

Clasificación de Imágenes SAR utilizando Descriptores de Textura

A. Rey^{1,2}, J. Gambini^{3,4}, C. Delrieux⁵

¹Dpto. de Matemática, Universidad Tecnológica Nacional, Facultad Regional Buenos Aires, Buenos Aires, Argentina

²Centro de Procesamiento de Señales e Imágenes, Universidad Tecnológica Nacional, Facultad Regional Buenos Aires, Buenos Aires, Argentina.

³Depto. de Ingeniería en Informática, Instituto Tecnológico de Buenos Aires, Buenos Aires, Argentina

⁴Depto. de Ingeniería en Computación, Universidad Nacional de Tres de Febrero, Caseros, Pcia. de Buenos Aires, Argentina

⁵Universidad Nacional del Sur, Departamento de Ingeniería Eléctrica y de Computadoras, Bahía Blanca, Pcia. de Buenos Aires, Argentina

⁶Consejo Nacional de Investigaciones Científicas y Técnicas de Argentina- CONICET. {arey@frba.utn.edu}, {mgambini@itba.edu.ar}, {cad@uns.edu.ar}

Resumen Las imágenes SAR (Sythetic Aperture Radar) y PolSAR (Polarimetric 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 imagen en presencia de ruido speckle y permitan su interpretación automática. 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 pixel 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 resultan altamente prometedores para aplicarse en imágenes reales.

Keywords: Clasificación de imágenes SAR, Descriptores de Textura, Entropía.

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, este sistema posee iluminación propia que lo hace independiente de la luz solar, atraviesa las nubes y por lo tanto 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 e interpretación automática de imágenes SAR. Debido a la naturaleza estocástica del ruido speckle, 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 porque 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 , el número de looks. En este artículo, utilizamos la estimación del parámetro α de esta distribución como descriptor de textura.

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

Por otro lado, la teoría de la 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 este trabajo 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 polarimétricas [9].

Presentamos un nuevo enfoque para clasificación de imágenes SAR, utilizando un vector de descriptores de textura que resulta representante de la región de interés y el método de aprendizaje supervisado SVM [10]. Aplicamos el método a imágenes SAR sintéticas generadas con la distribución \mathcal{G}_I^0 sin contaminar y contaminadas con valores extremos, imitando el fenómeno *double bounce*.

Los resultados muestran que es posible distinguir regiones de agua, pastura, bosque o urbanas y son muy prometedores para aplicar el método en imágenes reales.

El resto del artículo está organizado de la siguiente manera: en la sección 1.1 se presentan brevemente los descriptores de textura utilizados. En la sección 2 se muestran los resultados de aplicar el método de clasificación a imágenes sintéticas. Finalmente, en la sección 3 se extraen conclusiones y se proponen líneas de trabajo futuro.

1.1. Descriptores de Textura de Imagen

Con el objetivo de etiquetar cada pixel de la imagen y distinguir regiones con diferente grado de textura, construimos un vector de características local,

utilizando un entorno alrededor de cada pixel. Tomamos una muestra de pixels etiquetados por un experto y la utilizamos como conjunto de entrenamiento 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 los descriptores utilizados, 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 cinco elementos:

1. Estimación del parámetro α de la distribución \mathcal{G}_I^0 [11].
2. Estimación de la dimensión fractal, utilizando el método de *box-counting*, que puede utilizarse como medida de rugosidad de una región de la imagen [6].
3. Estimación de la dimensión fractal utilizando el método presentado en [12], observando a la imagen como una superficie [13].
4. Estimación de la entropía de Tsallis [8] que provee el grado de información que posee una región.
5. Estimación del índice entrópico óptimo para la entropía de Tsallis [14].

2. Resultados de Aplicación del Método en Imágenes Sintéticas

Siguiendo las recomendaciones propuestas en [15], se generan imágenes simuladas de tamaño 500×500 utilizando la distribución \mathcal{G}_I^0 con parámetros $(\alpha, \gamma) \in \{(-6,5,0,1), (-3,5,0,1), (-2,0,1)\}$, $L \in \{1,2\}$, dividida en tres regiones. La Fig. 1 muestra la imagen para $L = 1$ (izquierda), $L = 2$ (medio) y los pixels etiquetados (derecha), la roja corresponde a una zona muy texturada o zona urbana, la verde a un región de textura media y la azul a una zona de baja textura. Estas imágenes sintéticas son contaminadas con un método de contaminación artificial imitando el efecto *double bounce* que se produce durante la captura y que resulta en que algunos pixels poseen valores extremos.

Para cada región, consideramos una muestra de entrenamiento de 900 pixels, tomados aleatoriamente pero alejados de los sectores de borde o de los márgenes de la imagen. Con estas muestras se estiman los descriptores de textura utilizando entornos alrededor de cada pixel de tamaño 11×11 . Luego entrenamos el clasificador SVM y aplicamos el método de validación cruzada para elegir los parámetros adecuados y el núcleo apropiado.

La Fig. 2 muestra los resultados de aplicar el clasificador resultante a las imágenes de la Fig. 1 (izquierda y medio). Visualmente puede observarse calidad del clasificador. Los pixels mal clasificados resultaron en 0,3% y 0,04% de la cantidad total para $L = 1$ y $L = 2$, respectivamente.

3. Conclusions and Future Work

En este trabajo, presentamos un nuevo enfoque para segmentación de imágenes SAR utilizando clasificación de pixel a través de descriptores de textura.

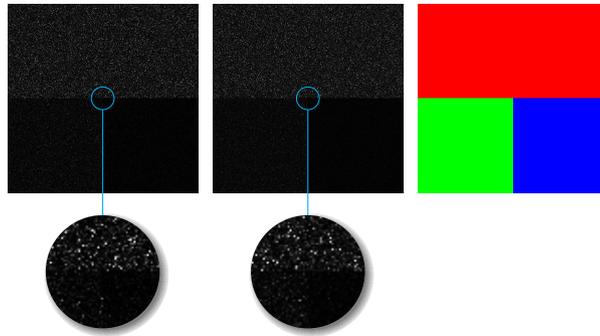


Figura 1: Imagen SAR simulada $L = 1$ (izquierda), $L = 2$ (medio), con zoom de la zona de bordes para distinguir las diferentes regiones. Etiquetas de cada pixel (derecha).

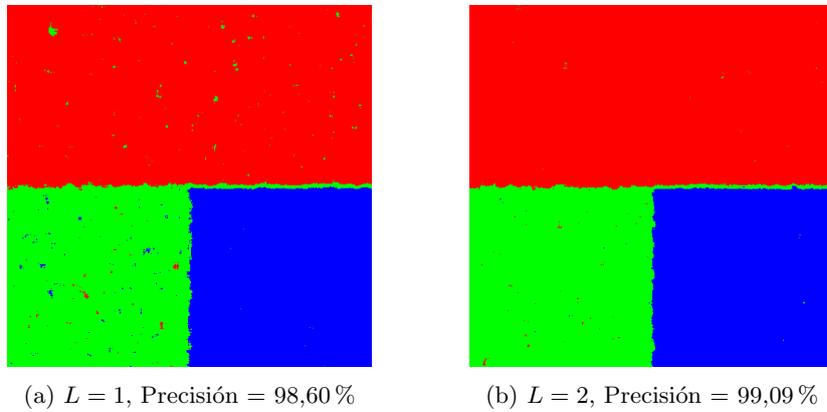


Figura 2: Resultado de aplicar el método de clasificación y los valores de precisión en cada caso.

Evaluamos el método utilizando el valor de precisión y la tasa de pixels mal clasificados. Creemos que la aplicación de este método en imágenes SAR reales tendrá resultados muy satisfactorios. Como trabajo futuro, tenemos la idea de aplicarlo a imágenes SAR 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 polsar 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. Silveti, 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