmentación el cual toma en cuenta el componente determinista de la descomposición como la imagen del campo externo en un modelo basado en CAM [7]. Mientras que en [12] se están explotando propiedades estadísticas de orden superior y la teoría de la descomposición de Wold para desarrollar un algoritmo de descomposición de textura 3-D.

En el modelo propuesto por Francos, el campo de textura es asumido a ser una realización de un campo aleatorio homogéneo 2-D. Basado sobre la descomposición de Wold-like 2-D de campos aleatorios homogéneos, el campo de textura es descompuesto dentro de una suma de componentes mutuamente ortogonales: un componente determinista, el cual representa los atributos estructurales de la textura, y un componente no determinista o puramente estocástico, el cual representa la aleatoriedad del campo. El componente determinista es posteriormente descompuesto en dos componentes ortogonales: un componente armónico y un componente evanescente generalizado. El componente armónico representa los atributos periódicos de la textura, mientras que los componentes evanescentes representan la direccionalidad. Así, las propiedades perceptibles de la imagen de textura: aleatoriedad, direccionalidad y periodicidad son preservadas. (ver Fig. 1).

La discriminación de la textura juega un papel vital en la segmentación y extracción de objetos en imágenes del mundo real. Con el objetivo de obtener esta discriminación, buenas características de textura tienen que ser extraídas. Una buena característica de textura debería determinar la similitud dentro de las clases y disimilitud entre las clases. En aplicaciones industriales es frecuente clasificar texturas similares que se encuentran en diferentes clases, siendo así necesario considerar descriptores de textura útiles para estos problemas de clasificación.

La extracción automática de objetos en imágenes satelitales es una tarea de investigación importante en problemas de reconocimiento de patrones y entendimiento de imágenes. Muchos objetos en imágenes de satélite tienen atributos de forma regular tales como círculo, elipses polígonos, etc. y están comúnmente distribuidos ordenadamente en grupos. La extracción automática de corona de árboles en imágenes de satélite por medio de procesos puntuales marcados es reportado en [13]. Perrin *et al.* modela una superficie como una realización de un proceso puntual marcado de elipses o elipsoides cuyos puntos son las posiciones de los árboles y las marcas las características geométricas. Sin embargo, hay otros recursos naturales importantes que se desean estudiar en la escala de árboles cuya geometría es desconocida por ejemplo manglar.

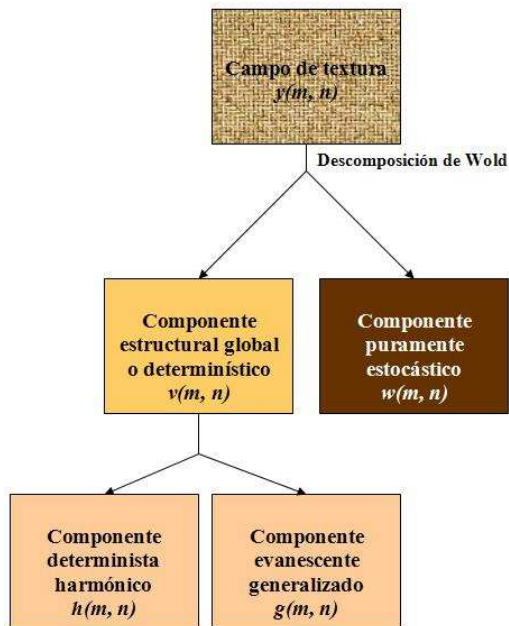


Figura 1. El modelo de textura unificado: Descomposición de Wold.

En este trabajo, motivados por el modelo de Francos, el cual permite un análisis individual de los componentes debido a que la textura es descompuesta en sus partes constituyentes. El componente determinista de la descomposición es empleado para obtener descriptores de textura de tres clases de calidad de plástico industrial y además es empleado para encontrar geometría oculta de corona de árbol en imágenes de satélite. El algoritmo implementado esta basado en el proceso de campo armónico de [2] y en el proceso de campo evanescente de [8]. Los descriptores de textura son comparados contra los descriptores de textura obtenidos a partir de la imagen original y la geometría observada es comparada contra la geometría modelada en la literatura de procesos puntuales marcados.

2 Descomposición de Wold de Campos Aleatorios Homogéneos

Sea $y(n, m)$, $(n, m) \in Z^2$ un campo aleatorio homogéneo regular. La descomposición de Wold 2-D permite descomponer al campo dentro de dos componentes mutuamente ortogonales:

$$y(n, m) = v(n, m) + w(n, m) \quad (1)$$

donde $\{v(n, m)\}$ es el componente determinista y $\{w(n, m)\}$ es el componente no-determinista. El componente determinista $\{v(n, m)\}$ de un campo aleatorio homogéneo regular 2-D puede ser representado por la siguiente descomposición ortogonal:

$$v(n, m) = h(n, m) + g(n, m) \quad (2)$$

donde $\{h(n, m)\}$ es el campo aleatorio armónico y $\{g(n, m)\}$ es llamado el campo aleatorio evanescente generalizado. El campo evanescente generalizado es una combinación lineal de un número contable de campos evanescentes mutuamente ortogonales.

En el dominio de las frecuencias, la función de distribución espectral $F(w, v)$ de $y(n, m)$ puede ser representada por las funciones de distribución espectral de los campos componentes:

$$F(w, v) = F_w(w, v) + F_v(w, v) \quad (3)$$

donde $F_w(w, v)$ es la función de distribución espectral del componente puramente no-determinista $\{w(n, m)\}$ y $F_v(w, v)$ es la función de distribución espectral del componente determinista $\{v(n, m)\}$. La función de distribución espectral $F_v(w, v)$ del componente determinista del campo regular, es representada por:

$$F_v(n, m) = F_h(w, v) + F_g(w, v) \quad (4)$$

Franco propone los siguientes modelos para cada uno de los campos. El campo aleatorio armónico tiene la siguiente representación:

$$h(n, m) = \sum_{k=1}^P \{C_k \cos 2\pi(n\omega_k + mv_k) + D_k \sin 2\pi(n\omega_k + mv_k)\} \quad (5)$$

donde las C_k 's y D_k 's son variables aleatorias mutuamente ortogonales, y (ω_p, v_p) son las frecuencias espaciales de las k 's armónicas. Este componente genera las funciones delta 2-D de la "densidad espectral" (Las funciones delta 2-D son funciones singulares soportadas sobre puntos discretos en el plano de las frecuencias).

Un modelo para el campo evanescente $\{g(n, m)\}$, el cual corresponde a las RNSHP (rational non-symmetrical half-plane) definido por $(\alpha, \beta) \in O$ esta definido mediante una combinación lineal de campos $e(n, m)$ de la forma:

$$e(n, m) = s(n) \sum_{i=1}^I \{A_i \cos 2\pi m v_i + B_i \sin 2\pi m v_i\} \quad (6)$$

donde $\{s(n)\}$ es un proceso 1-D no-determinista puro, I es el número de componentes evanescentes con inclinación (α, β) y v_i es la frecuencia del i -ésimo componente evanescente.

El componente no-determinista esta definido como:

$$w(n, m) = - \sum_{(0,0) \prec (k,l)} b(k, l) w(n-k, m-l) + u(n, m) \quad (7)$$

donde $\{u(n, m)\}$ es el campo de inovación blanco 2-D, cuya varianza es σ^2 .

Más detalles de las ecuaciones (5), (6) y (7) pueden ser encontrados en [2].

2.1 Algoritmo de Estimación

El algoritmo de estimación se presenta en la tabla 2.1. La implementación de la descomposición de Wold y algunos resultados para encontrar la geometría en coberturas terrestres en imágenes de percepción remota son mostrados en la siguiente sección.

3 Implementación

En general, el algoritmo de análisis de Franco se divide en tres etapas:

1. Primero, se estiman los parámetros del campo armónico (características periódicas),

-
- Algoritmo**
- 1) Probar la existencia de componentes deterministas. (Probar la existencia de funciones delta 1-D y 2-D en el periodograma).
 - 2) Construir un filtro donde sea “1” en las funciones delta 2-D detectadas, y “0” en otro caso.
 - 3) Filtrar la TDF (Transformada Discreta de Fourier) por medio del filtro del paso 2 y calcular la transformada inversa para obtener el componente armónico.
 - 4) Remover la contribución del componente armónico estimado desde los datos.
 - 5) Construir un filtro donde sea “1” en las frecuencias de las funciones delta 1-D detectadas, y “0” en otro caso.
 - 6) Filtrar la TDF por medio del filtro del paso 5, y calcular la transformada inversa para obtener el componente evanescente.
 - 7) Remover en los datos la contribución del componente evanescente. En esta etapa la imagen ya no contiene componentes deterministas.
 - 8) Aplicar un algoritmo tipo Levinson 2-D para estimar los parámetros del modelo AR 2-D de la imagen residuo o componente no-determinista puro.
-

Tabla 1. Algoritmo de Estimación.

2. Segundo, se estima el componente evanescente de la textura (características de direccionalidad),
3. Finalmente, se estiman los parámetros del componente puramente no determinista del campo de textura (características aleatorias).

La reconstrucción de la textura se realiza sumando la imagen obtenida por el procedimiento inverso a el procedimiento de análisis. Nos interesa analizar el componente determinista del algoritmo de análisis, debido a que a partir de él se busca definir la geometría de una cobertura de la tierra. Esto es posible puesto que el componente es parametrizado independientemente del componente puramente no determinista. El procedimiento para obtener el componente determinista es obtenido mediante el procedimiento de umbralización global, propuesto en [2], el cual estima el campo de textura armónico, y un procedimiento propuesto en [8] basado en la transformada de Hough para obtener el componente evanescente. El algoritmo para obtener el componente fue desarrollado en MATLAB 7.1, Fig. 2. Los detalles de implementación se presentan en las siguientes secciones.

3.1 Detección de Picos Armónicos

Primero se busca la presencia de los componentes armónicos antes de estimar sus parámetros. Los picos armónicos son detectados en la imagen de magnitudes de Fourier. El periodograma es empleado como un estimador de frecuencias para obtener los componentes armónicos-periódicos desconocidos. Se selecciona en el periodograma las frecuencias de los picos aislados y más grandes. Para lograr lo anterior, se determina el valor de amplitud máxima del periodograma. Este valor se establece como el umbral de amplitud y entonces gradualmente se baja este umbral mientras que se hace la detección de todos los picos que se consideran componentes armónicos. El número de los picos espectrales detectados es denotado

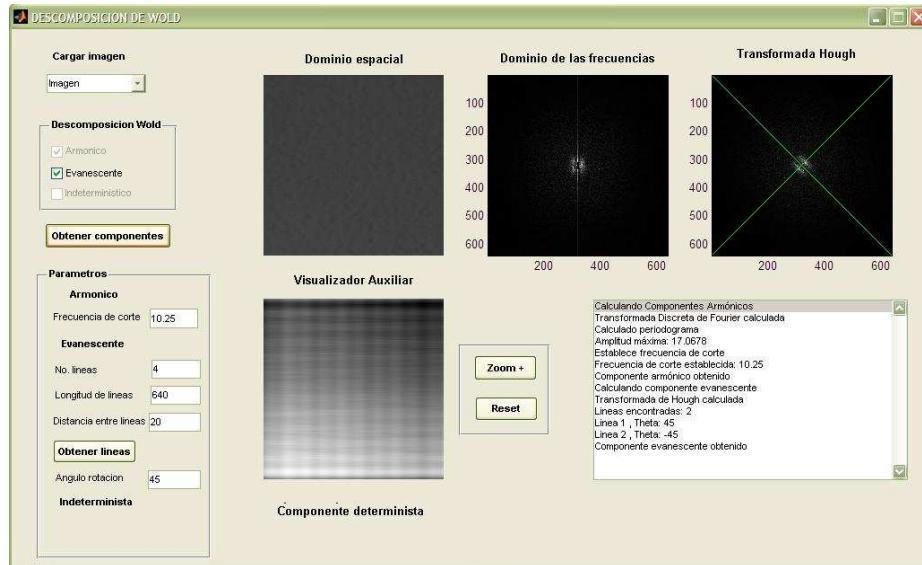


Figura 2. Interfaz: Descomposición de Wold.

por P (ver Ec. 5). La parte de parametrización se hace evaluando los valores de amplitud y fase de la TDF en las frecuencias de los picos detectados. Posteriormente, se realiza la sustracción en el campo de textura original de los componentes armónicos-periódicos, produciendo una imagen residuo, la cual ya no contiene información periódica. El procedimiento anterior puede ser observado en la Fig. 3.

3.2 Detección de Líneas Evanescentes

La obtención del componente evanescente se realiza empleando la Transformada de Hough para la detección de líneas sobre la imagen de las magnitudes de Fourier [8]. La parte de parametrización nuevamente se hace evaluando los valores de amplitud y fase de la TDF en las frecuencias de las líneas detectadas. De igual manera, después se realiza la sustracción de los componentes direccionales en el campo de textura, produciendo una imagen residuo que no contiene información direccional y periódica. El procedimiento anterior puede ser observado en la Fig. 4. Se puede observar que seis líneas evanescentes son encontradas para la textura Brodatz D64 [14].

Finalmente, el componente determinista es obtenido por sumar las imágenes obtenidas por el procedimiento inverso de detección de picos armónicos y líneas evanescentes Fig. 5.

4 Resultados Experimentales

Los resultados se presentan en dos etapas:

- Primero, el componente determinista de la descomposición de Wold es empleado para obtener descriptores de textura que discriminen entre tres clases de calidad de plástico industrial.
- Segundo, el componente determinista es empleado para extraer la geometría oculta de superficies terrestres en imágenes de satélite y aéreas.

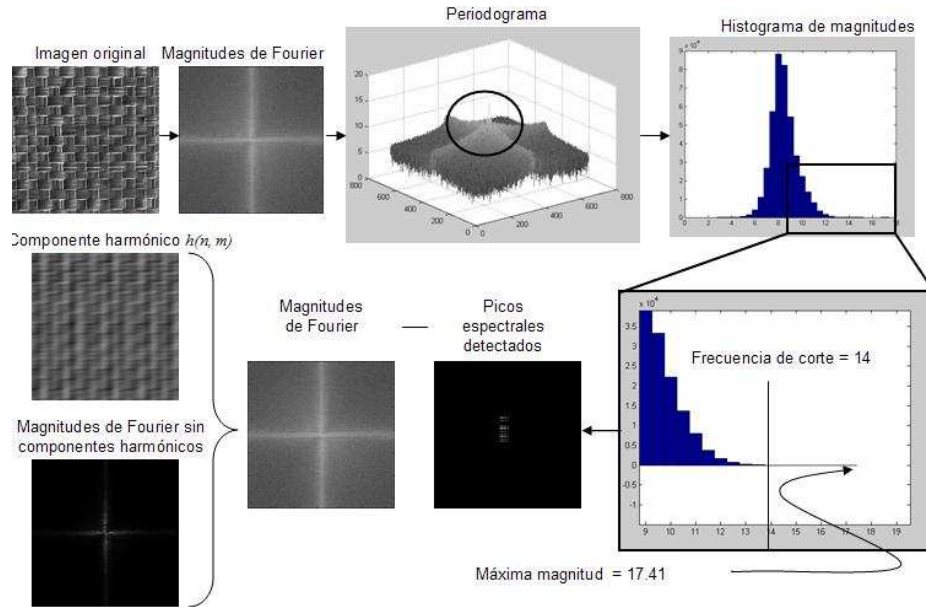


Figura 3. Procedimiento para obtener el componente armónico.

4.1 Descriptores de Textura

La base de datos incluye 52 imágenes de plástico etiquetadas manualmente. Las imágenes fueron obtenidas directamente de la industria. El error de clasificación en estos datos etiquetados manualmente está alrededor del 40%. Las tres clases de calidad de plástico se muestran en la Fig. 6. Desde la figura puede observarse que es difícil distinguir entre las tres calidades de plástico porque presentan características muy similares. La base de datos tiene 15 ejemplos de la clase 1, 18 ejemplos de la clase 2 y 19 ejemplos de la clase 3. El tamaño de las imágenes es de 640x640 píxeles. Para estos experimentos las imágenes fueron convertidas a escala de grises.

En este experimento, cuatro características de textura fueron obtenidas para cada imagen: energía, correlación, homogeneidad y contraste. Cada característica fue obtenida en cuatro direcciones (0° , 45° , 90° y 135°). Debido a que la clasificación presenta alta ambigüedad, seguimos un enfoque supervisado. Las cuatro características fueron usadas como descriptores de textura para clasificar con k-means. Las características de textura (descriptores de textura) fueron obtenidas tanto para las imágenes originales y el componente determinista. Los descriptores de textura obtenidos a partir de la imagen del componente determinista (DT-ICD) son comparadas visualmente contra los descriptores de textura obtenidos a partir de la imagen original (DT-IO). Los agrupamientos obtenidos empleando DT-OI y DT-ICD son mostrados en Fig. 7. Las gráficas 7a, 7c, 7e y 7g muestran los agrupamientos de DT-IO en la dirección 0° , 45° , 90° y 135° respectivamente. Las gráficas 7b, 7d, 7f y 7h muestran los agrupamientos usando DT-ICD en las mismas direcciones. Dentro del proceso para determinar el componente determinista, la frecuencia de corte para el componente armónico es de 9.25 de amplitud y se encontraron dos líneas evanescentes para cada imagen. Puede observarse en las gráficas que los agrupamientos empleando DT-ICD son mejor agrupados que DT-IO. Los agrupamientos usando DT-IO no son formados. En los experimentos, el porcentaje de clasificación usando k-means con DT-ICD es 10% mayor que k-means con DT-IO.

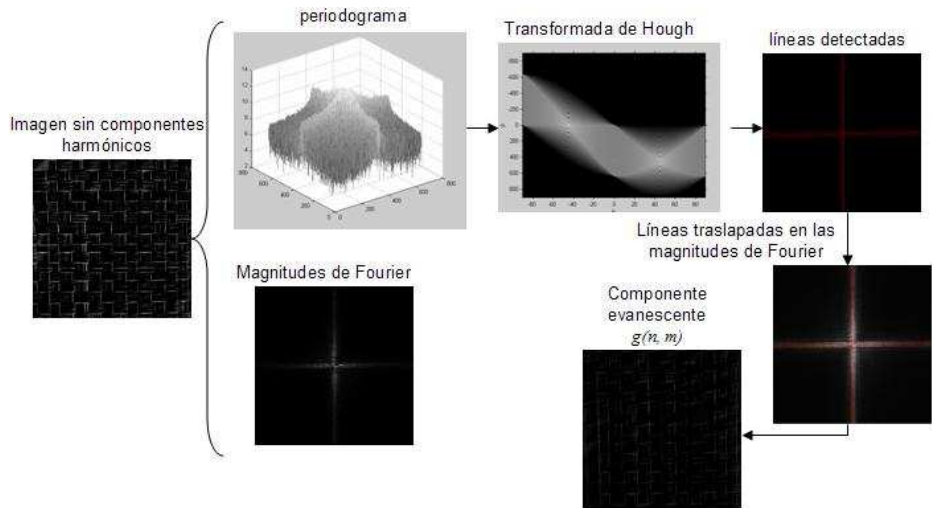


Figura 4. Procedimiento para obtener el componente evanescente.




Figura 5. Componente determinista de textura Brodatz D64.

4.2 Geometría

El segundo experimento fue realizado en imágenes satelitales y aéreas. El tamaño de la imagen es variable. El objetivo de este experimento es relacionar la geometría modelada en [13] para detectar corona de árbol con la geometría observada a partir del componente determinista de la descomposición de Wold. En los procesos puntuales marcados frecuentemente la corona de árbol es modelada por medio de círculos y elipses. Fig. 8 muestra el componente determinista (Fig. 8b, 8f) obtenido a partir de la imagen aérea en [13]. Podemos ver que la geometría que presenta el componente determinista son círculos igual a la geometría modelada por Perrin (Fig. 8c, 8g). Se aplicó un filtro de contraste al componente determinista para visualizar mejor la geometría.

Obtener los bordes de los objetos a identificar en una escena o simplemente realizar una inspección visual de la imagen nos puede dar idea de la geometría a modelar. Sin embargo, en texturas estocásticas la geometría no es tan obvia. Fig. 8d y 8h muestran los bordes obtenidos a partir de la imagen original. Puede observarse que la geometría visualizada en el componente determinista es más similar a la geometría modelada que la geometría que presentan los bordes. Fig. 9b muestra las elipses encontradas en la imagen CIR (color infrared). Fig. 9d y 9f muestran la geometría de círculos y triángulos de dos agriculturas en una imagen de satélite de alta resolución.




Figura 6. Imágenes de tres clases de plástico. a) clase 1 o (3), b) clase 2 o (4-) y c) clase 3 o (4+).

5 Conclusiones

En este trabajo, se empleó el componente determinista de la descomposición de Wold 2-D para obtener descriptores de textura y determinar geometría de campos de textura. El algoritmo implementado emplea el procedimiento de umbralización global del algoritmo de Francos para obtener el componente armónico o periódico del campo, y el procedimiento basado en la transformada de Hough de Liu para obtener el componente evanescente o direccional del campo de textura. Los resultados experimentales mostraron que los descriptores de textura obtenidos a partir del componente determinista agrupan mejor a las clases que los descriptores de textura obtenidos a partir de la imagen original. La descomposición también fue aplicada a algunos campos de textura de coberturas terrestres. Por un lado, se comprobó que existe la geometría de círculos y elipses en una superficie de bosques y se verificó con la geometría modelada en la literatura. Mientras que por otro lado, se determinaron más geometrías de otras coberturas. Dicha geometría no se conocía o no se podía determinar a simple vista. De esta forma, se ha establecido hasta el momento un método para determinar automáticamente la geometría de algunas coberturas de vegetación en imágenes satélites. Trabajo futuro involucra modelar las coberturas estudiadas como un proceso puntual marcado y definir la geometría encontrada mediante la descomposición como la marca del proceso.

Referencias

- [1] Mäenpää, T., Pietikäinen M.: Texture Analysis with Local Binary Patterns. University of Oulu, Finland. (2004) 1–20.
- [2] Francos, J.M., Meiri, A.Z., Porat, B.: A Unified Texture Model Based on a 2-D Wold-Like Decomposition. IEEE Transactions on Signal Processing, Vol. 41. IEEE Signal Processing Society, Piscataway New Jersey (1993) 2665–2678.
- [3] Pratt, W., Fugeras, O.: Decorrelation Methods of Texture Feature Extraction. IEEE Transactions on Pattern Analysis and Machine Intelligence, Vol. 2. (1980) 323–332.
- [4] Cross, G., Jain, A.: Markov Random Field Texture Models. IEEE Transactions on Pattern Analysis and Machine Intelligence, Vol. 5. IEEE Computer Society, Los Alamitos California (1983) 25–39.
- [5] Sánchez-Yáñez, R.E., Kurmyshev E.V., Cuevas, F.J.: A Framework for Texture Classification Using the Coordinated Clusters Representation. Pattern Recognition Letters, Vol. 24. (2003) 1-3.

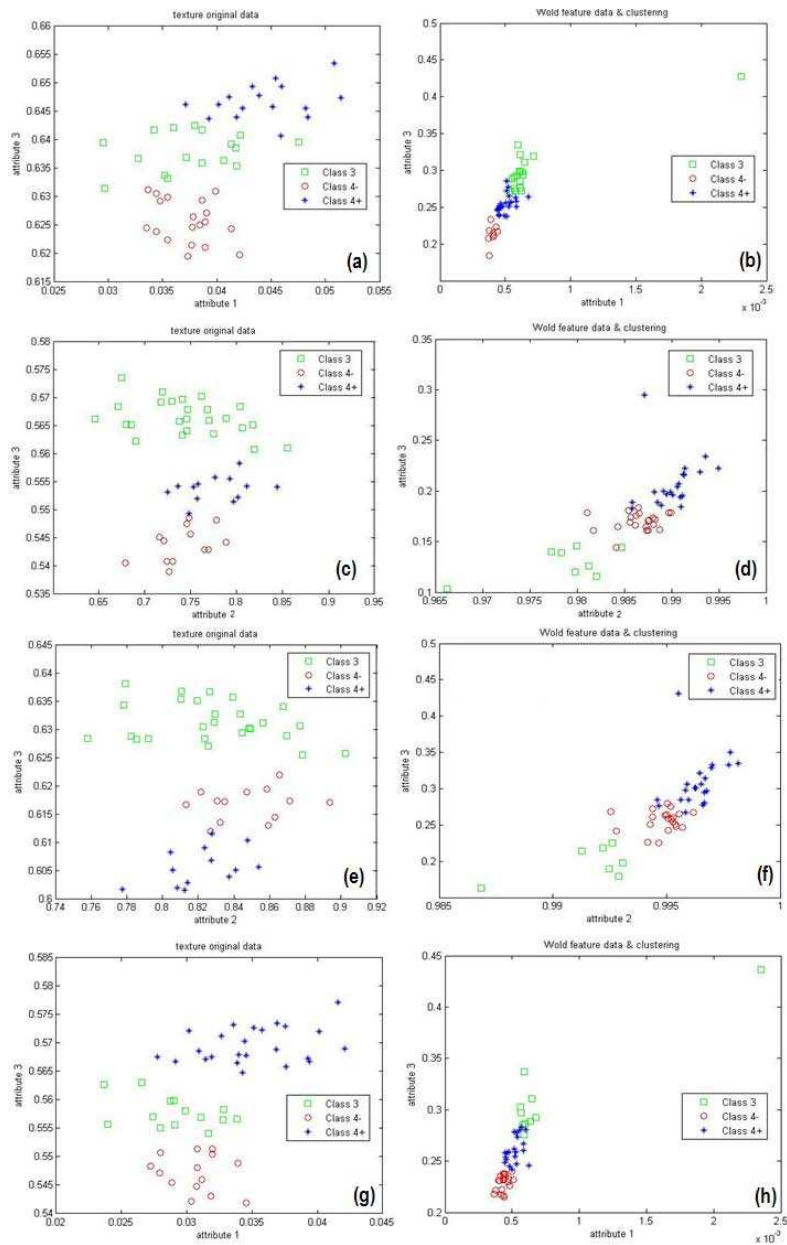


Figura 7. Comparación de los agrupamientos en imágenes de plástico (eje x y y atributos, * clase 4+, \circ clase 4-, \square clase 3). 7a, 7c, 7e y 7g muestran agrupamientos de DT-IO en 0° , 45° , 90° y 135° respectivamente; 7b, 7d, 7f y 7h muestran agrupamientos usando DT-ICD en las mismas direcciones.




Figura 8. Geometría: a) y e) imagen original, b) y f) componente determinista, c) y g) geometría modelada, d) y h) bordes de la imagen.




Figura 9. Geometría de coberturas permanentes de agricultura (imagen de satélite y CIR): a), c) y e) imagen original, b), d) y f) componente determinista.

- [6] Francos, J.M., Meiri, A.Z., Porat, B.: A Wold-Like Decomposition of 2-D Discrete Homogeneous Random Fields. Ben-Gurion University - Israel and Technion-Israel Institute of Technology - Israel. Technical Report.
- [7] Li, F., Peng, J., Zheng X.: Object-Based and Semantic Image Segmentation Using MRF. EURASIP Journal on Applied Signal Processing, Vol. 6. Hindawi Publishing Corporation, New York (2004) 883–840.
- [8] Liu, F., Picard, R.W.: A Spectral 2-D Wold Decomposition Algorithm for Homogeneous Random Fields. Proceedings of the International Conference on Acoustics, Speech, and Signal Processing. (1999).
- [9] Ramananjarasoa, C., Alata, O., Najim, M.: 2-D Wold Decomposition: New Parameter Estimation Approach to Evanescent Field Spectral. Supports.
- [10] Sriram, R., Francos, J.M., Pearlman, W.A.: Texture Coding Using a Wold Decomposition Model. Proceedings of the 12th IAPR International Conference on Pattern Recognition. IEEE Transactions on Image Processing, Vol. 3. IEEE Signal Processing Society, Piscataway New Jersey (1996) 35–39.
- [11] Liu, F., Picard, R.W.: Periodicity, Directionality, and Randomness: Wold Features for Perceptual Pattern Recognition. Computer Vision & Image. Proceedings of the 12th IAPR International Conference on Pattern Recognition, Vol 2. IEEE Computer Society, Los Alamitos California (1994) 184–189.
- [12] Stitou, Y., Turcu, F., Najim, M., Redouane, L.: 3-D Texture Characterization Based on Wold Decomposition and Higher Order Statistics. IEEE International Conference Acoustics, Speech, and Signal Processing (ICASSP), Vol. 2. IEEE Signal Processing Society, Piscataway New Jersey (2005) 165–168.
- [13] Perrin, G., Descombes, X., Zerubia, J.: 2D and 3D Vegetation Resource Parameters Assessment using Marked Point Processes. Proceedings of the 18th International Conference on Pattern Recognition (ICPR'06), Vol 1. IEEE Computer Society, Washington DC USA (2006) 1–4.
- [14] Brodatz, P.: Textures: A Photographic Album for Artists and Designers. Dover Publications, New York, (1966).