

SVM en Clasificación de Imágenes SAR con Características de Textura

A. Rey^{1,2}, J. Gambini^{3,4}, C. Delrieux^{5,6}

¹Dpto. de Matemática, UTN, FRBA, Argentina

²Centro de Procesamiento de Señales e Imágenes, UTN, FRBA, Argentina.

³Depto. de Ingeniería en Informática, ITBA, Argentina

⁴Depto. de Ingeniería en Computación, UNTreF, Pcia. de Buenos Aires, Argentina

⁵Dpto. de Ingeniería Eléctrica y de Computadoras, UNS, Bahía Blanca, Argentina

⁶Consejo Nacional de Investigaciones Científicas y Técnicas de Argentina

arey@frba.utn.edu, mgambini@itba.edu.ar, cad@uns.edu.ar

Resumen Las imágenes SAR (*Synthetic Aperture Radar*) cumplen un rol fundamental en el monitoreo ambiental y observación terrestre debido a que proveen información que las imágenes ópticas no proporcionan. Sin embargo, estas imágenes están contaminadas con un ruido inherente al método de captura, llamado ruido *speckle*, que dificulta su análisis e interpretación automática. Los modelos avanzados de segmentación de imágenes SAR están dedicados a resolver las dificultades que este ruido provoca. En este sentido, resulta de suma importancia el estudio de parámetros que describan las características estructurales de textura de la imagen en presencia de ruido *speckle*. En este trabajo, se propone un nuevo modelo de clasificación de imágenes SAR basado en el cálculo de descriptores de textura locales, formando un vector característico, el cual involucra estimaciones de parámetros de una distribución de probabilidad, estimaciones de la dimensión fractal y entropía de Tsallis. Luego, el etiquetado de cada píxel se realiza utilizando el método de clasificación supervisada SVM (*Support Vector Machine*). Se analizan los resultados de aplicar el algoritmo propuesto en imágenes SAR sintéticas, simples y con valores extremos agregados, los cuales muestran alta eficacia y son prometedores para la aplicación en imágenes SAR reales.

Keywords: Clasificación de imágenes SAR, Características de Textura, Entropía, Dimensión Fractal, SVM.

1. Introducción

Las imágenes SAR son ampliamente utilizadas en monitoreo ambiental y observación terrestre debido a que poseen importantes ventajas con respecto a imágenes ópticas. Por ejemplo, el sistema que las captura posee iluminación propia independizándolo de la luz solar, y atraviesa las nubes, por lo que no está supeditado a las condiciones climáticas. Además, posee la habilidad de tomar medidas indirectas de humedad y densidad de minerales [1]. Sin embargo, estas imágenes están contaminadas con un ruido inherente al método de captura llamado ruido *speckle*, el cual es no aditivo, no Gaussiano y muy difícil de eliminar.

Este ruido dificulta enormemente el análisis de este tipo de imágenes. Debido a su naturaleza estocástica, es posible describirlo utilizando el modelo multiplicativo y distribuciones estadísticas apropiadas, algunas de las cuales se discuten en [2].

Siguiendo el modelo multiplicativo, Frery *et al.* [3] introdujeron la distribución \mathcal{G}_I^0 que puede ser utilizada en el análisis de datos SAR pues describe de manera adecuada regiones con diferente grado de textura. Está gobernada por tres parámetros: α , relativo al grado de textura de la imagen; γ , relacionado con el brillo y L , que representa el número de *looks*. En este artículo, utilizamos la estimación por máxima verosimilitud del parámetro α como descriptor de textura.

Otro enfoque muy relevante para describir textura de una imagen es la utilización de estimaciones de la dimensión fractal [4], que caracteriza la complejidad geométrica de un conjunto y es invariante a transformaciones de escala [5]. En nuestra propuesta, utilizamos dos técnicas de estimación: la *box-counting* y el área del prisma triangular. Ambas pueden utilizarse como medida de rugosidad de una región de la imagen [6].

Asimismo, la teoría de información provee métodos para cuantificar el grado de información que posee un conjunto de datos, algunos de los cuales pueden utilizarse como descriptores de textura de imagen [7]. En particular, utilizamos la entropía de Tsallis, propuesta en [8] como una generalización de la clásica entropía de Shannon y que fue utilizada con relativo éxito para segmentación de imágenes SAR [9].

Nuestra contribución se basa en presentar un nuevo enfoque para la clasificación de imágenes SAR, utilizando un vector de descriptores de textura representante de regiones de interés y aplicando el método de aprendizaje supervisado SVM [10]. Empleamos generadores de valores aleatorios que siguen la distribución \mathcal{G}_I^0 para construir imágenes SAR sintéticas, sin contaminar y contaminadas con valores extremos, imitando el fenómeno *double bounce* que aparece en la captura real de imágenes SAR. Luego de aplicar la metodología presentada, observamos que los resultados obtenidos permiten distinguir regiones con diferentes grados de textura, pudiendo ser muy prometedores en la aplicación a imágenes SAR reales.

El resto del artículo está organizado de la siguiente manera: en la Sección 2 se presentan brevemente los descriptores de textura utilizados. En la Sección 3 se muestran los resultados de aplicar el método de clasificación a imágenes sintéticas. Finalmente, en la Sección 4 se extraen conclusiones y se proponen líneas de trabajo futuro.

2. Características de Textura

Con el objetivo de etiquetar cada píxel de la imagen y distinguir regiones con diferente grado de textura, construimos un vector de características locales, utilizando un entorno alrededor de cada píxel. Tomamos como referencia, una muestra de píxeles etiquetados y que utilizamos como conjunto para entre-

namiento, validación cruzada y testeo del método SVM. En esta oportunidad distinguimos entre tres regiones: pastura, bosque y zona urbana. Por razones de espacio realizamos una muy breve presentación de las características utilizadas, pero remitimos al lector interesado a la bibliografía correspondiente, indicada en cada caso.

El vector de características está compuesto por un conjunto parcial o total de los siguientes elementos:

1. Estimación por máxima verosimilitud del parámetro α de la distribución \mathcal{G}_I^0 [11].
2. Estimación de la dimensión fractal, utilizando el método de *box-counting* [6].
3. Estimación de la dimensión fractal, considerando a la imagen como una superficie y calculando el área del prisma triangular [12,13].
4. Índice entrópico óptimo para la entropía de Tsallis [14].
5. Entropía de Tsallis con el índice entrópico hallado en el punto anterior [8].

3. Resultados de Aplicar el Método en Imágenes SAR Sintéticas

Siguiendo las recomendaciones propuestas en [15], generamos imágenes, de tamaño 500×500 y divididas en tres regiones, utilizando la distribución $\mathcal{G}_I^0(\alpha, \gamma, L)$ con parámetros $(\alpha; \gamma) \in \{(-6,5; 0,1), (-3,5; 0,1), (-2; 0,1)\}$ y $L \in \{1, 2\}$. La Figura 1 muestra las imágenes generadas con $L = 1$ (izquierda), $L = 2$ (medio) y los píxeles etiquetados (derecha), donde la región roja corresponde a una zona muy texturada o zona urbana, la verde a un área de textura media, como puede ser un bosque, y la azul a una zona de baja textura, como de pastura. Luego, estas imágenes sintéticas son contaminadas artificialmente imitando el efecto *double bounce*, el cual se produce durante la captura de imágenes reales provocando que algunos píxeles posean valores extremos. Explícitamente, si W es la imagen sintética original, $0 < \epsilon \ll 1$ es la proporción de contaminación y B es una variable aleatoria Bernoulli de parámetro ϵ , dado $C \in \mathbb{R}^+$ suficientemente grande, se genera $Z = BC + (1 - B)W$. En este trabajo consideramos $\epsilon = 0,1$ y $C = 100$.

Las cinco características de textura se calculan utilizando ventanas deslizantes de tamaño 11×11 . Para cada región, consideramos una muestra aleatoria de referencia de 900 píxeles, elegidos de manera que estén alejados de las fronteras entre áreas o de los márgenes de la imagen. Luego, el 80 % de esta muestra se usa para validación cruzada del clasificador SVM con 5 partes, eligiendo los hiperparámetros y el núcleo apropiados. El 20 % restante se usa para el testeo.

En la Figura 2 exhibimos los resultados de aplicar el clasificador resultante a las imágenes de la Figura 1 (izquierda y medio) y a sus versiones contaminadas con valores extremos. De acuerdo a la exactitud global alcanzada, puede observarse la calidad del clasificador, incluso en las imágenes contaminadas, especialmente cuando $L = 2$.

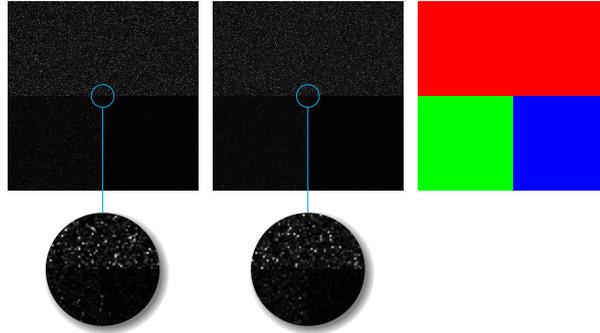


Figura 1: Imágenes SAR sintéticas $L = 1$ (izquierda), $L = 2$ (medio), y zoom de la zona de bordes para distinguir las diferentes regiones. Etiquetas de cada píxel (derecha).

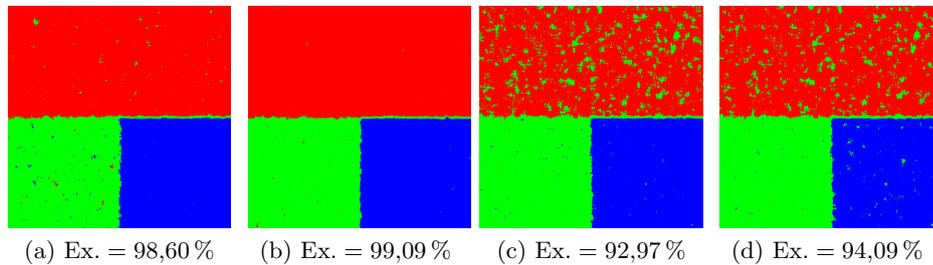


Figura 2: Clasificación y exactitud resultantes de aplicar el método a las imágenes de la Figura 1 (Figuras a y b) y a sus versiones contaminadas (Figuras c y d).

4. Conclusiones y Trabajos Futuros

En este trabajo presentamos un nuevo enfoque para segmentación de imágenes SAR utilizando clasificación de píxeles a través de características de textura. Evaluamos el método utilizando el valor de exactitud, obteniendo valores superiores al 90%. Observamos que la idea de utilizar un grupo de características en conjunto para describir textura es más apropiada que la utilización de cada una de ellas por separado. Debido a los resultados conseguidos, creemos que la aplicación de este método en imágenes SAR reales tendrá un efecto muy satisfactorio. Como trabajo futuro, tenemos la intención de aplicar nuestra propuesta a imágenes SAR reales monopolarimétricas y polarimétricas.

Referencias

1. Lee, J., Pottier, E.: Polarimetric Radar Imaging: From Basic to Application. CRC Press: Boca Raton, FL, USA (2011)

2. Yue, D.X., Xu, F., Frery, A.C., Jin, Y.Q.: SAR image statistical modeling Part I: Single-pixel statistical models. *IEEE Geoscience and Remote Sensing Magazine* (in press)
3. Frery, A., Müller, H., Yanasse, C., Sant'Anna, S.: A model for extremely heterogeneous clutter. *IEEE Transactions on Geoscience and Remote Sensing* **35**(3) (1997) 648–659
4. Gambini, J., Mejail, M., Jacobo-Berlles, J., Delrieux, C.: SAR images segmentation through b-spline deformable contours and fractal dimension. In: *International Society for Photogrammetry and Remote Sensing, Istanbul, Turkey* (2004)
5. Falconer, K.: *Fractal Geometry: Mathematical Foundations and Applications*. John Wiley & Sons, Chichester, England (1990)
6. Gneiting, T., Ševčíková, H., Percival, D.B.: Estimators of Fractal Dimension: Assessing the Roughness of Time Series and Spatial Data. *Statistical Science* **27**(2) (2012) 247–277
7. Barbieri, A.L., Arruda, G., Rodrigues, F.A., Bruno, O., Costa, L.: An entropy-based approach to automatic image segmentation of satellite images. *Physica A-statistical Mechanics and Its Applications* **390** (2009) 512–518
8. Tsallis, C.: Possible generalization of Boltzmann-Gibbs statistics. *Journal of statistical physics* **52**(1) (1988) 479–487
9. Frery, A.C., Cintra, R.J., Nascimento, A.D.C.: Entropy-based statistical analysis of polar data. *IEEE Transactions on Geoscience and Remote Sensing* **51**(6) (2013) 3733–3743
10. Boser, B.E., Guyon, I.M., Vapnik, V.N.: A training algorithm for optimal margin classifiers. In: *Proceedings of the Fifth Annual Workshop on Computational Learning Theory, New York, NY, USA, Association for Computing Machinery* (1992) 144–152
11. Frery, A., Cribari-Neto, F., de Souza, M.: Analysis of minute features in speckled imagery with maximum likelihood estimation. *EURASIP Journal on Advances in Signal Processing* **2004**(16) (2004) 370–375
12. Clarke, K.: Computation of the fractal dimension of topographic surfaces using the triangular prism surface area method. *Computers & Geosciences* **12**(5) (1986) 713–722
13. Silvetti, A.F., Delrieux, C.A.: Quadratic self-correlation: An improved method for computing local fractal dimension in remote sensing imagery. *Comput. Geosci.* **60** (2013) 142–155
14. Ramírez-Reyes, A., Hernández-Montoya, A., Herrera-Corral, G., Domínguez-Jiménez, I.: Determining the entropic index q of Tsallis entropy in images through redundancy. *Entropy* **18**(8) (2016) 299–313
15. Chan, D., Rey, A., Gambini, J., Frery, A.C.: Sampling from the \mathcal{G}_I^0 distribution. *Monte Carlo Methods and Applications* **24** (2018) 271–287