

Análisis de la Dimensión Fractal para Clasificación Automática

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

1 Objetivos del Proyecto

La segmentación constituye 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]. Los resultados esperados en la 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. Las técnicas básicas de segmentación se basan en la *clasificación* de partes de la imagen en función del valor respecto de un descriptor. 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 clasificación, la cual, combinada con otros procedimientos, suele estar casi siempre presente en mecanismos más sofisticados de segmentación. 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 [14, 10, 6]. Una vez obtenido el gradiente respecto del descriptor elegido, se binariza respecto de un valor umbral determinado [19, 17].

Sin embargo, el valor umbral no siempre puede determinarse adecuadamente en forma automática. Además, si en la imagen hay incertidumbre en los descriptores utilizados (por ejemplo por ruido o a condiciones indeseadas de iluminación) entonces los resultados pueden ser de escasa utilidad. Por lo tanto, se requiere algún mecanismo global o multi-etapa de clasificación 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. 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]. 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 proyecto proponemos el uso de clasificadores fractales, basados en la *dimensión fractal* [14, 1, 16] como paso previo a la segmentación.

2 Umbralización

La umbralización puede basarse en diversas características de las imágenes (nivel de gris, color, etc.), utilizando niveles umbral estáticos o adaptativos [18]. La integración de métodos de detección y clasificación en forma conjunta permite obtener resultados de segmentación bastante buenos con cómputo sencillo [14]. El umbralizado más sencillo es con respecto al nivel de gris o luminancia. 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 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). 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, y pueden agruparse en dos clases muy diferentes: 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 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. En imágenes ruidosas, debido a la fluctuación aleatoria en las luminancias, la clasificación por histograma no producirá los resultados óptimos, básicamente porque puede existir una multiplicidad de mínimos y máximos locales ubicados en lugares poco significativos. Una técnica más elaborada y robusta 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. 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 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. 1b se muestra el resultado de umbralizar la imagen de la Fig. 1a con esta técnica, observándose que el resultado es bastante inadecuado. 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]. Por último, la clasificación Bayesiana se basa en considerar la intersección entre ambas Gaussianas como discriminador entre las clases. Este valor es denominado *discriminador Bayesiano*. Al igual que con la técnica anteriores, en imagen con ruido multiplicativo, la clasificación por medio distancia mínima o por medio del discriminador Bayesiano es poco adecuada.

3 Detección de 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]. La presencia de ruido en la imagen, aún luego de la umbralización, es amplificada por cualquier operador gradiente produciendo una “sobresegmentación” (ver la Fig. 1c). 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

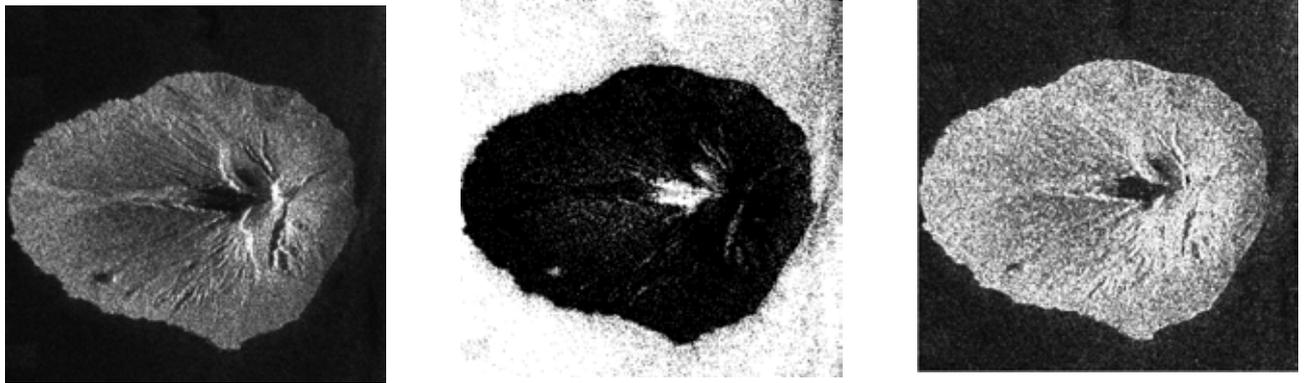


Figura 1: (a) Imagen con ruido multiplicativo, (b) umbralizada por el valor mínimo, y (c) detección de fronteras por medio de filtrado de Sobel.

empleadas bajo estas condiciones dificultosas suelen combinar detección de bordes y esquemas de procesamiento global tendientes a evitar los mínimos locales. 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.

4 Dimensión Fractal

Dado que en imágenes con ruido multiplicativo la clasificación basada en los niveles de luminancia resulta ser muy dificultosa tanto para umbralizar como para detectar contornos, 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. 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 box. 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:

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

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

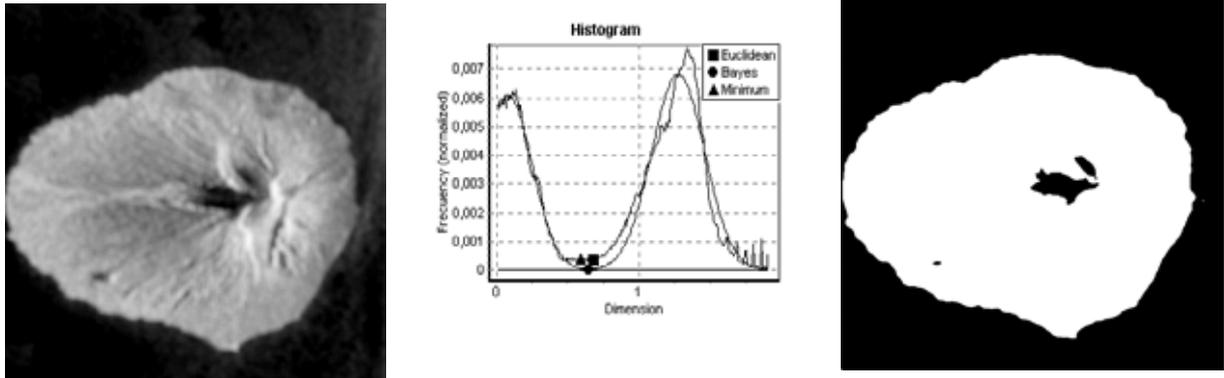


Figura 2: (a) Dimensión box D en la Fig. 1a (representada como niveles de gris), (b) histograma de D y los valores de umbralización, y (c), umbralización utilizando clasificación Bayesiana.

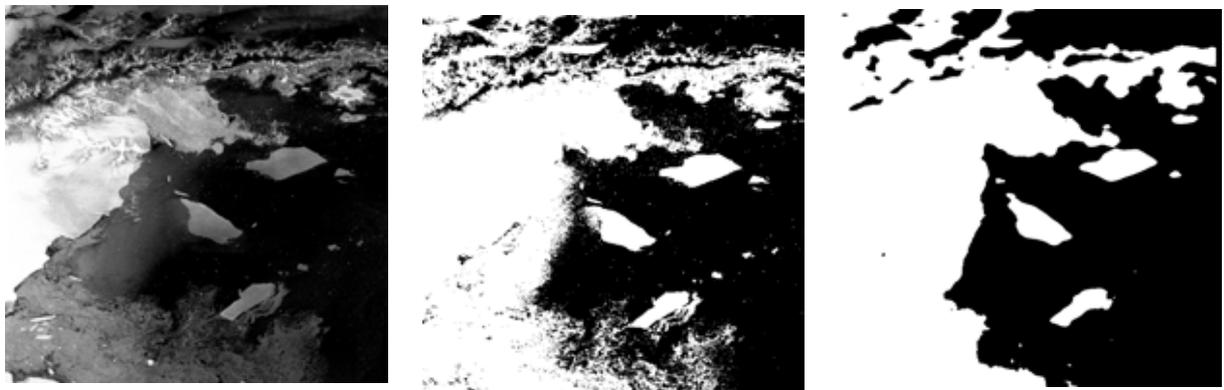


Figura 3: Ejemplo de umbralización (en luminancia y en dimensión box).

trabajo tomamos grillas de 5×5 o 7×7 pixels como relación de compromiso, lo cual mostró experimentalmente ser adecuado para nuestros objetivos. Para computar la Ec. 1, debería umbralizarse la imagen antes de computar los píxeles visitados. Esto produce una circularidad en el problema. Por dicha razón es que en vez de computar $N(s)$ como sumatoria de píxeles visitados, simplemente integramos la luminancia acumulada en la grilla de la sub-imagen. Esto hace que que la estimación de D sea en realidad más fácil de computar. 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. 2a 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. 2b 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. 2c 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.

Tomamos como ejemplos figuras del Planetary Photojournal de la NASA (<http://photojournal.jpl.nasa.gov/>). En la Fig. 3 mostramos un ejemplo de umbralización (en luminancia vs. en dimensión fractal), en la Fig. 4 un ejemplo de detección de fronteras (en luminancia vs. en dimensión fractal), y en la Fig. 5 ejemplos de extracción de contornos por medio de algoritmos evolutivos (ver [9]).

Referencias

- [1] M. F. Barnsley. *Fractals Everywhere*. Academic Press, Boston, 1988.
- [2] A. Blake y 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.

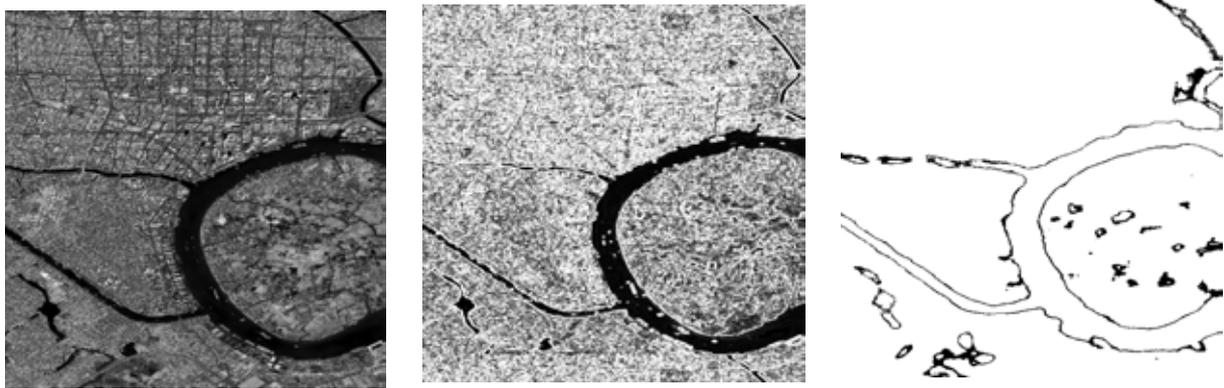


Figura 4: Ejemplo de detección de bordes (en luminancia y en dimensión box).

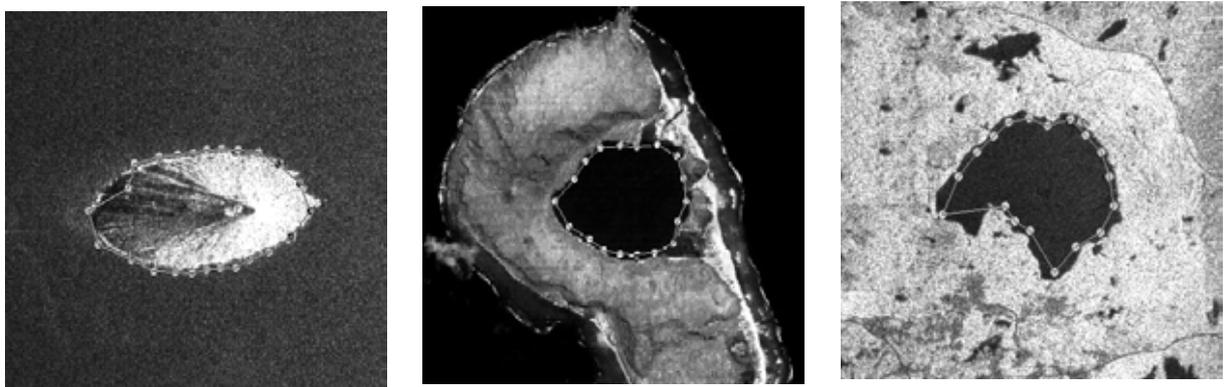


Figura 5: Ejemplos de extracción de contornos.

- [3] J. Gambini, J. Jacobo, M. Mejail y A. Frery. SAR image segmentation using B-Spline deformable contours. *Congreso Argentino de Ciencias de la Computación*, pp. 503–510, Buenos Aires, 2002.
- [4] D. Goldberg. *Genetic Algorithms in Search, Optimization and Machine Learning*. Addison-Wesley, New York, 1989.
- [5] Rafael González y Richard Woods. *Digital Image Processing*. Addison-Wesley, 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 y C. Delrieux. Extracción de Contornos Mediante Algoritmos Evolutivos. *Congreso Argentino de Ciencias de la Computación* pp. 588–599, 2002.
- [9] R. Katz y C. Delrieux. Boundary Extraction Through Gradient-Based Evolutionary Algorithm. *Journal of Computer Science and Technology*, 3:7–12, 2003.
- [10] T. Lillesand y R. Kiefer. *Remote Sensing and Image Interpretation*. Wiley, NY, 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.