

Segmentación Eficiente Utilizando Dimensión Fractal

Román Katz y Claudio Delrieux

*Departamento de Ingeniería Eléctrica y de Computadoras
Universidad Nacional del Sur - Av. Alem 1253, (8000) Bahía Blanca, ARGENTINA.
e-mail: claudio@acm.org*

Resumen

Las técnicas de segmentación usuales, tanto en imágenes por tonos de gris o multibanda, dependen de la supervisión o asistencia de un operador, por medio de procedimientos de prueba y error. Más aún, en imágenes ruidosas —las cuales son evidentemente mucho más comunes en la mayoría de las aplicaciones del procesamiento de imágenes— los esquemas de clasificación local utilizados para segmentar suelen ser de escasa utilidad, debido a las fluctuaciones aleatorias introducidas por el ruido. En algunos casos particulares, las recientes ideas propuestas para segmentación automática basada en contornos activos pueden ser lo suficientemente robustas para manejar situaciones de imágenes ruidosas sin supervisión (excepto por el paso de inicialización). Sin embargo, en situaciones de ruido no aditivo (por ejemplo en imágenes SAR, ultrasonido, microscopía electrónica, etc.) y/o en la segmentación de objetos de forma compleja, los contornos activos no tienen una performance adecuada.

En este trabajo proponemos el manejo de la segmentación de imágenes ruidosas por medio del análisis de la dimensión fractal. Un paso previo de clasificación utilizando como estimador la counting box dimension ha demostrado mejorar significativamente tanto la eficacia como la calidad final de la segmentación realizada tanto por técnicas locales de filtrado, como por medio de contornos activos o extracción de contornos por medio de algoritmos evolutivos. Los resultados obtenidos por los algoritmos presentados en este trabajo son lo suficientemente robustos como para manejar imágenes con degradación severa por ruido multiplicativo, y la segmentación de objetos con formas arbitrariamente complejas.

Palabras Clave: PROCESAMIENTO DE IMÁGENES — SEGMENTACIÓN — CONTORNOS ACTIVOS — ANÁLISIS FRACTAL — PROGRAMACIÓN EVOLUTIVA

1 Introducción

La segmentación de objetos en imágenes digitales es el paso clave en el procesamiento, análisis y visión por computadora, dado que es el punto que vincula las técnicas de adquisición y procesamiento de bajo nivel con los posteriores pasos de análisis de alto nivel como el reconocimiento y la interpretación [5]. El objetivo de esta etapa es fácil de establecer:

se trata de separar la figura del fondo en una imagen digital. Sin embargo, la segmentación completamente autónoma —como podría ser requerida en diversas aplicaciones de visión robótica fija y móvil, reconocimiento de patrones, identificación no supervisada, etc.— es un objetivo de notable complejidad, y que ha sido parcialmente alcanzado en algunos casos particulares. Los resultados adecuados y simples de una segmentación son indispensables para el éxito y efectividad de los próximos pasos del análisis de la imagen, siendo importante no solo la calidad de los datos obtenidos como su tamaño. Es decir, la etapa de segmentación debe tener en cuenta no solo su propia eficiencia, sino la eficiencia de las tareas posteriores[14].

Las primeras técnicas de segmentación se basaron en la clasificación de partes de la imagen en función del valor respecto de un descriptor (o conjunto de valores). Por ejemplo, en una imagen de escala de grises, la intensidad o nivel de gris podría ser un buen estimador de cuándo un pixel de la imagen pertenece a la figura o al fondo de la misma. Por lo tanto, umbralizar respecto de un determinado valor (tal vez computado en un paso previo de estimación) es una de las técnicas más básicas de segmentación, la cual, combinada con otros análisis, suele estar casi siempre presente en mecanismos más sofisticados. Otras técnicas de segmentación tienen en cuenta no solo la intensidad del pixel sino también de un contexto local. De esa forma surgen las técnicas que asumen que la frontera entre figura y fondo puede detectarse por medio de filtros que computan el gradiente de la intensidad. En imágenes color o multibanda, pueden utilizarse otros descriptores como por ejemplo el color, la reflectancia, la textura, un análisis por componentes principales, etc. [14, 10, 6]. Una vez obtenido el gradiente respecto del descriptor elegido, se binariza respecto de un valor umbral determinado en función de las propiedades globales de la imagen [19, 17].

Este procedimiento tiene varias desventajas. Primero, muchas veces el valor umbral no puede determinarse adecuadamente en forma automática, lo cual implica un paso supervisado por prueba y error. Segundo, si en la imagen hay incertidumbre en los descriptores utilizados —debida a la presencia de ruido, o a condiciones indeseadas de iluminación, o a una complejidad inherente en la imagen de entrada— entonces los resultados que pueden obtenerse por medio de este procedimiento pueden ser de escasa utilidad. En particular, en imágenes con ruido, cualquier esquema local de clasificación seguramente fracasará debido a las fluctuaciones aleatorias introducidas por el mismo. Por lo tanto, se requiere algún mecanismo global o multi-etapa para realizar segmentaciones adecuadas en estos casos.

Una forma de encontrar la frontera de los objetos es buscar una solución como un problema de minimización. Esta estrategia es interesante, porque los problemas de minimización han sido muy estudiados y existe una notable artillería de algoritmos y metaheurísticas para buscar soluciones. En este caso, puede plantearse la extracción de un contorno como el problema de minimizar la diferencia acumulada de un determinado descriptor a lo largo de una poligonal. Una manera de solucionar este problema por medio de algoritmos evolutivos fue presentada en [9], y demostró ser adecuada para objetos de forma arbitraria, e imágenes con ruido aditivo. Otra propuesta relativamente reciente es la basada en los *contornos activos* o *snakes* [2, 15, 3]. Los contornos activos se han utilizado exitosamente para problemas generales de segmentación, y son lo suficientemente robustos como para manejar imágenes ruidosas contaminadas con ruido aditivo (por ejemplo debido a ruido térmico en los sensores, errores de cuantización, dithering, tonalizado digital, etc.). Sin embargo, en imágenes donde los objetos a segmentar poseen

formas complejas, o en imágenes con ruido multiplicativo (imágenes SAR, ultrasonido, microscopía digital, etc.) los resultados obtenidos al segmentar por medio de contornos activos no son satisfactorios.

En este trabajo proponemos el uso de estimadores fractales, basados en la *counting box dimension* [14, 1, 16] como paso previo a la segmentación. Es decir todas las técnicas mencionadas en los párrafos anteriores pueden mejorar sensiblemente su eficacia si se utiliza como estimador la dimensión box. En algunos casos, la clasificación directa puede dar buen resultado, mientras que en otros es necesario utilizar además una técnica global como los mencionados algoritmos evolutivos o los contornos activos. En todos los casos estudiados de imágenes con ruido multiplicativo y objetos de forma arbitrariamente compleja, nuestra combinación de técnicas mostró resultados satisfactorios. Estas ideas se desarrollan a continuación según el siguiente orden. En la Sec. 2 presentamos un breve resumen de los conceptos básicos para que este trabajo sea auto-contenido. En la siguiente Sección desarrollamos la metodología necesaria para incorporar la dimensión box en la segmentación de imágenes. En la Sec. 4 mostramos algunos resultados, y en la siguiente Sección presentamos las conclusiones y las propuestas para trabajos futuros.

2 Fundamentos Teóricos

Esta Sección está incluida para proveer los conceptos teóricos necesarios que fundamentan los resultados de este trabajo. En particular se brinda una breve introducción a la importancia de la umbralización como base de la segmentación, a sus diferentes técnicas de clasificación, y a la problemática de la detección de bordes y extracción de fronteras. Los lectores con conocimientos en estos temas pueden omitir esta Sección.

2.1 Umbralización

Las operaciones de umbralización siempre recibieron bastante atención, dado que proveen mecanismos sencillos (en complejidad de cómputo y de operación) para discriminar entre las características de una imagen, discriminación indispensable como paso previo para la mayor parte de las tareas de estimación, medición, interpretación y muchas otras. Más aún, una buena cantidad de tareas de procesamiento digital de imágenes mejora en mucho su calidad, complejidad y performance sobre imágenes adecuadamente umbralizadas, como por ejemplo el procesamiento morfológico o la detección de bordes y fronteras. Por dicha razón, el umbralizado es utilizado regularmente como etapa inicial en casi todas las tareas que involucran segmentación de parte de una imagen, y en algunos casos sencillos y bien conocidos, la umbralización puede producir segmentaciones de adecuada calidad [5].

La umbralización puede proceder de acuerdo a varias técnicas, y puede basarse en diversas características de las imágenes (nivel de gris, color, etc.), utilizando niveles umbral estáticos o adaptativos [18]. Más aún, la integración de métodos de detección y clasificación en forma conjunta (por medio de diversos métodos adaptativos de detección de umbrales, o de la denominada *umbralización óptima*), permite obtener resultados de segmentación bastante buenos con cómputo sencillo [14]. El umbralizado conceptual y computacionalmente más sencillo es con respecto al nivel de gris o luminancia, con el cual se pueden seleccionar los pixels de un determinado rango y asumir que pertenecen a una

determinada clase. Esta detección puede ser o bien entre figura y fondo, o bien entre diferentes objetos (si es posible clasificar previamente los diferentes niveles de luminancia asociados). Esta umbralización indudablemente no va a producir resultados adecuados en todos los casos, es decir, no hay esperanza que una clasificación estática de los rangos permita segmentar adecuadamente. En la vasta mayoría de los casos, las condiciones de iluminación, calibración de los sensores, orientación, y muchas otras circunstancias afectan los niveles de luminancia. Por lo tanto se requiere un mecanismo previo de adaptación dinámica a las condiciones particulares que permita adecuar los rangos de umbralización.

La base de muchos de estos métodos adaptativos es un análisis del histograma de luminancia (o del atributo de la imagen utilizado para umbralizar). Este análisis puede permitir una clasificación automática o asistida, por medio de la detección de un umbral adecuado para esa imagen en particular. El histograma se computa por medio de la frecuencia relativa de ocurrencia de cada nivel de gris (o el atributo utilizado) en la imagen. En una situación ideal, los pixels de la figura tendrán un nivel determinado, y los del fondo otro, con lo cual el histograma permite determinar un valor de umbralización que separa estos dos niveles en forma adecuada. Esta situación tampoco es frecuente, dado que los niveles de luminancia suelen estar afectados por las condiciones ya mencionadas (iluminación no uniforme, calibración, etc.).

Más aún, las imágenes en general contienen elementos indeseados producidos por diversas causas, y englobados bajo el término de *ruido*. El ruido se produce en un sinnúmero de procesos no modelables que ocurren en el proceso de producción, captura y manejo de una imagen, como por ejemplo variaciones locales en la sensibilidad de los detectores, cambios en el ambiente, la naturaleza discreta de la radiación, transmisión no isotrópica, cuantización, etc. Todos estos tipos de ruido pueden agruparse en dos clases muy diferentes, que hacen a la caracterización y tratamiento estadístico del ruido: el ruido aditivo y el ruido multiplicativo. El primero ocurre por ejemplo en los detectores, los cuales son dispositivos discretos (contadores de fotones), y además sujetos a las fluctuaciones térmicas del ambiente. El ruido aditivo es también inherente al tratamiento digital de señales e imágenes, dado que el proceso de digitalización requiere una cuantización, la cual puede modelarse por medio del agregado de una fluctuación aleatoria a la señal a ser digitalizada. Este ruido aditivo en general está uniformemente distribuido sobre el espectro (por lo que se lo denomina “ruido blanco”), y por lo tanto puede reducirse mucho por medio de filtros espaciales o frecuenciales (aunque a costo de cierto deterioro en la imagen original, especialmente en los bordes o aristas) [11]. El otro tipo de ruido, el multiplicativo, se debe a otro tipo de procesos que ocurren en el sensado de imágenes por medio de fuentes fotónicas o sónicas coherentes (imágenes SAR, ultrasonido, etc.), y se debe a la interferencia determinística que introduce la variación aleatoria de los elementos de *scattering* que reflejan la radiación dentro de un mismo intervalo de resolución. Este tipo de ruido no puede modelarse por medio del agregado de una fuente aleatoria a la señal (no es aditivo), y por lo tanto su filtrado en el espectro no produce resultados satisfactorios.

Claramente, en imágenes ruidosas, el histograma de luminancia o de cualquier atributo de la imagen deberá reflejar la fluctuación aleatoria con respecto al valor ideal. La ocurrencia de dos máximos locales sugiere que el nivel de umbralización adecuado debe ocurrir en algún nivel de luminancia entre dichos máximos [14]. Una idea intuitiva sería por ejemplo elegir como umbral el valor donde ocurre el mínimo local que separa ambos máximos (ver más abajo). Sin embargo, en imágenes ruidosas, debido a la fluctuación aleatoria en las luminancias, esta idea seguramente no producirá los resultados óptimos,

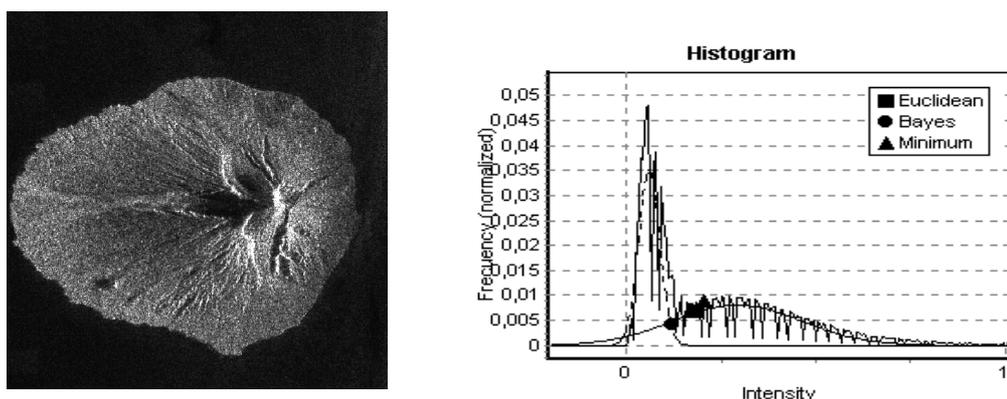


Figura 1: (a) Una imagen con ruido multiplicativo, y (b) su histograma de luminancias.

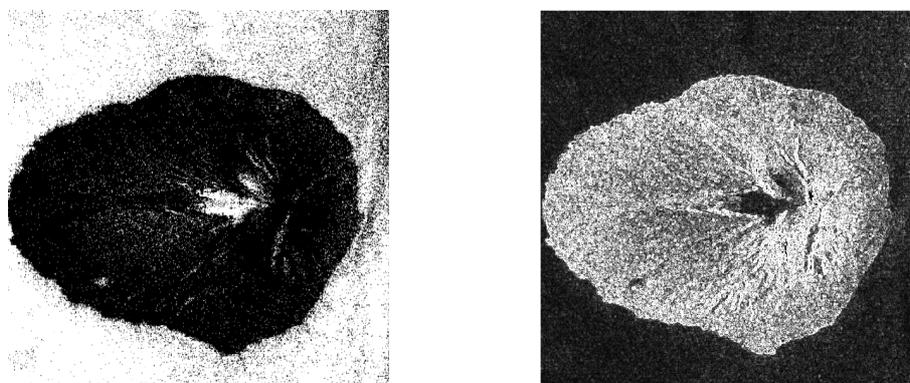


Figura 2: (a) Imagen de la Fig. 1a umbralizada por el valor mínimo, y (b) detección de fronteras por medio de filtrado de Sobel.

básicamente porque puede existir una multiplicidad de mínimos y máximos locales ubicados en lugares poco significativos. Por ejemplo, en la Fig. 1 podemos ver una imagen con cierta cantidad de ruido multiplicativo, y su correspondiente histograma de nivel de gris. Una técnica más elaborada y robusta, ilustrada en el histograma de la Fig. 1b, consiste en aproximar la distribución de luminancias por medio de una distribución bimodal (dos Gaussianas separadas), cada una de las cuales identificando las dos partes de la imagen (figura y fondo).

A partir de la obtención de los modelos Gaussianos de cada parte de la imagen, el nivel de umbralización puede obtenerse por diversos criterios:

Umbralizado por el valor mínimo: Una técnica posible sería elegir como valor umbral al valor de luminancia de menor frecuencia relativa que ocurra entre las luminancias medias de ambas distribuciones (o entre los máximos relativos). Este punto, marcado con el símbolo \blacktriangle en la Fig. 1b, debería corresponder al nivel de luminancia de la frontera o borde entre las dos clases, y por lo tanto debería dar el menor error de clasificación (la menor cantidad de falsos positivos y negativos). Sin embargo, como se dijo más arriba, su definición está sujeta a las fluctuaciones aleatorias debidas al ruido, que pueden originar mínimos espúrios en cualquier zona del histograma, sin ningún significado. En la Fig. 2a se muestra el resultado de umbralizar la imagen de la Fig. 1a con esta técnica, observándose que el resultado es bastante inadecuado.

Distancia mínima: Otro criterio posible para elegir un valor de umbralización es construir un clasificador basado en la distancia mínima. De acuerdo a este criterio, el patrón se clasifica como perteneciente a una clase cuando es mínima la distancia entre el patrón y los estimadores de dicha clase [14]. La medida de la distancia puede computarse con alguna norma que sea adecuada para el caso (norma 1 o distancia de Manhattan, norma 2 o distancia Euclidea, norma ∞ , e inclusive normas arbitrarias que utilicen diferentes pesos y exponentes en diferentes estimadores). En nuestro ejemplo particular, al tener un estimador unidimensional, todas las normas coinciden con la distancia Euclidea. Por lo tanto, el nivel de umbralización que discrimina entre una clase y otra es el que está a mitad de camino entre las medias de ambas Gaussianas, marcado con un ■ en la Fig. 1b. Como con el criterio anterior, la umbralización obtenida con este nivel es de escasa utilidad.

Clasificador Bayesiano: Este método se basa en considerar la intersección entre ambas Gaussianas como discriminador entre las clases. En efecto, sean las dos Gaussianas w_1 y w_2 con sus respectivas medias μ_1 y μ_2 y desvíos standard σ_1 y σ_2 , entonces existe un valor de luminancia x_0 para el que la probabilidad de pertenecer a cualquiera de las dos Gaussianas es igual. Si la probabilidad de que el valor x pertenezca a la clase j está dada por la distribución Gaussiana

$$p_j(x) = \frac{1}{\sqrt{2\pi}\sigma_j} \left[-\frac{(x-\mu_j)^2}{2\sigma_j^2} \right], \quad (1)$$

entonces dadas las dos Gaussianas w_1 y w_2 , se puede encontrar el valor x_0 para el cual $p_1(x_0) = p_2(x_0)$. Este valor, denominado *discriminador Bayesiano* está marcado con ● en la Fig. 1b. Al igual que con las técnicas anteriores, en esta imagen con ruido multiplicativo, la umbralización por medio del discriminador Bayesiano es poco adecuada.

2.2 Detección de bordes y contornos

En general las técnicas utilizadas caracterizan a los contornos de un objeto mediante la detección de sus bordes en función de discontinuidades importantes entre los niveles de intensidad de pixels vecinos [6]. Es adecuada en este sentido la utilización del operador gradiente para encontrar los cambios bruscos de intensidad $I(x, y)$ de los objetos que conforman la imagen [5]. El mismo está descrito matemáticamente por la definición siguiente.

$$\nabla I(x, y) = \begin{bmatrix} G_x \\ G_y \end{bmatrix} = \begin{bmatrix} \frac{\partial I(x, y)}{\partial x} \\ \frac{\partial I(x, y)}{\partial y} \end{bmatrix}. \quad (2)$$

Los operadores G_x y G_y representan una implementación genérica de las derivadas direccionales en la imagen digital, pudiéndose implementar por medio de las “máscaras” de Roberts, Prewitt, o Sobel. En este trabajo adoptamos esta última posibilidad porque experimentalmente es la que brinda mejores resultados. Es fácil ver, entonces, que estos operadores se pueden encontrar por medio de la respectiva convolución de la imagen con máscaras escalares adecuadas. En la Fig. 2b se observa el gráfico de la magnitud del gradiente ∇ correspondiente a la imagen de la Fig. 1a. La presencia de ruido en la imagen, aún luego de la umbralización, es amplificada por cualquier operador gradiente (en este ejemplo con el filtro de Sobel), produciendo una “sobresegmentación”. Por dicha razón,

la segmentación de contornos por medio de la utilización de técnicas de procesamiento local basados en la aplicación aislada del operador gradiente se ve notablemente restringida. Si una medida de lo adecuado de un contorno es la diferencia acumulada entre las intensidades de sus pixels sucesivos, entonces este operador minimiza localmente esta diferencia, pero queda “estancado” en mínimos locales, mientras que el mínimo global sería el contorno que ajusta perfectamente el límite de los objetos que componen la imagen.

Por ello, las estrategias típicas empleadas bajo estas condiciones dificultosas suelen combinar detección de bordes y esquemas de procesamiento global tendientes a evitar los mínimos locales. Tal es el caso de los métodos compuestos de extracción de contornos mediante la detección de bordes junto con la transformada de Hough, la búsqueda en grafos [5] o la programación dinámica [6]. Otras técnicas se basan en el uso de *contornos activos* [7, 15], que consisten en utilizar curvas inicializadas por el usuario, las cuales se mueven dentro de la imagen hasta encontrar el contorno buscado. Para ello se utilizan mecanismos diversos, como B-Splines [3], flujo del vector gradiente, etc. En general, los contornos activos poseen limitaciones respecto de las concavidades de las fronteras a segmentar [20]. Otra posibilidad es el uso combinado del operador gradiente con estrategias evolutivas [8, 9]. La utilización de algoritmos evolutivos [4] provee una herramienta de resolución capaz de encontrar soluciones próximas a la óptima a este problema de formulación matemática no trivial y de gran complejidad computacional. Sin embargo, en imágenes con ruido multiplicativo como la mostrada más arriba, ninguna de estas técnicas produce resultados adecuados. Por dicha razón es que, en la siguiente Sección, utilizaremos como descriptor para umbralización a la dimensión fractal local de la imagen.

3 Análisis Basado en la Dimensión Fractal

En esta Sección presentamos el concepto del análisis basado en la dimensión fractal, y cómo puede utilizarse para la umbralización y segmentación de imágenes. Pese a que el análisis fractal ha sido utilizado como descriptor en algunos casos, las estrategias que presentamos aquí parecen producir resultados mucho mejores en problemas de clasificación autónoma.

3.1 Dimensión box local

Dado que en imágenes ruidosas, con ruido multiplicativo, la segmentación basada en los niveles de luminancia resulta ser muy dificultosa, una estrategia a considerar puede ser utilizar como descriptor la dimensión fractal [12], considerada localmente en el entorno de cada pixel. La relación entre distribuciones aleatorias y la dimensión fractal es muy significativa [16, 13]. La idea subyacente en este análisis es que las distribuciones aleatorias poseen características de autosimilitud que son análogas a la de los objetos fractales matemáticamente definidos (conjunto de Cantor, curvas de Koch y Peano, conjunto de Sierpinski, etc.). Sin embargo, a diferencia de lo que ocurre en estos conjuntos, en una distribución aleatoria la descripción basada en la dimensión de auto-similitud no es aplicable. Por dicha razón se utilizan estimadores estadísticos de autosimilitud como la dimensión de medida, o la dimensión box. Esta última es la que utilizamos en este trabajo.

La dimensión box se basa en medir el conjunto a evaluar sobre una grilla de resolución y posición variable. Sea s el tamaño del lado de una celda cuadrada en la grilla, y sea

$N(s)$ el valor promedio de las celdas de la grilla en las cuales el conjunto se encontraba presente bajo diferentes traslaciones de la grilla. Entonces, es esperable que aumentando la resolución de la grilla (lo cual implica disminuir el tamaño s del lado de las celdas), aumente también la cantidad de celdas visitadas $N(s)$. La pendiente de esta relación en el límite es la dimensión box:

$$D = \lim_{s \rightarrow 0} \frac{\log(N(s))}{\log(\frac{1}{s})}. \quad (3)$$

Para poder establecer estimaciones numéricas adecuadas de D debería ser posible encontrar una correlación a lo largo de varios órdenes de magnitud de s , lo cual no siempre es posible. Por dicha razón, cuando se dispone de pocos valores, los valores de D obtenidos se toman como provisorios. Éstos pueden ser utilizados en forma local como estimadores en una imagen para su segmentación, tomando una sub-imagen centrada en el pixel a estimar. Sub-imágenes de mayor tamaño producen mejores estimaciones, pero con costo computacional mucho mayor. En este trabajo tomamos grillas de hasta 5×5 pixels como buena relación de compromiso, lo cual mostró experimentalmente ser adecuado para nuestros objetivos. Para computar la Ec. 3, debería umbralizarse la imagen antes de computar los pixels visitados. Esto produce una circularidad en el problema. Por dicha razón es que en vez de computar $N(s)$ como sumatoria de pixels visitados, simplemente integramos la luminancia acumulada en la grilla de la sub-imagen. Esto hace que la estimación de D sea en realidad más fácil de computar.

3.2 Análisis del histograma de la dimensión box

En la Sección anterior introdujimos algunas técnicas de umbralización basadas en los histogramas de luminancia. Las mismas ideas podrían ser utilizadas para analizar el histograma de la dimensión box local de una imagen. De esa manera, si figura y fondo en una imagen tienen diferentes distribuciones estadísticas, tendrán diferentes dimensiones fractales, y sería posible segmentarlas de una manera adecuada, mucho mejor de lo que ocurre con la segmentación basada en la umbralización de la luminancia. En la Fig. 3a representamos la dimensión box por medio de niveles de gris (donde la dimensión 0 se corresponde con negro y la dimensión 2 con blanco). En la Fig. 3b se muestra el histograma de las frecuencias relativas de la dimensión box, junto con los tres criterios de elección de valor umbral (Euclídeo, Bayesiano, y distancia mínima). En la Fig. 3c se muestra la imagen segmentada utilizando como valor umbral el discriminador Bayesiano de la dimensión Box.

En una gran cantidad de imágenes con ruido multiplicativo, esta estrategia automática de segmentación es segura y robusta. Cuando el histograma no es bimodal, sin embargo, es necesario recurrir a un análisis más refinado. Puede seguir suponiéndose que el histograma se puede modelar con la superposición de dos Gaussianas, pero la metodología para encontrar los estimadores de las mismas es un poco más elaborado. En particular, un histograma unimodal con un sesgo hacia uno de sus lados puede considerarse como la superposición de dos Gaussiana simétricas lo suficientemente próximas como para que no exista un mínimo local entre sus medias. Por ejemplo, si el histograma está sesgado hacia la derecha, puede asumirse que del máximo hacia la izquierda domina la Gaussiana debida al valor más bajo de la dimensión box, y dicha Gaussiana puede encontrarse por ajuste de una versión simetrizada de este tramo del histograma. La se-

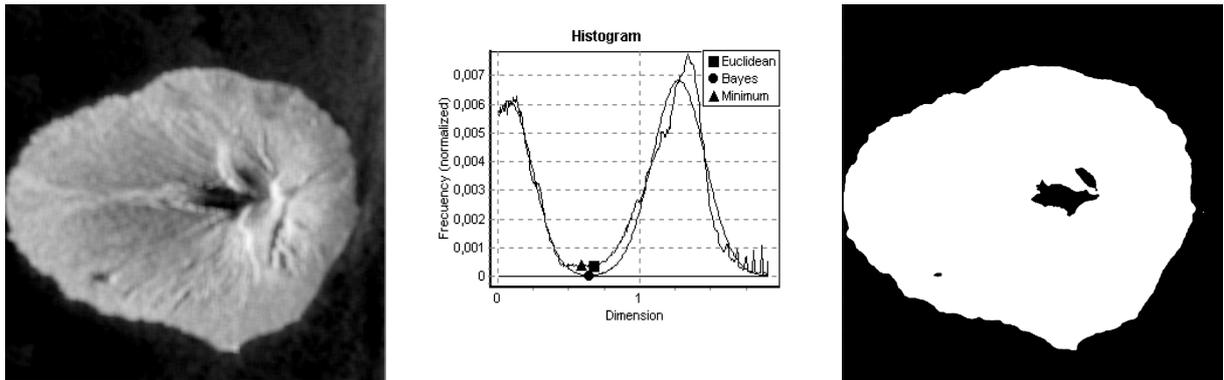


Figura 3: (a) Dimensión box local D en la imagen de la Fig. 1a (representada como niveles de gris), (b) histograma de D y los valores de umbralización, y (c), umbralización utilizando clasificación Bayesiana de D .

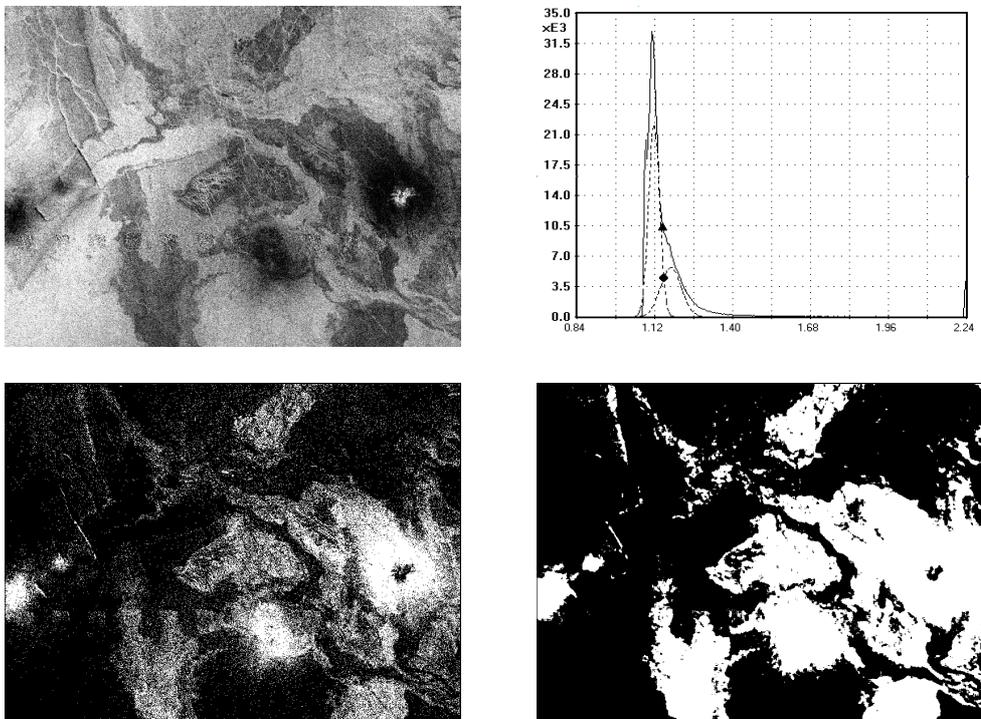


Figura 4: (a) Imagen de prueba, (b) histograma de su dimensión box (unimodal), (c) segmentación por luminancia, y (d) segmentación por dimensión box (en ambos casos utilizando discriminante Bayesiano).

gunda Gaussiana se encuentra por ajuste de la resta entre el histograma total y la primer Gaussiana. Este caso está ejemplificado en la Fig. 4.

Esta misma técnica puede combinarse con un posterior paso de detección de bordes con operadores gradiente, tal como se describe en la Sección anterior, sin que exista sobresegmentación. Por ejemplo en la Fig. 5a se muestra una imagen SAR, en la Fig. 5b la detección de bordes por medio de gradientes, y en la Fig. 5c el resultado de aplicar gradiente sobre la dimensión box de la imagen.

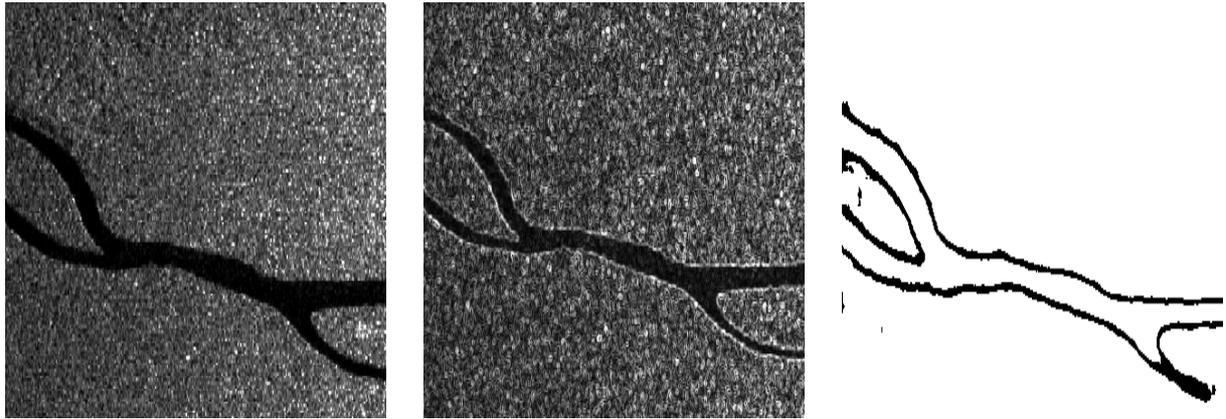


Figura 5: Detección de bordes por medio de la dimensión box: (a) imagen original, (b) detección de bordes aplicando filtro de Sobel sobre la imagen anterior, y (c) detección de bordes aplicando filtro de Sobel sobre la dimensión fractal.

4 Resultados Experimentales

En esta Sección mostramos algunos ejemplos de nuestro mecanismo automático de segmentación basado en el análisis de la dimensión box. Tomamos como ejemplos figuras del Planetary Photojournal de la NASA (<http://photojournal.jpl.nasa.gov/>). En la Fig. 6 mostramos un ejemplo de umbralización (en luminancia vs. en dimensión fractal), en la Fig. 7 un ejemplo de detección de fronteras (en luminancia vs. en dimensión fractal), y en la Fig. 8 ejemplos de extracción de contornos por medio de algoritmos evolutivos (ver [9]).

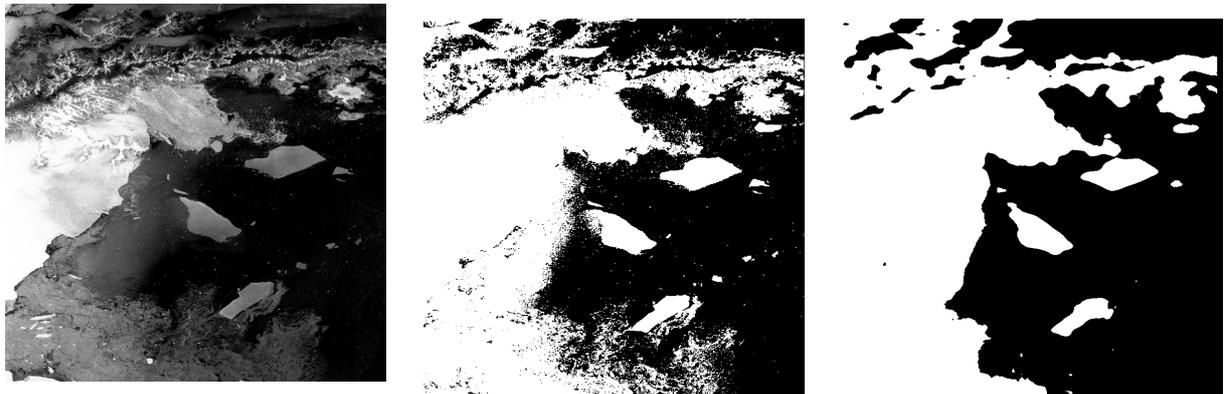


Figura 6: Ejemplo de umbralización (en luminancia y en dimensión box).

5 Conclusiones

Presentamos una técnica de clasificación, eficiente y robusta como para ser utilizada en forma autónoma, basada en el análisis de la dimensión fractal box. La clasificación del histograma de este atributo permite encontrar adecuados umbrales de segmentación, aún en imágenes con ruido multiplicativo. Los resultados obtenidos en todos los casos estudia-

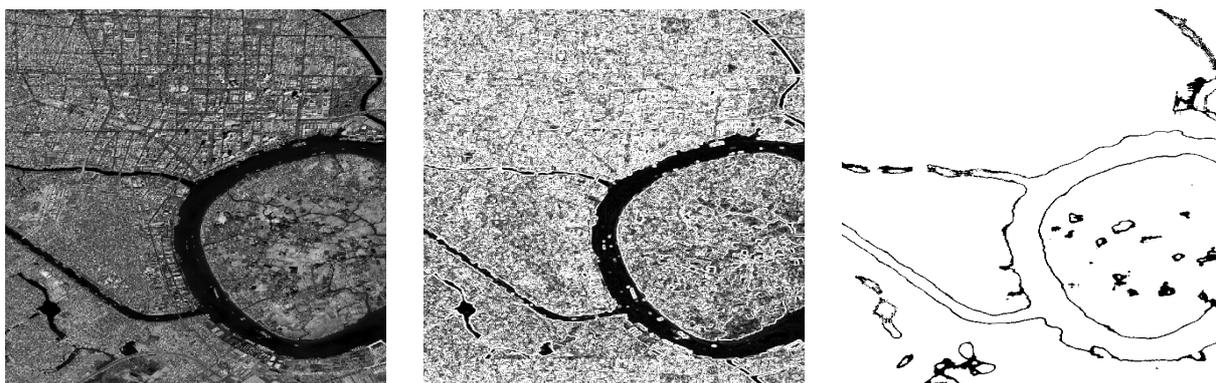


Figura 7: Ejemplo de detección de bordes(en luminancia y en dimensión box).



Figura 8: Ejemplos de extracción de contornos.

dos han sido satisfactorios, tanto en segmentación de zonas, en la extracción de bordes, o en la detección de contornos de formas complejas.

Actualmente estamos trabajando en extender estas técnicas de segmentación para el tratamiento de imágenes con histogramas multimodales, donde tres o más zonas en la imagen deben ser segmentadas. Al mismo tiempo, otro de los estimadores fractales que podrían ser de utilidad es el coeficiente de autocorrelación de Hurst, el cual es también de relativamente fácil implementación para el análisis local de la dimensión fractal.

Referencias

- [1] M. F. Barnsley. *Fractals Everywhere*. Academic Press, Boston, 1988.
- [2] A. Blake and M. Isard. *Active contours: the application of techniques from graphics, vision, control theory and statistics to visual tracking of shapes in motion*. Springer-Verlag, 1998.
- [3] Juliana Gambini, Julio Jacobo, Marta Mejail, and Alejandro Frery. SAR image segmentation using B-Spline deformable contours. In *Congreso Argentino de Ciencias de la Computación*, pages 503–510, Buenos Aires, 2002. VIII CACiC.
- [4] D. Goldberg. *Genetic Algorithms in Search, Optimization and Machine Learning*. Addison-Wesley, New York, 1989.

- [5] Rafael González and Richard Woods. *Digital Image Processing*. Addison-Wesley, Wilmington, USA, 1996.
- [6] Anil Jain. *Fundamentals of Digital Image Processing*. Prentice-Hall, Cambridge, 1996.
- [7] M. Kass, A. Witkin, and D. Terzopoulos. Snakes: Active Contour Models. *International Journal of Computer Vision*, 1:321–331, 1987.
- [8] R. Katz and C. Delrieux. Extracción de Contornos Mediante Algoritmos Evolutivos. In *Congreso Argentino de Ciencias de la Computación*, , pages 588–599. CACIC 2002, 2002.
- [9] R. Katz and C. Delrieux. Boundary Extraction Through Gradient-Based Evolutionary Algorithm. *Journal of Computer Science and Technology*, 3:7–12, 2003.
- [10] T. Lillesand and R. Kiefer. *Remote Sensing and Image Interpretation (4th. ed.)*. Willey & Sons, New York, 2000.
- [11] Jae Lin. *2D Signal and Image Processing*. Prentice-Hall, Cambridge, 1991.
- [12] B. Mandelbrot. *The Fractal Geometry of Nature*. W. H. Freeman, New York, 1983.
- [13] B. Mandelbrot and J. van Ness. Fractional Brownian Motion, fractional noises and applications. *SIAM Review*, 10(4):422–437, 1968.
- [14] M.Sonka, V. Hlavac, and R. Boyle. *Image Processing, Analysis, and Machine Vision*. PWS Publishing, Pacific Grove, CA, 1998.
- [15] J. Park and J. M. Keller. Snakes on the Watershed. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 23(10):1201–1205, 2001.
- [16] H.-O. Peitgen and D. Saupe. *The Science of Fractal Images*. Springer-Verlag, New York, 1986.
- [17] Arie Roszenfeld. *Digital Picture Processing*. MIT Press, Cambridge, MA, 1995.
- [18] J. C. Russ. *The Image Processing Handbook*. CRC Press, Boca Raton, FL, 1989.
- [19] S. E. Umbaugh. *Computer Vision and Image Processing*. Prentice-Hall, New York, 1998.
- [20] C. Xu and J. L. Prince. Snakes, Shapes, and Gradient Vector Flow,. *IEEE Transactions on Image Processing*, 28(3):359–369, 1998.