

Estimación de características lineales en imágenes de sensado remoto

Marina P. Cipolletti^{1,2}, Claudio A. Delrieux^{2,3}, Gerardo M. E. Perillo^{1,4}, and M. Cintia Piccolo^{1,5}

¹ Instituto Argentino de Oceanografía, CONICET. CP B8000FWB. Bahía Blanca, Argentina

² Instituto de Investigaciones en Ingeniería Eléctrica, CONICET- Dpto. de Ing. Eléctrica y de Computadoras, UNS

³ Universidad Nacional de Tres de Febrero

⁴ Departamento de Geología, UNS

⁵ Departamento de Geografía y Turismo, UNS

e-mail: mpcipolletti@gmail.com

Resumen En este trabajo se formula un método de estimación de perímetro a partir de una imagen de baja resolución con técnicas de geometría fractal. El algoritmo segmenta la imagen y sub-muestras de la misma y determina la longitud de la poligonal en cada caso empleando Marching Squares con Interpolación Lineal. Finalmente, se aplica la regresión fractal de la dependencia entre la longitud y la escala utilizada lo cual permite calcular la dimensión fractal y con ella estimar en forma robusta el perímetro en una resolución mayor.

Palabras clave: estimación, perímetro, dimensión fractal.

1. Introducción

Richardson [11], durante su análisis matemático de la guerra, estudió la longitud de las fronteras. En sus mediciones de límites entre varios países, observó que la distancia obtenida dependía de la precisión utilizada al calcular y el resultado final aumentaba si aumentaba el nivel de detalle. Luego de reunir datos de diferentes ejemplos, descubrió que existen constantes F y D características de cada frontera

tal que la ecuación $L(\epsilon) = F\epsilon^{1-D}$ aproxima su longitud. Mandelbrot [10] continuando los estudios de Richardson propuso utilizar el valor del exponente D como *dimensión fraccionaria o dimensión fractal (DF)*.

El método estándar de análisis fractal es el postulado por Richardson [10,4] el cual determina la invariancia de escala D en el plano $\log(\text{Longitud})-\log(\text{Escala})$, sin embargo, diferentes autores presentan en sus trabajos técnicas de medición de DF y analizan su performance [1,3,9]. Definir longitudes es un tema recurrente en muchas disciplinas. En particular, en PDI la medición de perímetro depende del método empleado para medir [2] y, por lo tanto, su utilización para determinar la constante D se ve altamente influenciada [6,7]. Håkanson (1978) en su trabajo de estimación de perímetros establece las pautas para calcular la medición. En investigaciones posteriores, se reconoce la dependencia existente entre D y la densidad de muestreo y se determina que los gráficos de Richardson son lineales a trozos [5,12,8].

En este trabajo, se formuló un método de estimación de perímetros a partir de extrapolación fractal, el cual se basa en la idea original presentada por Richardson. El algoritmo establece la regresión fractal de la relación entre mediciones realizadas con diferentes resoluciones, para extrapolar el valor correspondiente a una medición hipotética realizada con muy alta definición. Se presentan los primeros resultados aplicados sobre sectores de la costa de la provincia de Buenos Aires que luego se extendieron a islas del estuario de Bahía Blanca.

2. Metodología

2.1. Preparación de la imagen

Segmentación: el algoritmo se basa en el concepto de distancia mínima. A partir de la elección de píxeles prototipo o referencia, se determina una función escalar distancia que relaciona los datos de todas las bandas de información con un único coeficiente. Cada píxel prototipo representa en su composición en bandas las características del objeto que se desea segmentar. A la imagen en escala de gris generada en función de los coeficientes la denominamos *imagen distancia* y se puede clasificar en fondo/figura definiendo un valor de umbral U .

Submuestreo: sobre la imagen segmentada se aplica un filtro lineal basado en *kernels o máscaras de convolución*. El kernel es una matriz de coeficientes f de tamaño y forma variable elegido por el usuario, sin embargo comunmente se

trata de una matriz cuadrada de $n * n$. En el dominio del espacio se realiza una convolución (barrido) del kernel sobre la imagen de partida. Cada píxel de la imagen resultante q_{xy} se obtiene mediante la sumatoria de la multiplicación del kernel por los píxeles contiguos a p_{xy} normalizado mediante una constante k (figura 1). El número de imágenes conseguidas depende de la resolución inicial de la misma y las dimensiones del objeto en estudio.

Perímetro: se calcula la longitud del perímetro de todas las imágenes utilizando el algoritmo *Marching Squares con Interpolación Lineal* (MSI) [2]. El MSI, se basa en el Marching Squares original y permite obtener resultados super resolución sobre *imágenes distancia*.

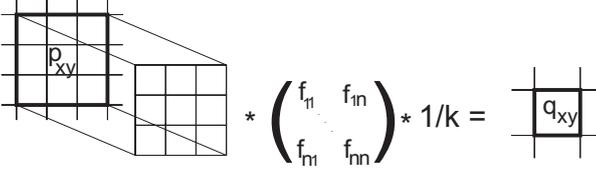
$$\begin{aligned}
 F^{nn} &= \begin{pmatrix} f_{11} & \cdots & f_{1n} \\ \vdots & \ddots & \vdots \\ f_{n1} & \cdots & f_{nn} \end{pmatrix} \\
 k &= \sum_{i=1}^n \sum_{j=1}^n f_{ij} \\
 q_{xy} &= \left(\sum_{i=1}^n \sum_{j=1}^n f_{ij} p_{ij} \right) / k
 \end{aligned}$$


Figura 1. Esquema para submuestrear.

2.2. Regresión Fractal

Durante el proceso de submuestro y medición se producen tantos pares de datos como imágenes se puedan generar. Los puntos se grafican en un diagrama de dispersión en el plano $\log(P)$ vs $\log(1/R)$ y se calcula la recta que mejor aproxime los puntos de acuerdo con el criterio de menor error cuadrático. Las ecuaciones para aproximar la recta son:

$$\sum_{i=1}^n \log(P_i) = nc + \sum_{i=1}^n \log(1/R_i) \quad (1)$$

$$\sum_{i=1}^n \log(P_i) \log(1/R) = c \sum_{i=1}^n \log(1/R_i) + b \sum_{i=1}^n \log(1/R_i)^2 \quad (2)$$

donde b y c son el término independiente y la pendiente de la recta de aproximación respectivamente. Finalmente la recta queda como:

$$\log(P_e) = (b + 1) \log(1/R) + c \quad (3)$$

P_e es el perímetro estimado para una resolución R buscada.

3. Resultados

3.1. Validación de resultados con imágenes Landsat

Las primeras pruebas se realizan con sub-muestreos de una imagen Landsat. La resolución utilizada para la medición directa fue de $R = 30 \text{ m}$ (resolución original) y se generaron submuestreos de la misma con resolución final variando R entre 150 m y 270 m . La imagen presenta un perfil de costa de la zona sur de la Provincia de Buenos Aires. Se segmentó a partir de distancia mínima a un prototipo de la región con presencia de agua y se utilizaron las bandas 4, 5 y 7 para calcular distancia Euclídea. En la figura 3a se señala la región medida y en la figura 2 se grafica las líneas de costa utilizando diferente escala. El valor del perímetro con escala $R = 30 \text{ m}$ medido se comparara con el resultado estimado con el resto de los datos y las ecuaciones de la sección 2.2 de regresión fractal.

3.2. Validación de resultados con imágenes de alta resolución

El segundo ejemplo fue la verificación de resultados con mediciones realizadas en imágenes de resolución fina. Se eligió un islote dentro del estuario de Bahía Blanca y se segmentó en dos tipos distintos de imágenes. Por un lado se utilizó un recorte de

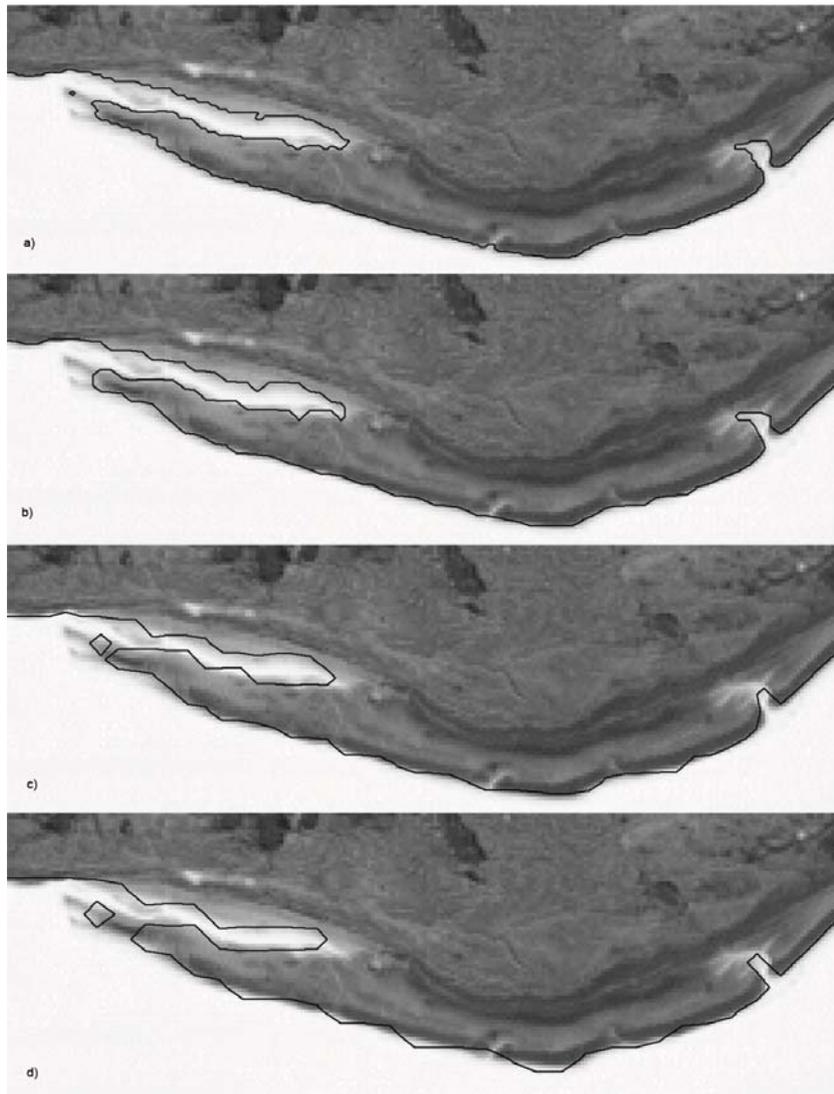


Figura 2. Efecto de la resolución (R) en el perímetro medido (P). a) $R = 30\text{ m}$ y $P = 26070\text{ m}$. b) $R = 90\text{ m}$ y $P = 25350\text{ m}$. c) $R = 150\text{ m}$ y $P = 24300\text{ m}$. d) $R = 210\text{ m}$ y $P = 23250\text{ m}$.

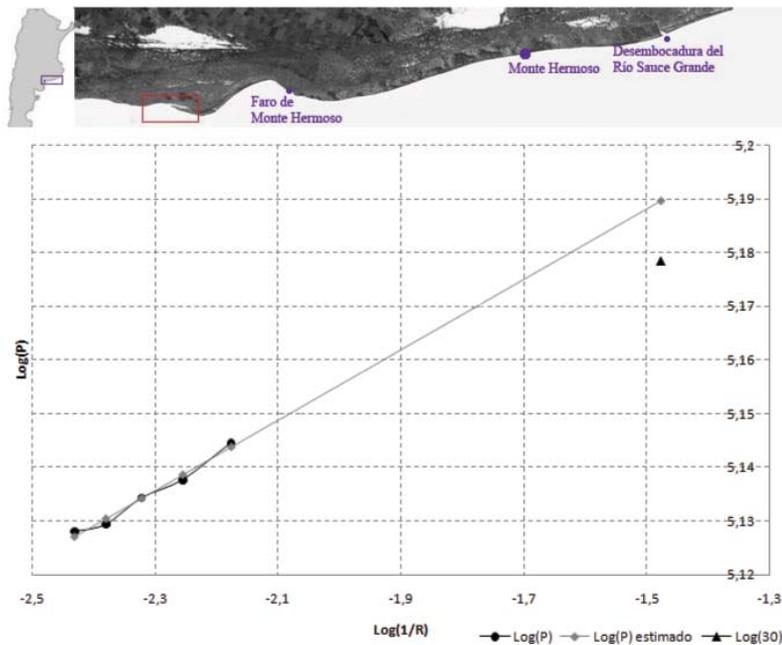


Figura 3. Regresión Fractal de la costa. a) Región medida. El recuadro violeta delimita el sector de la costa medido y el rojo la región graficada en la figura 2. b) Regresión fractal.

imagen Landsat la cual luego de ser segmentada se le aplicó el método de estimación fractal presentado y por el otro un recorte de imagen Ikonos de alta resolución (figura 5a). La información medida en la imagen Ikonos se utilizó para contrastar la estimación realizada con submuestreos de la misma zona en una imagen Landsat. En la figura 4 se presentan en forma gráfica los datos de la regresión fractal y los puntos importantes. En las figuras 5c y 6b se muestran las clasificaciones obtenidas a partir de las imágenes distancia del recorte sobre Ikonos y Landsat respectivamente. En la figura 7 se presentan los resultados de superponer las imágenes binarias y las poligonales del perímetro obtenido en cada caso con el cambio apropiado en la escala. En esta imagen se observa que si bien la imagen Landsat no posee los

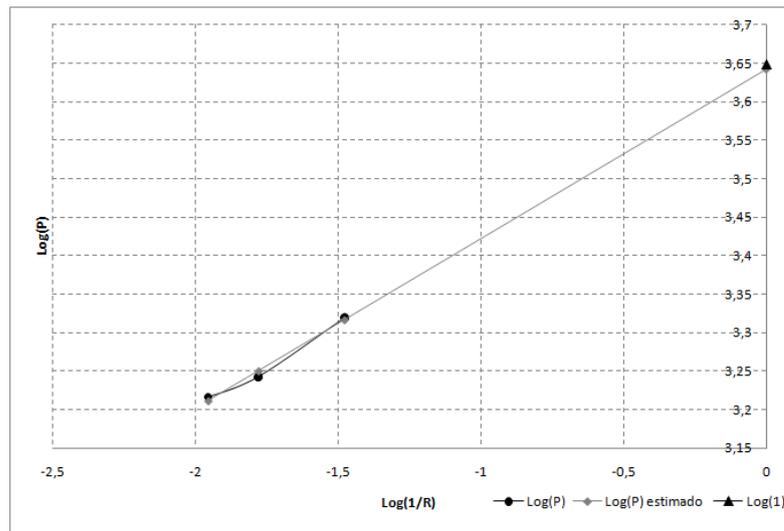


Figura 4. Regresión Fractal de un islote del estuario.

detalles de alta frecuencia presentes en la imagen Ikonos es posible asegurar su correspondencia.

4. Conclusiones

En este trabajo se presentó un método de estimación de perímetros. Las primeras pruebas se realizaron sobre sectores de la costa de la provincia de Buenos Aires y se extendieron a islas del estuario de Bahía Blanca. Esta estimación resultó ser extremadamente precisa, en áreas geográficas para las que se contaba con imágenes satelitales de diferentes resoluciones (Landsat e Ikonos), sin los problemas de incongruencia de información que se presentaban hasta el momento en la realización del cómputo con el uso de cartografía heterogénea. En el primer ejemplo, si bien el nivel de rugosidad es bajo ($DF = 1,065$), se observa que el error no supera el 3% sugiriendo que es posible la estimación de características lineales. En el segundo ejemplo, la DF obtenida fue de 1,22 ya no tan pequeña si tenemos en cuenta que la

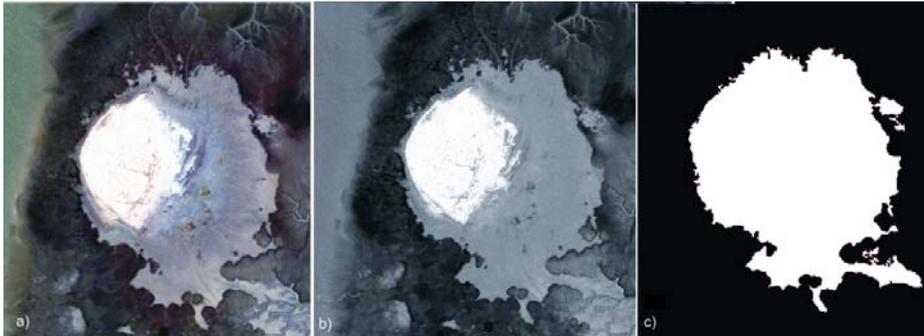


Figura 5. Islote del estuario de Bahía Blanca. a) Recorte de la imagen Ikonos original. b) Imagen distancia. c) Imagen binaria, clasificación supervisada.

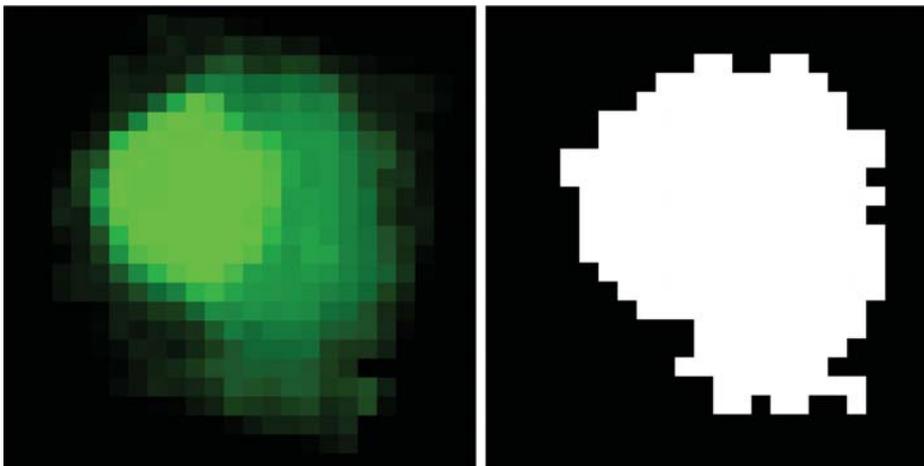


Figura 6. Isla del estuario de Bahía Blanca. a) Recorte de la imagen Landsat con el resultado de distancia. b) Clasificación de la imagen distancia.

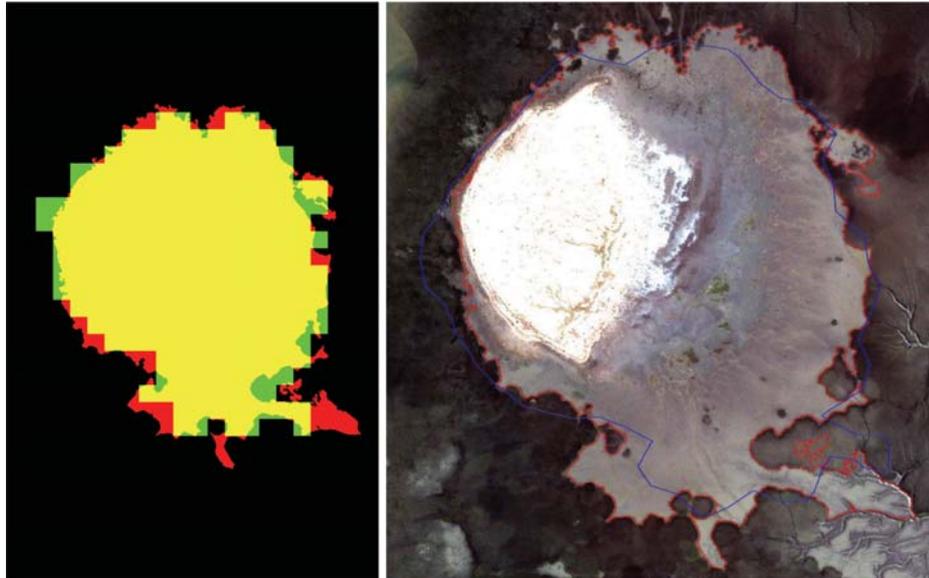


Figura 7. Superposición de resultados. a) Superposición de imágenes binarias. b) Superposición de línea de costa (en rojo/azul coordenadas obtenidas a partir de MSI en la imagen Ikonos/Landsat).

costa de Gran Bretaña presenta el mismo valor. El error calculado en la estimación es de 1,39 %, superando la performance de métodos estándar de medición.

Referencias

1. M. Allen, G. Brown, and N. Miles. Measurement of boundary fractal dimensions: review of current techniques. *Powder Technology*, 84(1):1–14, 1995.
2. Marina P. Cipolletti, Claudio A. Delrieux, Gerardo M.E. Perillo, and M. Cintia Piccolo. Super-resolution Border Segmentation and Measurement in Remote Sensing Images. *Computers & Geosciences*, 2011. En prensa.
3. Cathal Dillon, Paul Carey, and Richard Worden. Fractscript: A macro for calculating the fractal dimension of object perimeters in images of multiple objects. *Computers & Geosciences*, 27:787–794, 2001.

4. Steven Dutch. Linear Richardson Plots from non-Fractal Data Sets. *Mathematical Geology*, 725(6):737–751, 1993.
5. M F Goodchild. Fractals and the accuracy of geographical measures. *Mathematical Geology*, 12(2):85–98, 1980.
6. Lars Håkanson. The length of closed geomorphic lines. *Mathematical Geology*, 10(2):141–167, 1978.
7. Attila Imre. Artificial fractal dimension obtained by using perimeter-area relationship on digitalized images. *Applied Mathematics and Computation*, 173:443–449, 2006.
8. N.Ńgan Lam and Dale Quattrochi. On the Issues of Scale, Resolution, and Fractal Analysis in the Mapping Sciences. *Professional Geographer*, 44(1):88–98, 1992.
9. R. Lopes and N. Betrouni. Fractal and multifractal analysis: A review. *Medical Image Analysis*, 13:634–649, 2009.
10. B. Mandelbrot. How long is the coast of Britain? Statistical self-similarity and fractional dimension. *Science*, 156(3775):636–638, 1967.
11. Lewis Richardson. The problem of contiguity: an appendix of statistics of deadly quarrels. *General Systems Yearbook of the International Society for Science*, 6:139–187, 1961.
12. M. Shelberg, H. Moellering, and N. Lam. Measuring the Fractal Dimensions of Empirical Cartographic Curves. In *Proceedings of the International Symposium on Computer Cartography*, pages 481–490, 1982.