

COMPARACIÓN DE MÉTODOS PARA LA DETECCIÓN DE BORDES EN IMÁGENES SATELITALES SAR

COMPARISSON OF METHODS FOR BORDER DETECTION IN SAR SATELLITE IMAGES

Miguel A. Ré^{a,b} y Karim A. Nemer Pelliza^a

^a*CIII, Facultad Regional Córdoba, Universidad Tecnológica Nacional, Maestro López y Cruz Roja
Argentina, Ciudad Universitaria, 16000 Córdoba, Argentina, mgl.re33@gmail.com,
kanemer@gmail.com*

^b*Facultad de Matemática, Astronomía, Física y Computación, Universidad Nacional de Córdoba, Haya
de la Torre y Medina Allende, Ciudad Universitaria, 16000 Córdoba, Argentina, re@famaf.unc.edu.ar*

Palabras clave: Speckle, Imágenes SAR, segmentación.

Resumen. El reconocimiento y delimitación de regiones homogéneas en imágenes satelitales de radar de apertura sintética (SAR) es un problema de interés por las diversas aplicaciones posibles. Sin embargo la presencia del ruido de speckle en la retrodispersión dificulta el procesamiento de las imágenes con métodos tradicionales. Surge así el interés en el análisis y evaluación de distintas alternativas para superar esta dificultad. Presentamos en esta comunicación un análisis comparativo del desempeño de dos métodos desarrollados por uno de los autores con una nueva alternativa en desarrollo basada en la divergencia de Jensen Shannon, una medida de semejanza entre distribuciones de probabilidad. Las densidades a comparar se estiman por el método del kernel de densidad. Se generan imágenes sintéticas y se evalúa el desempeño de cada método por la cifra de mérito de Pratt (PFoM).

Keywords: Speckle, SAR images, segmentation.

Abstract. The reconnaissance of homogeneous regions and the detection of the limit between them in synthetic aperture radar (SAR) satellite images is a subject of interest on account of numerous applications. Nevertheless the presence of speckle noise in backscatter makes it difficult the images processing by traditional methods. Consequently it is of interest the analysis and evaluation of different alternatives to overcome this shortcoming. We present in this paper a comparative analysis of the performance of two methods developed by one of the authors with a new alternative in development based on Jensen Shannon divergence, a measure of similarity between two probability distributions. The probability density functions to be compared are estimated by the kernel density approximation. Synthetic images are generated and the performance of the methods are evaluated by means of Pratt figure of merit.

1. INTRODUCCIÓN

La delimitación de regiones en imágenes satelitales SAR resulta de interés por las distintas aplicaciones que surgen. Citamos a modo de ejemplo el análisis de cobertura como en [Davis y Robbins (2018), Comber et al. (2005)], la evolución del hielo antártico [Whitehouse et al. (2019)] o la detección de cambios temporales en imágenes SAR [Yang et al. (2014)]. Sin embargo la presencia de un ruido multiplicativo de aspecto moteado (speckle) dificulta el procesamiento de las imágenes SAR. Diversas alternativas se ha propuesto para superar esta dificultad como filtrado [Kuan et al. (1987)] o métodos estadísticos basados en modelos probabilísticos [Lopés et al. (1990)].

Ofrecen otra opción los sistemas híbridos que combinan técnicas de inteligencia artificial entre sí y/o con técnicas matemáticas y estadísticas. En este contexto se presentaron y analizaron dos técnicas para la localización de líneas costeras: las denominadas Fuzzy Wavelet Framework (FWF) [Nemer Pelliza et al. (2016)] y Adaptive Canny's Parameters Regression (ACPR) [Nemer Pelliza et al. (2019)].

Alternativamente estamos considerando un método basado en el cálculo de la divergencia de Jensen Shannon (DJS) [Deza y Deza (2006)], presentado en una comunicación simultánea. La DJS es una medida de distancia o diferencia entre distribuciones de probabilidad. En esta oportunidad estamos adaptando el método de segmentación de secuencias presentado anteriormente [Ré y Aguirre Varela (2016)].

Nuestro interés en esta presentación es establecer una comparación de los métodos que hemos desarrollado. Esta comparación la hacemos evaluando el desempeño de los algoritmos presentados al procesar imágenes sintéticas de amplitud de retrodispersión (backscatter). Estas imágenes son generadas siguiendo los modelos usuales para amplitud de retrodispersión en imágenes SAR de regiones homogéneas de una vista (look) los valores en cada región se generan con distribución de Rayleigh [Frery (1996)]. Evaluamos el desempeño mediante la cifra de mérito de Pratt [Pratt (2007)] que toma valores entre 0 y 1, tomando en consideración tres tipos de error.

En la sección 2 describimos brevemente los métodos para la detección de bordes comparados. En la sección 3 mostramos los resultados obtenidos en la comparación. Finalmente en la sección 4 discutimos los resultados obtenidos y presentamos nuestras conclusiones.

2. MÉTODOS

Presentamos en esta sección una breve descripción de los métodos que hemos desarrollado para la detección de bordes de regiones homogéneas: Fuzzy Wavelet Framework, Adaptive Canny's Parameter Regression y Segmentación de Secuencias.

Los métodos desarrollados cumplen con 3 requisitos fundamentales para cumplir el objetivo:

1. Bajo Rango de Error : Una buena detección únicamente de bordes existentes.
2. Buena Localización: La distancia entre el píxel de borde detectado y el del borde real debe ser minimizado.
3. Mínima respuesta: Sólo una respuesta de detección por borde.

2.1. Fuzzy Wavelet Framework (FWF)

Esta es una técnica híbrida que combina la potencialidad de las Transformadas Wavelets para eliminar ruido y la capacidad de la Lógica Difusa para tomar decisiones en entornos ruidosos, incompletos e incluso erróneos [Nemer Pelliza et al. (2016)]. Consta de 5 etapas generales, donde las dos primeras permiten eliminar gran parte del ruido presente en las imágenes SAR y las tres últimas completan el proceso de extracción de bordes o líneas costeras:

1. Proyectar y reconstruir la imagen utilizando una Transformada Wavelet Unidimensional (1d-DWT) de la familia de las Discrete Meyer con 5 niveles de decimación, recorriendo la imagen en filas y columnas, de forma independiente.
2. Reconstruir dos imágenes intermedias, utilizando sólo la información de la última banda de la 1d-DWT.
3. Combinar las dos imágenes intermedias utilizando Lógica Borrosa. Para realizar la combinación se utiliza el píxel correspondiente de cada imagen intermedia y una vecindad denominada FAR (Fuzzy Area Radius, Radio de área borrosa). El valor de la FAR va de 1 a 3, tomado la vecindad según se detalla a continuación:
 - a) Únicamente toma el píxel analizado
 - b) Toma el píxel analizado y los vecinos de un píxel de distancia, haciendo un total de 9 píxeles.
 - c) Toma el píxel analizado y la vecindad de hasta 2 píxeles de distancia, haciendo un total de 25 píxeles.
4. El resultado es una transformación suave con secciones relacionadas con los conjuntos considerados en la Lógica Borrosa. Se debe indicar por parámetro la cantidad de conjuntos existentes en la imagen procesada. A este paso se lo conoce como defuzzification.
5. Extraer la frontera de tales secciones aplicando el algoritmo de serpiente, generando el mapa de borde final.

2.2. Adaptive Canny's Parameters Regression (ACPR)

El método de detección de bordes de Canny, desarrollado por John F. Canny en 1986 [Canny (1986)], utiliza un algoritmo de 5 etapas que permite detectar bordes dentro de las imágenes:

1. Aplicación de borroneo Gaussiano: Su objetivo es eliminar parte del ruido presente en la imagen. Para conseguir esto, se pasa por la imagen una máscara de 5 x 5 predeterminada. Cada píxel es definido como la suma ponderada de los valores de la vecindad de 5 x 5 multiplicado por el correspondiente peso Gaussiano, dividido por el peso total de la máscara. Los coeficientes de la tabla están determinados según el parámetro σ , que determina la forma de la Gaussiana utilizada.
2. Obtención del gradiente: Su objetivo es detectar la magnitud y la orientación del vector gradiente de cada píxel. La imagen obtenida en el punto anterior es filtrada con un núcleo Sobel en las direcciones horizontal y vertical para obtener imágenes en las que se registran la primera derivada en las direcciones horizontal, G_H , y en la vertical G_V . A partir de estas dos imágenes, se puede encontrar el valor gradiente del borde y la dirección para

cada píxel, donde la dirección del gradiente es siempre perpendicular a los bordes. El resultado es redondeado hacia una de las cuatro direcciones, a saber, horizontal, vertical y ambas diagonales.

3. **Supresión no máxima:** Tiene por objetivo afinar los bordes obtenidos en la etapa anterior. Se eliminan los píxeles que no son máximos en un entorno predeterminado, este paso es aplicado hasta que todos los bordes remanentes tienen un píxel de ancho.
4. **Umbral con Histéresis:** Tiene por objetivo la eliminación del rayado (Streaking). Denominamos rayado o Streaking a la ruptura de una línea de borde causada por la fluctuación del operador de salida por encima y por debajo del umbral. Si se aplica un único umbral T_1 a la imagen, y un borde tiene fuerza media T_1 , entonces, debido al ruido, habrá casos en los que el borde estará por debajo del umbral. También se extenderá el umbral por encima, generando una línea discontinua. Para evitar esto, la histéresis utiliza dos umbrales, uno alto y el otro bajo. Cualquier píxel de la imagen con un valor por encima de T_1 se presume que es un borde y se marca de forma instantánea como tal. Entonces, Los píxeles conectados a éste con un valor superior a T_2 también serán seleccionados como bordes. Si un borde es seguido, un gradiente T_1 es necesario para comenzar y se seguirá hasta encontrar un gradiente menor a T_1 .
5. **Cerrando contornos:** Esta etapa tiene por objetivo cerrar los contornos que podrían haber quedado abiertos debido a la presencia de ruido.

El detector de bordes de Canny depende de los tres parámetros vistos arriba, desviación estándar σ de la de la función Normal para el borroneo Gaussiano, umbral superior T_1 y umbral inferior T_2 . La eficiencia del método de Canny radica en encontrar los parámetros adecuados, los cuales dependen exclusivamente de las características del conjunto de imágenes que se está procesando. Luego de la aplicación de redes neuronales artificiales con entrenamiento reforzado y técnicas de regresión estadística, se obtuvieron un conjunto de funciones, basadas en los primeros dos momentos de las imágenes (media y varianza), para el cálculo de los tres parámetros de Canny [Nemer Pelliza et al. (2019)]. Para este trabajo se seleccionó la combinación correspondiente a retrodispersiones heterogéneas con heterogéneas. Dichas funciones son:

$$\begin{cases} T_2 = 0,3813 - 0,0001 \frac{\mu_I}{\sigma_I} \\ T_1 = 0,6389 + 0,0013 \sigma_I \\ \sigma = 1,3524 + 9,7027 \frac{\sigma_I}{\mu_I} \end{cases}$$

Siendo μ_I y σ_I la media y la desviación estándar de los valores de los píxeles de la imagen procesada.

2.3. Segmentación de secuencias

Consideramos aquí el registro de la imagen como una matriz que recorremos fila a fila y/o columna a columna. Cada fila o columna se analiza individualmente y se busca el punto de segmentación, a identificar con la posición del borde en la línea, como se describe a continuación. Concluido este proceso el borde se reconstruye uniendo los puntos detectados. Cabe señalar que en este caso no es necesario un filtrado previo o cualquier otro proceso de la imagen registrada. El método en este caso se basa en diferenciar la distribución de probabilidad a cada lado del punto de segmentación o del borde.

Supongamos una secuencia de n números reales (o enteros en un rango amplio, como en la digitalización de un registro continuo) conformada por dos subsecuencias estacionarias con n_1

y n_2 elementos respectivamente ($n_1 + n_2 = n$) como se ilustra esquemáticamente en la figura 1. Se pretende determinar el punto de segmentación en la secuencia, es decir el valor de n_1 , la posición del valor a partir del cual cambia el carácter estacionario de la secuencia.




Figura 1: **Punto de segmentación.** Considere una secuencia S de n números reales compuesta por dos subsecuencias estacionarias, S_1 y S_2 con n_1 y n_2 elementos respectivamente. El punto de segmentación se identifica con la posición del elemento en posición n_1 , *i. e.* el elemento luego del cual cambia la estadística.

Para detectar el punto de segmentación se propone definir una ventana de ancho fijo que se desplaza a lo largo de la secuencia. La ventana se divide en dos segmentos con igual número de elementos como se ilustra en la figura 2. La posición en la secuencia del último elemento del primer segmento se define como la posición de la ventana.




Figura 2: **Método de la ventana deslizante.** Se define una ventana deslizante para la segmentación de la secuencia. La ventana se divide en dos segmentos de igual magnitud. La posición en la secuencia del último elemento en el primer segmento se define como la posición de la ventana.

Se asocia una densidad de probabilidad a cada segmento de la ventana por el método de aproximación del kernel de densidad [Silverman (1986)] como se ha descrito en [Ré y Aguirre Varela (2016)]

$$\hat{f}_i(y) = \frac{1}{\nu_i h_i} \sum_{j=1}^{\nu_i} K\left(\frac{y - v_j}{h_i}\right) \tag{1}$$

donde la suma para aproximar una densidad de probabilidad a los valores en cada segmento de la ventana se extiende sobre los valores incluidos en ese segmento. La función del kernel, K , sólo debe cumplir la condición de normalización

$$\int_{-\infty}^{\infty} dy K(y) = 1 \tag{2}$$

Hemos elegido aquí un kernel gaussiano y el parámetro h_i , un parámetro de suavizado, resulta de una solución de compromiso para eliminar fluctuaciones espúreas sin ocultar el comportamiento de la distribución [Sheather (2004), Steuer et al. (2002)]. El método del kernel de densidad es un método no paramétrico y por lo tanto no asume un modelo particular para las densidades de probabilidad de cada segmento. Para cada posición de la ventana se calcula la DJS definida como

$$D[f_1, f_2] = H[\pi_1 f_1 + \pi_2 f_2] - \pi_1 H[f_1] - \pi_2 H[f_2] \tag{3}$$

entre las densidades aproximadas en (1) y se identifica el punto de segmentación con la posición de la ventana que hace máximo el valor de la DJS.

Aquí

$$H[f] = - \int dy f(y) \ln[f(y)] \quad (4)$$

es la entropía de Gibbs Shannon para distribuciones continuas y los factores π_i son pesos arbitrarios restringidos por la condición $\pi_1 + \pi_2 = 1$.

3. RESULTADOS Y DISCUSIÓN

Para establecer la comparación entre los métodos descriptos en la sección anterior se generaron imágenes sintéticas con ruido multiplicativo de speckle como el que está presente en imágenes SAR.

Si se considera una imagen obtenida con polarización simple en una vista (1 look) los modelos presentes en la literatura asumen una distribución de probabilidades de Rayleigh con densidad de probabilidad

$$f_R(x | \lambda) = \frac{x}{\lambda^2} \exp\left(-\frac{x^2}{2\lambda^2}\right) \quad (5)$$

para el speckle asociado a la amplitud de la señal de la retrodispersión. El parámetro λ está relacionado con el valor medio de la distribución por

$$\langle x \rangle = \frac{\sqrt{\pi}}{2} \lambda$$

Las distribuciones en distintas regiones homogéneas se diferencian por el valor medio de la retrodispersión.

Con esta consideración se generaron imágenes sintéticas y se aplicaron los métodos de detección de bordes descriptos en la sección anterior. Los resultados obtenidos se evalúan mediante el índice de mérito de Pratt [Pratt (2007)].

3.1. Generación de imágenes

Las imágenes a utilizar en la comparación se crearon en forma de matriz cuadrada divididas en dos zonas o regiones homogéneas con distinto valor medio para la retrodispersión en base a la discusión anterior para el ruido en la señal de amplitud. Se generaron dos conjuntos de imágenes a partir de bordes predefinidos: un conjunto a partir de un borde pseudo vertical y un segundo conjunto a partir de un cuadrado rotado a 45° respecto de la matriz de referencia. Estos bordes se ilustran en la figura 3. A partir de los bordes así definidos se elaboraron las secuencias que dan origen a la matriz de la imagen fila a fila. En cada fila se creó una secuencia pseudo aleatoria por el método de Monte Carlo [Papoulis (1991)] con una distribución de Rayleigh. Cada secuencia se divide en dos o más segmentos de acuerdo al borde de generación. Los valores medios para cada segmento se fijaron en una relación 5 a 1. En la figura 3 se incluyen también a modo de ejemplo dos de las figuras producidas, una para cada tipo de borde.

3.2. Resultados de la comparación

En muchas de las aplicaciones que requieren la detección de bordes de regiones la principal medida o apreciación del desempeño del método está dada por la coincidencia del borde detectado con la percepción visual de las fronteras. En general un observador puede distinguir

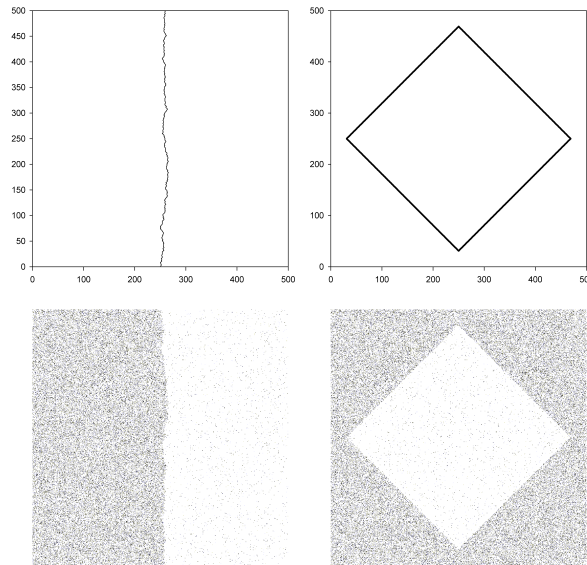


Figura 3: **Imágenes sintéticas** Imágenes generadas para la comparación de los métodos. En la fila superior los bordes predefinidos a partir de los cuales se generaron las imágenes. En la fila inferior dos imágenes de las generadas.

la frontera entre dos regiones claramente en un sentido de percepción como puede apreciarse en la figura 3. Sin embargo el trazado de la frontera sobre la imagen no resulta sencillo para el observador. Surge así la necesidad de evaluar el acierto del método de detección de bordes más allá de la apreciación cualitativa de la superposición del borde detectado en la imagen de partida.

Para la evaluación del método de detección seguimos aquí la propuesta de Pratt ya mencionada que contempla tres tipos de errores en la determinación de un borde:

1. Puntos del borde perdidos o no detectados.
2. Falla en la localización del borde, desplazamiento.
3. Falsa detección debido a fluctuaciones en el ruido.

En base a estos criterios Pratt propone un índice de mérito que contempla los errores enumerados definido por

$$P = \frac{1}{N_m} \sum_{i=1}^{N_d} \frac{1}{1 + ad_i^2} \quad (6)$$

En esta expresión $N_m = \max [N_r, N_d]$ con N_r el número de puntos que conforman el borde y N_d el número de puntos detectados en el borde. El coeficiente a es un parámetro de escala y d_i es la distancia desde cada punto detectado al borde real. El índice está normalizado por N_m de manera que $P = 1$ corresponde a una detección exacta del borde. El factor de escala puede ajustarse a fin de penalizar los puntos detectados en forma desplazada. Hemos usado aquí el valor sugerido en [Pratt (2007)] $a = 1/9$.

En la comparación calculamos el índice P para la detección del borde con cada método en cada conjunto de figuras. Los resultados obtenidos se ilustran en la figura 4 presentando los histogramas correspondientes a los valores de P para cada método.

Observamos en general un mejor desempeño de los métodos ACPR y de segmentación frente a




Figura 4: **Resultados de la comparación** Presentamos los histogramas obtenidos para el índice de mérito para cada método evaluado.

FWF, tanto por dar mayores valores promedio de P como por estar más concentrados alrededor de estos valores medios. Notamos además que los valores promedio de P están próximos o superan el valor de 0,9, lo cual se considera un buen desempeño.

4. RESUMEN Y CONCLUSIONES

Hemos efectuado la comparación del desempeño de tres métodos de detección de bordes en imágenes satelitales por nosotros desarrollados. La evaluación del desempeño se hizo a partir de la detección de bordes en imágenes sintéticas generadas a partir de fronteras preestablecidas. De esta forma podemos cuantificar la bondad de cada aproximación del borde detectado a los bordes originales.

Para esta evaluación hemos considerado el índice de mérito de Pratt P presentado en la ec. (6). Encontramos en general un buen desempeño de los tres métodos considerados tomando como referencia los valores encontrados en la literatura: valores próximos o por encima de 0,9 se consideran satisfactorios. Existe una diferencia en favor de los métodos de ACPR y Segmentación. Mencionamos además la simpleza del método de segmentación al no requerir un tratamiento previo de la imagen a analizar.

AGRADECIMIENTOS

Agradecemos a SCyT-UTN el financiamiento parcial de este proyecto.

REFERENCIAS

- Canny J.F. A computational approach to edge detection. *IEEE Trans. on Pattern Analysis and Machine Intelligence*, 8:679–698, 1986.
- Comber A., Fisher P., y Wadsworth R. What is land cover? *Environment and Planning B: Planning and Design*, 32:199–209, 2005.
- Davis D.K. y Robbins P. Ecologies of the colonial present: Pathological forestry from the taux de boisement to civilized plantations. *Environment and Planning E: Nature and Space*, 1:447–469, 2018.
- Deza E. y Deza M.M. *Dictionary of Distances (First Edition)*. Elsevier B. V., 2006.

- Frery A.C. El modelo multiplicativo para el análisis de imágenes sar. *Proceedings of the first Latino-American Seminar on Radar Remote Sensing - Image Processing Techniques*, páginas 63–70 – <http://articles.adsabs.harvard.edu/full/1997ESASP.407...63F/0000063.000.html> SAO/NASA Astrophysics Data System (ADS), 1996.
- Kuan D., Sawchuk A., Stand T., y Chavel P. Adaptive restoration of images with speckle. *IEEE Trans. Acoust. Speech. Signal Processing, ASSP*, 35:373–383, 1987.
- Lopés A., Laur H., y Mezry E. Statistical distribution and texture in multilook and complex sar images. *Proc. IGARSS*, páginas 20–24, 1990.
- Nemer Pelliza K.A., Pucheta M.A., y Flesia A.G. Unsupervised fuzzy-wavelet framework for coastal polynya detection in synthetic aperture radar images. *Cogent Engineering*, 3(1), 2016. doi:10.1080/23311916.2016.1216725.
- Nemer Pelliza K.A., Pucheta M.A., y Flesia A.G. Optimal canny's parameters regressions for coastal line detection in satellite-based sar images. *IEEE Geoscience and Remote Sensing Letters*, páginas 1–5, 2019. ISSN 1545-598X. doi:10.1109/LGRS.2019.2916225.
- Papoulis A. *Probability, Random Variables and Stochastic Processes - 3rd Ed.* McGraw - Hill International Editions, 1991.
- Pratt W. *Digital Image Processing: PIKS Scientific Inside.* Wiley-Interscience, John Wiley & Sons, New York, 2007.
- Ré M. y Aguirre Varela G.G. Segmentación de secuencias de rango continuo mediante información mutua. *Mec. Computacional*, 35:1195–1202, 2016.
- Sheather S.J. Density estimation. *Stat. Sci.*, 19:588–597, 2004.
- Silverman B.W. *Density Estimation for Statistics and Data Analysis.* Chapman and Hall, London, 1986.
- Steuer R., Kurths J., Daub C.O., Weise J., y Selbig J. The mutual information: Detecting and evaluating dependencies between variables. *Bioinformatics*, 18:S231–S240, 2002.
- Whitehouse P.L., Gomez N., King M.A., y Wiens D.A. Solid earth change and the evolution of the antarctic ice sheet. *Nature Communications*, 10:503 | <https://doi.org/10.1038/s41467-018-08068-y> | www.nature.com/naturecommunications, 2019.
- Yang W., Song H., Xiaojing H., Xu X., y Liao M. Change detection in high-resolution sar images based on jensen shannon divergence and hierarchical markov model. 7:3318–3327, 2014.