

Imágenes SAR Polarimétricas: Segmentación por medio del Análisis de la Dimensión Fractal

Horacio Abbate¹, Juliana Gambini², Claudio Delrieux^{2,3*}

¹Facultad de Ingeniería, UBA, Buenos Aires, Argentina

²Departamento de Computación, FCEyN, UBA, Buenos Aires, Argentina

³Departamento de Ingeniería Eléctrica y Computadoras, UNS, Bahía Blanca, Argentina

habbate@dc.uba.ar, jgambini@dc.uba.ar, claudio@acm.org

Resumen Las imágenes de Radar de Apertura Sintética (SAR) Polarimétricas son muy difíciles de analizar debido a la gran complejidad que contienen, sin embargo son importantes porque proveen información que no puede extraerse de otro tipo de imágenes SAR, como las monopolarizadas. En este trabajo se presenta un nuevo enfoque en segmentación de imágenes SAR Polarimétricas basado en el análisis de la Dimensión Fractal (DF) para cada pixel de cada banda de la imagen. Se construye un espacio de imágenes y cada elemento se utiliza como características de clasificación en el algoritmo de K-medias. Luego se aplica un método de segmentación con curvas B-spline para encontrar el borde de las diferentes regiones. El algoritmo desarrollado se prueba tanto para imágenes sintéticas como reales, obteniéndose resultados muy satisfactorios.

1. Introducción

Las imágenes SAR Polarimétricas son muy importantes debido a la gran cantidad de información que contienen. En los artículos [18], [4] y [14] los autores muestran el potencial que tienen las imágenes SAR polarimétricas con respecto a la monopolarimétricas, en distintas aplicaciones. Sin embargo este tipo de imágenes es muy difícil de analizar e interpretar por diversas razones. Una de las dificultades es la presencia del ruido *speckle*, característico de este tipo de imágenes. Este ruido es inherente al sistema de captura y es lo que le da a la imagen el aspecto granulado. Las imágenes SAR Polarimétricas son particularmente complejas porque están dadas en bandas. Por ejemplo, una imagen polarimétrica de 500×500 pixels está compuesta por 6 matrices de 500×500 números reales o complejos, como se explica en la sección 2.

Por otro lado, la DF ha sido utilizada por muchos autores en segmentación de imágenes y clasificación de texturas porque resulta una medida eficiente de la rugosidad de un área

*Parcialmente financiado por la SECyT-UNS

determinada. En los artículos [16], [10], [3], [11], [1] se utiliza una estimación de la DF como descriptor de la complejidad geométrica de una zona de la imagen y en base a esto se realiza la clasificación o segmentación. También ha sido utilizada en detección de objetos en imágenes SAR, combinada con la Transformada rápida de Fourier ([2], [5]) y combinada con algoritmos de contornos activos ([6]). Sin embargo, hasta ahora no había sido utilizada en imágenes SAR Polarimétricas.

La idea de este método de segmentación es que la distribución estocástica de luminancia en una zona de la imagen posee características geométricas de autosemejanza estadística similares a la de los conjuntos fractales determinísticos [12], y por lo tanto puede estimarse su dimensión fractal local y utilizarse como una medida de rugosidad de la zona. En imágenes, así como en otros conjuntos cuya función característica es no determinística, existe una relación directa entre la dimensión fractal y el coeficiente de autocorrelación de la función, como se expone en [15, 13].

Existen diversas formas de estimar la DF de un conjunto acotado. En este trabajo se utiliza el método de estimación llamado Box Counting Diferencial, desarrollado por Chaudhuri *et al.* en [1], porque exhibe buen comportamiento en imágenes no binarias y razonable costo computacional. Con este método se estima la DF para cada pixel de la imagen, deslizando una ventana rectangular y esto se hace, a su vez para cada banda de la imagen SAR Polarimétrica. Luego, estos datos se utilizan como características para la clasificación. Con el objetivo de extraer el borde de las distintas regiones en la imagen se aplica, luego de la clasificación, un algoritmo de detección de bordes con curvas B-spline.

Este trabajo está desarrollado de la siguiente manera: en la sección 2 se presenta una descripción básica de imágenes SAR polarimétricas. En la sección 3 se explica la forma de estimar la DF utilizando el método Box Counting Diferencial. En la sección 4 se introduce el proceso de clasificación y segmentación de la imagen, que consiste en un proceso de suavizado con difusión anisotrópica, luego la clasificación utilizando K-medias y el algoritmo de detección de bordes con curvas B-spline. En la sección 5 se muestran los resultados y finalmente, en la sección 6 se exponen las conclusiones.

2. Imágenes SAR Polarimétricas

En esta sección presentamos un breve resumen de las imágenes SAR polarimétricas, para ampliar sobre el tema puede verse [8]. El radar de imágenes es un instrumento que mide la respuesta del terreno a la radiación electromagnética. El valor de esta respuesta en cada punto de una zona determinada de la tierra puede ser utilizado de varias maneras, una de ellas es construir una imagen de la zona.

En los sistemas de radar de apertura sintética, se emite una onda electromagnética en forma de pulsos y el retorno de los mismos es detectado y almacenado para su posterior procesamiento. En el proceso de detección, el retorno es demodulado por medio de la multiplicación de dos funciones, obteniéndose dos magnitudes que constituyen la parte real e imaginaria de los "pulsos crudos".

Las imágenes SAR poseen un ruido inherente a su proceso de captura y formación, llamado *speckle* el cual es propio de todos los sistemas generadores de imágenes con iluminación coherente. El ruido *speckle* es lo que hace que en este tipo de imágenes se vea un granulado, y es una

de las razones por la cual son muy difíciles de analizar e interpretar. Para reducir este ruido, una de las técnicas utilizadas es generar varias "vistas" o *looks* a partir del mismo conjunto de pulsos crudos durante el proceso de generación de la imagen. Estos *looks* son generados de manera que sean estadísticamente independientes. El promediado, pixel a pixel, de cada uno de estos *looks* genera una imagen multilook que posee menor ruido *speckle*.

En radares polarimétricos se emite una radiación electromagnética con polarización horizontal (h) y con polarización vertical (v). Luego se detectan las componentes horizontal y vertical de los retornos correspondientes a ambas polarizaciones emitidas. Entonces el retorno \mathbf{Z} está dado por

$$\mathbf{Z} = [Z_{hh}, Z_{hv}, Z_{vv}]^t \quad (1)$$

el cual es un vector aleatorio complejo que modela el retorno de la señal. Donde Z_{ab} es el retorno correspondiente a emitir la radiación con polarización a y detectar la componente b , donde $a = h, v, b = h, v$.

Definimos ahora, la matriz compleja de 3×3 , $\mathbf{Z}^{(n)}$ dada por

$$\mathbf{Z}^{(n)} = \frac{1}{n} \sum_{k=1}^n \mathbf{Z}(k) \mathbf{Z}^{*t}(k), \quad (2)$$

donde n es el número de looks y $\mathbf{Z}(k)$ son los retornos que corresponden a cada uno de los n looks.

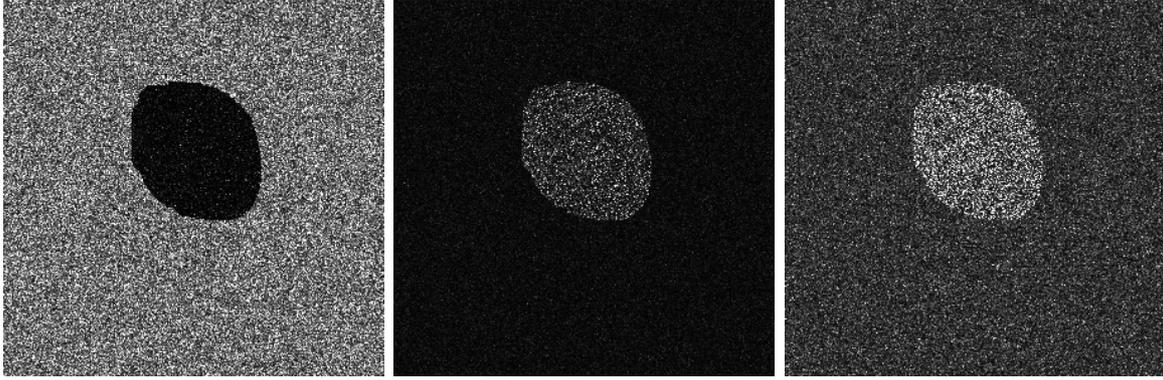
Para cada k resulta

$$\mathbf{Z}(k) = \begin{bmatrix} Z_{hh} Z_{hh}^* & Z_{hh} Z_{hv}^* & Z_{hh} Z_{vv}^* \\ Z_{hv} Z_{hh}^* & Z_{hv} Z_{hv}^* & Z_{hv} Z_{vv}^* \\ Z_{vv} Z_{hh}^* & Z_{vv} Z_{hv}^* & Z_{vv} Z_{vv}^* \end{bmatrix}$$

Esta matriz es simétrica, y cada una de las 6 componentes distintas se llaman bandas. Las bandas de la diagonal de la matriz son números reales, mientras que los elementos fuera de la diagonal tienen parte imaginaria distinta de 0. Las bandas se identifican de la manera que muestra la tabla 2:

Banda	imagen	tipo de dato
Banda 1	$Z_{hh} Z_{hh}^*$	real
Banda 2	$Z_{hv} Z_{hv}^*$	real
Banda 3	$Z_{vv} Z_{vv}^*$	real
Banda 4	$Z_{hh} Z_{hv}^*$	complejo
Banda 5	$Z_{hh} Z_{vv}^*$	complejo
Banda 6	$Z_{hv} Z_{vv}^*$	complejo

La Figura 1 muestra una imagen SAR Polarimétrica sintética generada con un modelo estadístico diseñado para interpretar este tipo de datos (ver [8]). Las Figuras 1(a), 1(b) y 1(c) corresponden a las Bandas 1, 2 y 3 de la imagen, respectivamente.



(a) Banda HH

(b) Banda HV

(c) Banda VV

Figura 1: Imagen SAR polarimétrica sintética con dos regiones diferentes, generada con un modelo estadístico polarimétrico.

3. Estimación de la Dimensión fractal

Un conjunto acotado A , en un espacio, es autosimilar si es la unión de N_r copias distintas (no solapadas) de sí mismo escalada por encima o por debajo de un radio r . En este caso, la dimensión fractal DF de A está dada por la relación:

$$DF = \frac{\log(N_r)}{\log(1/r)}$$

El concepto de autosimilaridad es utilizado para estimar la dimensión fractal de un conjunto arbitrario. Existen diversos métodos para calcular esta estimación, la mayoría de los cuales se aplican a imágenes que deben estar previamente binarizadas. Chaudhuri *et al.* describen un método que tiene la ventaja de que puede aplicarse a imágenes que tengan niveles de gris entre $[0, 255]$. La ecuación 3, es la base de la estimación de la dimensión fractal. En este caso N_r está determinada de la siguiente manera:

dada una imagen de $M \times M$ pixels, se hace una partición de $s \times s$ donde $M/2 \geq s > 1$ y $s \in \mathbb{Z}$. Luego el radio es $r = s/M$. Se considera la imagen perteneciente a un espacio tridimensional, donde cada elemento es una terna (x, y, z) , con (x, y) la posición del pixel y z es el nivel de gris correspondiente al pixel (x, y) .

El espacio (x, y) está particionado en una grilla cuya celdas son de lado s . Sobre cada una de las celdas se considera una columna de cajas de tamaño $s \times s \times s$, es decir se hace una partición de los niveles de gris sobre cada celda.

Si el máximo y mínimo nivel de gris caen en la k -ésima y l -ésima celdas de la columna que se levanta sobre la celda (i, j) , entonces

$$n_r(i, j) = k - l + 1$$

es la contribución de N_r en la (i, j) -ésima celda. Tomando todas las contribuciones sobre la grilla se obtiene:

$$N_r = \sum_{i,j} n_r(i, j) \quad (3)$$

N_r se calcula para diferentes valores de r . Luego, la dimensión fractal DF se estima como la pendiente de la recta de mínimos cuadrados que ajusta $\log(N_r)$ vs. $\log(\frac{1}{r})$.

La Figura 2 muestra la imagen DF para la imagen de la Figura 1(a).

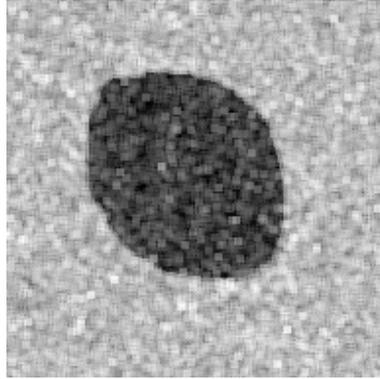


Figura 2: Estimación de la Dimensión Fractal para cada pixel de la imagen de la Figura 1(a).

4. Proceso de Clasificación

En este trabajo se utiliza el algoritmo de K-medias para la clasificación de distintas zonas de la imagen. Esta clasificación se hace pixel por pixel, tomando como características la dimensión fractal de los datos.

El proceso de clasificación es el siguiente, en primer lugar se estima la DF de cada pixel para cada banda de la imagen SAR polarimétrica, generando de esta manera un espacio 9-dimensional de características. Entonces, cada pixel (x, y) tiene asociado un arreglo 9-dimensional que corresponde al valor de DF en cada banda de la imagen en el pixel (x, y) . Las tres primeras características corresponden a la dimensión fractal de las bandas 1, 2 y 3. Las bandas 4, 5 y 6 están compuestas por números complejos, estas imágenes poseen información de la estructura geométrica tanto en el módulo como en la fase. Por esta razón se toman como características 4, 5, 6, 7, 8, y 9 el módulo y la fase de cada una de ellas.

El algoritmo de K-medias es muy sensible al ruido e inestable frente a pequeños cambios en el nivel de gris de los pixels (para mayor información sobre el algoritmo de K-medias consultar [9] y [7]), por esa razón se le aplica a las imágenes de DF, el algoritmo de suavizado con difusión anisotrópica, que elimina el ruido preservando bordes y detalles. El método de difusión anisotrópica ha sido ampliamente tratado por diversos autores, aunque la propuesta original se debe a Perona y Malik [17]. Un ejemplo de este suavizado se muestra en la Figura 3.

Las 9 imágenes generadas de esta forma son los datos de entrada del algoritmo de K-medias (ver [9] y [7]). Finalmente se aplica un algoritmo de detección de bordes con curvas B-spline (ver [6]) para segmentar diferentes regiones. Este algoritmo de contornos B-spline es una herramienta muy útil para encontrar bordes de regiones por su eficiencia computacional.

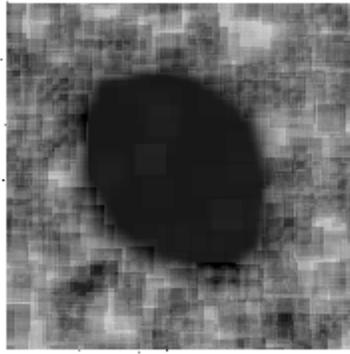


Figura 3: Suavizado con Difusión Anisotrópica.

Trabaja sobre regiones previamente especificadas lo cual reduce el costo computacional. Además tiene la ventaja que produce una curva suave para el contorno del objeto de interés con poca cantidad de parámetros.

Un esquema del procedimiento se muestra en el Algoritmo 1.

Algorithm 1 Algoritmo de Segmentación de Imágenes SAR Polarimétricas

- 1: **for** para cada banda **do**
 - 2: Hallar la imagen Dimensión Fractal.
 - 3: Suavizar la imagen con el algoritmo de Difusión Anisotrópica.
 - 4: **end for**
 - 5: Clasificar cada pixel, como un arreglo 9-dimensional usando K-medias.
 - 6: Detección del punto de bordes de regiones en la imagen con un algoritmo que utiliza curvas B-spline.
-

5. Resultados

La Figura 4 muestra el resultado de aplicar el algoritmo descrito en el Algoritmo 1 a la imagen de la Figura 1. Para clasificar esta imagen se utilizaron solo 3 características, correspondientes a las bandas 1, 2 y 3 (reales). La Figura 5(a) corresponde una imagen E-SAR real de 3 looks proveniente de un área urbana de la ciudad de Munich, Alemania. La Figura 5(b) muestra el resultado de aplicar el algoritmo de segmentación descrito en el Algoritmo 1, clasificando con 6 características correspondientes a las bandas 1, 2 y 3 (reales), y 4, 5 y 6 (módulo de las bandas complejas).

6. Conclusiones

En este trabajo se describe un nuevo enfoque en segmentación de imágenes SAR Polarimétricas usando una técnica de clasificación basada en la estimación de la Dimensión Fractal y contornos deformables. Esto resulta un algoritmo eficiente para clasificar. El algoritmo de contornos

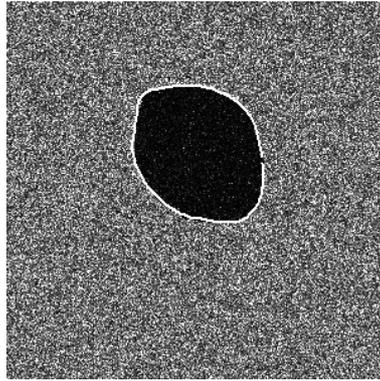
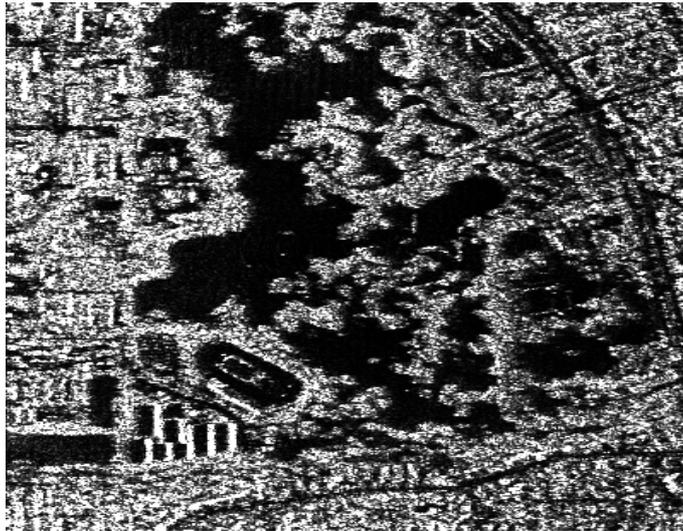


Figura 4: Resultado de aplicar el algoritmo 1 a la Figura 1

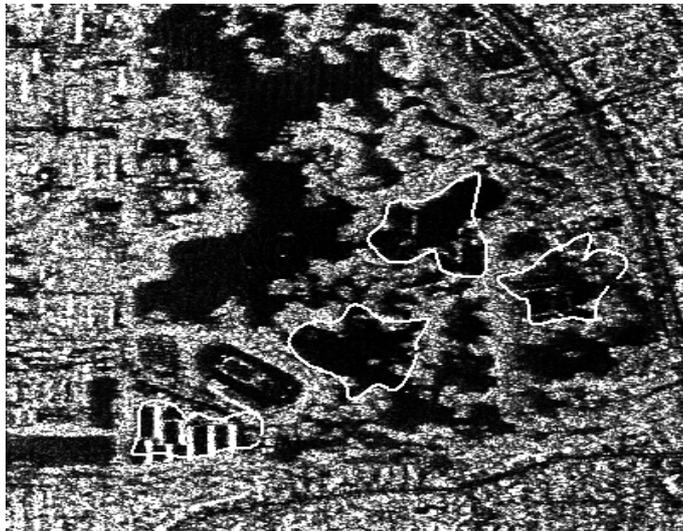
deformables es una herramienta muy útil para encontrar bordes de regiones por su eficiencia computacional. En el primer paso se calculan los descriptores basados en la dimensión fractal utilizando las diferentes bandas de la imagen polarimétrica, luego se procede al suavizado utilizando difusión anisotrópica para hacer la clasificación con el algoritmo de K-medias. A la imagen clasificada, se le aplica un proceso de detección de puntos de borde sobre una serie de segmentos y luego se construye la B-spline interpolante. Los resultados son buenos, con un aceptable costo computacional.

Referencias

- [1] B.Chaudhuri and N.Sakar. Texture segmentation using fractal dimension. *IEEE Trans. Pattern Anal. Machine Intell*, 25(17):72–76, 1995.
- [2] J.M. Blackledge and E. Fowler. Fractal dimensions segmentation of synthetic aperture radar images. In *International Conference on Image Processing and its Applications*, pages 445–449. IEEE, 1992.
- [3] T.J. Dennis and N.G. Dessiripis. Fractal modelling in image texture and analysis. In *IEEE Proceedings*, 136F(5). IEEE, 1989.
- [4] W. Dierking, H. Skriver, and P. Gudmandsen. Sar polarimetric for sea ice monitoring. In *ESA POLInSAR workshop*, ESRIN, 2003.
- [5] G. Du and T. S. Yeo. A novel multifractal estimation method and its application to remote image segmentation. *IEEE Trans. Geosci. Remote Sensing*, 40:980–982, 2002.
- [6] M. J. Gambini, M. Mejail, J. Jacobo-Berlles, and C. Delrieux. SAR images segmentation through b-spline deformable contours and fractal dimension. In *International Society for Photogrammetry and Remote Sensing, ISPRS04*, Istanbul, Turkey, 2004. IEEE.
- [7] R. Gonzales and R. Woods. *Tratamiento Digital de Imágenes*. Addison Wesley Iberoamericana/ Ediciones Diaz de Santos, 1996.
- [8] J. Jacobo Berllés. *Nuevas Familias de Distribuciones Polarimétricas para Imágenes SAR*. PhD thesis, Universidad de Buenos Aires, 2005.



(a) Banda HH de una imagen E-SAR real, polarimétrica de 3 looks.



(b) Bordes de las regiones detectadas.

Figura 5: Imagen SAR polarimétrica real y el resultado de aplicar el algoritmo descrito.

- [9] A. K. Jain. *Fundamentals of Digital Image Processing*. Prentice-Hall International Editions, Englewood Cliffs, NJ, 1989.
- [10] T. Keller. Texture description and segmentation through fractal geometry. *Computer Vision, Graphics and Image Processing*, 45:150–166, 1989.
- [11] Y. Liu and Y. Li. Image feature extraction and segmentation using fractal dimension. In *International Conference on Information and Signal Processing*, pages 975–979. IEEE, Sept. 1997.
- [12] B. Mandelbrot. *The Fractal Geometry of Nature*. W. H. Freeman, 1983.
- [13] B. Mandelbrot and J. van Ness. Fractional brownian motion, fractional noises and applications. *Siam Review*, 10:422–437, 1983.

- [14] K. Papathanassiou, T. Mette, and I. Hajnsek. Model based forest height estimation from single baseline polinsar data: The fichtelgebirge test case. In *ESA POLInSAR workshop, ESRIN*, 2003.
- [15] H. O. Peitgen and D. Saupe. *The Science of Fractal Images*. Springer-Verlag, 1986.
- [16] T. Peli. Multiscale fractal theory and object characterization. *Journal of the Optical Society of America*, 7(6):1113–1123, 1990.
- [17] P. Perona and J. Malik. Scale-space and edge detection using anisotropic diffusion. *IEEE Trans. Pattern Anal. Machine Intell.*, 12(7):629–639, 1990.
- [18] S. Quegan, M. Gomez-Dans, D. Gonzales-Sanpedro, D. Hoekman, T. Le Toan, and H. Skriver. Classification with multitemporal polarimetric SAR data. In *ESA POLInSAR workshop, ESRIN*, 2003.