

Polarimetric SAR Image Segmentation using CEM Algorithm

J. I. F. Michelli, M. Hurtado, *Member, IEEE*, J. A. Areta and C. H. Muravchik *Senior Member, IEEE*

Abstract— In this work we perform Synthetic Aperture Radar (SAR) polarimetric images segmentation based on the Classification-Expectation-Maximization (CEM) method, with both supervised and unsupervised initialization. In the former case, the algorithm is randomly initialized with the number of classes as the only initial information, while in the unsupervised case initialization is based on a previous classification. Real EMISAR Single-Look-Complex (SLC) data are used, with Mixing Gaussian model. Results are compared with those obtained by Wishart unsupervised classification method, which is a well-known and widely used method for radar image classification. Finally, Davies-Bouldin index is applied for quantitative comparison between the obtained segmentations, and for studying the CEM method performance.

Keywords— SAR, Segmentation, Classification, Expectation Maximization, CEM.

I. INTRODUCCIÓN

EL RADAR de Apertura Sintética (SAR) es un sistema que sensa la superficie terrestre y forma imágenes de la misma para su estudio. Opera sobre una plataforma aerotransportada o satelital, emitiendo pulsos de radio frecuencia y recibiendo las ondas reflejadas en la superficie terrestre a medida que se desplaza. Mediante un adecuado procesamiento, el conjunto de estas reflexiones es transformado para formar una imagen del terreno, a partir de la cual es posible analizar diversas características del mismo, como humedad, vegetación, rugosidad, entre otras.

Dentro del procesamiento de datos SAR, la segmentación de imágenes es un tópico de gran actividad y relevancia. Consiste básicamente en la transformación de una imagen de la escena en una nueva imagen, donde los nuevos píxeles son organizados en diferentes grupos. Cada grupo se define por una característica compartida por los datos que lo conforman, reflejando información estructural de la escena subyacente. En este contexto, se entiende como clasificador al algoritmo que se encarga de clasificar cada píxel de una imagen, es decir, de indicar a cuál de las diferentes clases pertenece. De esta manera, segmentación y clasificación están íntimamente relacionadas, de forma que para poder segmentar una imagen es nece-

sario clasificar sus píxeles con algún criterio. En vista de lo anterior, se utilizará en adelante el término clasificación, para hacer referencia a la operación que se aplica a la imagen con el fin de segmentarla.

Existen numerosos métodos de clasificación, tanto supervisados como no supervisados. Los primeros necesitan una fase de entrenamiento con datos conocidos para que su algoritmo aprenda la cantidad y característica de las clases presentes en la imagen a clasificar. Los métodos no supervisados, obtienen esta información de la misma imagen a clasificar, o de alguna clasificación previa. En [1] se propone un esquema de clasificación no supervisada basada en una *descomposición polarimétrica del objetivo*, la descomposición H/α , que permite agrupar los píxeles según el tipo de reflexión (superficial, dipolo o múltiple) y el grado de aleatoriedad (entropía). En [2] se desarrolla un método de clasificación no-supervisada, basado en la matriz de covarianza de los datos y su distribución Wishart. Este algoritmo utiliza el resultado del esquema propuesto en [1] como inicialización y luego realiza una clasificación iterativa hasta alcanzar la convergencia. Ambos métodos son extensamente utilizados, por lo que serán tomados como referencia para contrastar los resultados.

En este trabajo se aplica un método de clasificación basado en el algoritmo EM (Expectation-Maximization), usando un modelo de mezcla de Gaussianas para los datos polarimétricos complejos.

Este método ha sido utilizado en trabajos previos ([3], [4]), donde la clasificación obtenida es comparada con el terreno verdadero (ground-truth), o con la clasificación de los píxeles de los datos de entrenamiento. En el presente trabajo, los resultados obtenidos son comparados utilizando el índice de Davies-Bouldin ([5]). Este índice provee una medida cuantitativa de la calidad de la segmentación, y resulta útil cuando se trabaja con datos reales y no se tiene información del terreno verdadero.

A. Organización del trabajo

El trabajo se organiza de la siguiente manera: en la Sección II se explican los fundamentos del algoritmo CEM y el modelo de datos utilizado. En la Sección III se presentan los resultados de la clasificación CEM sobre datos SAR reales y los resultados de las clasificaciones H/α y Wishart sobre los mismos datos. En la Sección IV se define el índice de Davies-Bouldin y se aplica a cada clasificación realizada y finalmente en la Secciones V y VI se discuten los resultados obtenidos y se presentan las conclusiones, respectivamente.

II. FORMULACIÓN

El algoritmo CEM (Classification- Expectation- Maximiza-

J. I. F. Michelli, LEICI Instituto de Investigaciones en Electrónica, Control y Procesamiento de Señales (LEICI-IIECPS), CONICET-UNLP, La Plata, Argentina, jfernandez@ing.unlp.edu.ar

M. Hurtado, LEICI Instituto de Investigaciones en Electrónica, Control y Procesamiento de Señales (LEICI-IIECPS), CONICET-UNLP, La Plata, Argentina, martin.hurtado@ing.unlp.edu.ar

J. A. Areta, Universidad Nacional de Río Negro (UNRN), CONICET, S.C. de Bariloche, Argentina, javierareta@gmail.com

C. H. Muravchik, LEICI Instituto de Investigaciones en Electrónica, Control y Procesamiento de Señales (LEICI-IIECPS), CICpBA-UNLP, La Plata, Argentina, carlosm@ing.unlp.edu.ar

tion) es un método de clasificación basado en el algoritmo EM ([6]). Se explicarán en primer lugar las bases de EM y luego su aplicación en el proceso de clasificación.

A. Algoritmo EM

Este algoritmo resuelve el problema de hallar el estimador de máxima verosimilitud de un conjunto de parámetros utilizando un esquema iterativo de dos etapas: una en la que por promediado se reduce el número de variables, de manera de obtener en la otra un problema de maximización más sencillo de resolver que el problema de máxima verosimilitud inicial.

Sea $X \in \mathbb{C}^d$, una variable aleatoria proveniente de un modelo compuesto de la forma:

$$f(\mathbf{x}; \boldsymbol{\theta}) = \sum_{j=1}^K \omega_j f_j(\mathbf{x}; \boldsymbol{\theta}_j), \quad (1)$$

donde f_1, \dots, f_K son las K densidades de probabilidad del modelo, cada una de las cuales, representa una clase y posee un conjunto de parámetros descrito por el vector $\boldsymbol{\theta}_j$. Los coeficientes ω_j indican en qué proporción interviene la j -ésima distribución en el modelo compuesto, cumpliendo con las condiciones $\sum_{j=1}^K \omega_j = 1$ y $\omega_j \geq 0$, $j=1, \dots, K$. $\boldsymbol{\theta} = (\omega_1, \dots, \omega_K, \boldsymbol{\theta}_1, \dots, \boldsymbol{\theta}_K)$ es el vector de parámetros desconocidos a estimar.

Dadas N observaciones independientes de $\mathbf{X} = [\mathbf{x}_1, \dots, \mathbf{x}_N]$, el problema es hallar el estimador de máxima verosimilitud de $\boldsymbol{\theta}$.

Definiendo la función de verosimilitud $L(\boldsymbol{\theta}; \mathbf{x}_1, \dots, \mathbf{x}_N)$ como:

$$L(\boldsymbol{\theta}; \mathbf{x}_1, \dots, \mathbf{x}_N) = \prod_{i=1}^N f(\mathbf{x}_i; \boldsymbol{\theta}), \quad (2)$$

el problema de estimación consiste en la siguiente maximización:

$$\hat{\boldsymbol{\theta}} = \arg \max_{\boldsymbol{\theta}} L(\boldsymbol{\theta}; \mathbf{x}_1, \dots, \mathbf{x}_N). \quad (3)$$

Debido al modelo compuesto, el problema de maximización no es de fácil resolución. El método EM surge entonces como un enfoque de resolución iterativo, hallando la solución $\hat{\boldsymbol{\theta}}$ en función de las observaciones $\mathbf{x}_i, i=1, \dots, N$. En el contexto de EM, las observaciones son denominadas datos *incompletos*, ya que no se tiene información de a cuál de las distribuciones corresponde cada uno. Los datos incompletos \mathbf{X} se corresponden con datos *completos* (\mathbf{X}, \mathbf{Y}) , donde $Y \in [1, \dots, K]$ es una variable aleatoria que indica qué distribución f_i es más probable que haya generado a \mathbf{X} . EM resuelve el problema de maximización de datos completos, utilizando sólo los datos incompletos (observaciones).

En lugar de maximizar la función de verosimilitud $L(\boldsymbol{\theta}; \mathbf{x}_1, \dots, \mathbf{x}_N)$, EM maximiza, en cada iteración, la función $Q(\boldsymbol{\theta}' / \boldsymbol{\theta}') = \sum_{i=1}^N E_{y_i | \mathbf{x}_i; \boldsymbol{\theta}'} [\log(f_{\mathbf{x}_i, y_i; \boldsymbol{\theta}'}(\mathbf{x}_i, y_i; \boldsymbol{\theta}'))]$ que aproxima a $\ln(L(\boldsymbol{\theta}; \mathbf{x}_1, \dots, \mathbf{x}_N))$ con el menor error cuadrático medio. En la expresión anterior, $\boldsymbol{\theta}'$ es el vector de parámetros estimados de

la iteración previa, $f_{\mathbf{x}_i, y_i; \boldsymbol{\theta}'}(\cdot)$ es la distribución conjunta de los datos completos y $E_{y_i | \mathbf{x}_i; \boldsymbol{\theta}'}[\cdot]$ es el operador esperanza condicional. Se puede demostrar que la secuencia de estimados $\boldsymbol{\theta}^{(l)}$ hacen crecer monótonamente a la función de verosimilitud, de manera que al alcanzar la condición de convergencia en la iteración L , $\boldsymbol{\theta}^{(L)} = \hat{\boldsymbol{\theta}}$ ([6], p.81).

La estructura del algoritmo EM es la siguiente:

1) Inicializar apropiadamente el algoritmo, de manera de disponer de un primer estimado $\boldsymbol{\theta}^{(0)}$.

2) Repetir los pasos a) y b) hasta cumplir con $\ln(L(\boldsymbol{\theta}^{(l)}; \mathbf{x}_1, \dots, \mathbf{x}_N)) - \ln(L(\boldsymbol{\theta}^{(l-1)}; \mathbf{x}_1, \dots, \mathbf{x}_N)) \leq \epsilon$.

a) *Paso E*: calcular $Q(\boldsymbol{\theta} / \boldsymbol{\theta}^{(l-1)})$ utilizando el estimado anterior $\boldsymbol{\theta}^{(l-1)}$.

b) *Paso M*: calcular $\boldsymbol{\theta}^{(l)} = \arg \max_{\boldsymbol{\theta}} (Q(\boldsymbol{\theta} / \boldsymbol{\theta}^{(l-1)}))$.

Asumiendo un modelo de mezcla de distribuciones Gaussianas para los datos SLC, cada término de la ec. (1) resulta:

$f_j(\mathbf{x}; \boldsymbol{\theta}_j) = (\pi^d |\Sigma_j|)^{-1} \exp[-(\mathbf{x} - \boldsymbol{\mu}_j)^H \Sigma_j^{-1} (\mathbf{x} - \boldsymbol{\mu}_j)]$, donde $\boldsymbol{\theta}_j = (\boldsymbol{\mu}_j, \Sigma_j)$ es el vector de parámetros de la clase j , compuesto de la media $\boldsymbol{\mu}_j \in \mathbb{C}^d$ y la matriz de covarianza $\Sigma_j \in \mathbb{C}^{d \times d}$ de esa clase. \mathbf{v}^H denota el transpuesto conjugado del vector \mathbf{v} .

En estas condiciones, en la l -ésima iteración del algoritmo resultará:

1) *Paso E*:

$$Q(\boldsymbol{\theta} / \boldsymbol{\theta}^{(l-1)}) = \sum_{i=1}^N \sum_{j=1}^K \gamma_{ij}^{(l)} \log(\omega_j f_j(\mathbf{x}_i, \boldsymbol{\theta}_j)) \quad (4)$$

$$\gamma_{ij}^{(l)} = \frac{\omega_j^{(l-1)} f_j(\mathbf{x}_i, \boldsymbol{\theta}_j^{(l-1)})}{\sum_{r=1}^K \omega_r^{(l-1)} f_r(\mathbf{x}_i, \boldsymbol{\theta}_r^{(l-1)})} \quad (5)$$

2) *Paso M*:

$$\omega_j^{(l)} = \frac{\sum_{i=1}^N \gamma_{ij}^{(l)}}{N} \quad (6)$$

$$\boldsymbol{\mu}_j^{(l)} = \frac{\sum_{i=1}^N \gamma_{ij}^{(l)} \mathbf{x}_i}{\sum_{i=1}^N \gamma_{ij}^{(l)}} \quad (7)$$

$$\Sigma_j^{(l)} = \frac{\sum_{i=1}^N \gamma_{ij}^{(l)} (\mathbf{x}_i - \boldsymbol{\mu}_j^{(l)}) (\mathbf{x}_i - \boldsymbol{\mu}_j^{(l)})^H}{\sum_{i=1}^n \gamma_{ij}^{(l)}}. \quad (8)$$

La ec. (5) indica la probabilidad a posteriori de que el i -ésimo dato provenga de la j -ésima clase, en la iteración l . Las ecs. (6) a (8) presentan el resultado de la maximización en la iteración l para cada uno de los parámetros.

B. Clasificación CEM

CEM es un clasificador que utiliza los resultados de EM y aplica una clasificación MAP (Maximum A Posteriori) a cada píxel. Luego de que EM alcanzó la convergencia en la iteración L , para cada dato (píxel) i se analiza $\gamma_{ij}^{(L)}$ para cada una de las K clases. La clasificación se realiza asignando el i -ésimo dato a la k -ésima clase si $\gamma_{ik}^{(L)} > \gamma_{ij}^{(L)}$, para $k \neq j$, $j=1, \dots, K$.

En la siguiente sección se mostrarán los resultados de aplicar CEM a datos SAR reales.

III. CLASIFICACIÓN

Tal como se indicó en la introducción, los resultados de CEM se compararán con las clasificaciones de H/α y Wishart. Si bien ambas comparaciones son válidas, la más significativa será entre CEM y Wishart debido a que, a diferencia del primero, ambos son métodos iterativos. Sin embargo se incluye la clasificación H/α , ya que es utilizada tanto por CEM como por la clasificación Wishart en los casos no supervisados.

Las clasificaciones H/α y Wishart fueron realizadas con el software de código abierto PolSarPro, desarrollado por la Agencia Espacial Europea (ESA) ([7]). Se utilizaron datos SLC de la plataforma aerotransportada EMISAR (una zona de 201×201 píxeles), disponibles en el sitio web de la ESA. La clasificación CEM se realizó con implementación propia.

Las Figs. 1 y 2 muestran los resultados de las clasificaciones por los distintos métodos. Para CEM y el método Wishart se incluyó una clasificación con promediado previo para observar el desempeño en cada caso. Dicho promediado se efectuó con un filtro de media móvil de 5×5 píxeles (boxcar filter). En el caso CEM, el resultado de la segmentación con datos promediados (Figs. 2(b) y 2(d)) presentan el efecto transitorio del filtro en sus bordes, los cuales no se han eliminado para preservar el tamaño de las imágenes.

En todos los casos se ha fijado la cantidad de clases a ocho, que resulta de la clasificación H/α . La paleta de colores se ha escogido a efectos de mejorar el contraste entre clases, y no representa ninguna característica del terreno en particular.

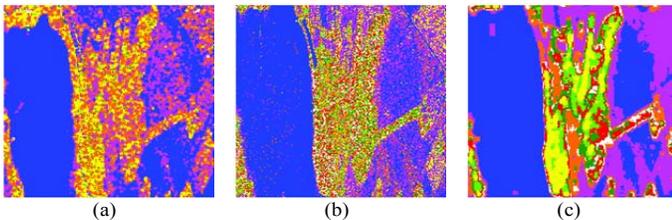


Figura 1. Clasificaciones. (a): H/α , (b): Wishart, (c): Wishart con promediado de 5×5 .

Puede observarse que CEM realiza una clasificación similar al caso Wishart, aún con inicialización aleatoria donde cuenta sólo con la cantidad de clases como información inicial, aunque de aspecto más ruidoso. Una comparación cuantitativa entre los métodos se realiza en la Sección V.

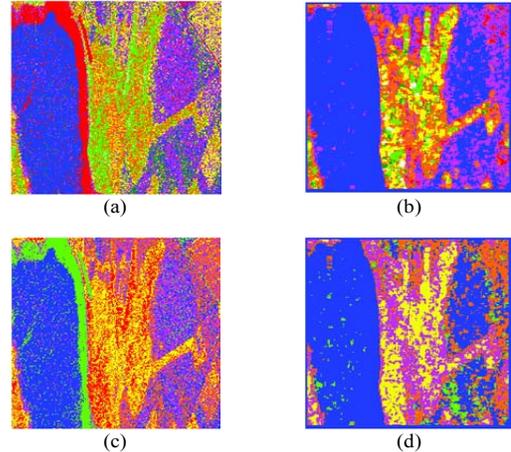


Figura 2. Clasificaciones CEM. (a): CEM con inicialización H/α , (b): CEM con inicialización H/α y promediado de 5×5 , (c): CEM con inicialización aleatoria, (d): CEM con inicialización aleatoria y promediado de 5×5 .

IV. COMPARACIÓN DE RESULTADOS

A. Índice Davies-Bouldin

Con el objetivo de realizar una comparación cuantitativa entre los resultados obtenidos, es necesario contar con un índice que mida el desempeño de una dada clasificación. En [5] los autores Davies y Bouldin definen una medida de similitud promedio \bar{R} de una imagen segmentada, que puede utilizarse para tal propósito.

Denotando S_i a la medida de dispersión en la clase i y M_{ij} la distancia entre centros de las clases i y j , el número $R_{ij} = (S_i + S_j) / M_{ij}$ es una medida de similitud entre las clases i y j . Se define la similitud promedio \bar{R} como:

$$\bar{R} = \frac{1}{K} \sum_{i=1}^K \max_{j \neq i} R_{ij} \quad (9)$$

Dado que \bar{R} es la similitud promedio, cuanto menor es este índice, mayor resulta la separación entre clases. Entendiendo que cuanto más separadas estén las clases, mejor es la segmentación que se logra, diremos que, dadas dos segmentaciones A y B con índices \bar{R}_A y \bar{R}_B respectivamente, A es mejor que B si $\bar{R}_A < \bar{R}_B$, en el sentido de este índice.

Las definiciones de las medidas de dispersión S_i y distancia M_{ij} , dependen de cada problema en particular. En este trabajo se utilizaron las siguientes definiciones:

$$\begin{aligned} S_i &= \sqrt{\frac{1}{n_i} \sum_{\mathbf{x} \in \text{clase } i} (\mathbf{x}_i - \mathbf{M}_i)^H (\mathbf{x}_i - \mathbf{M}_i)} \\ M_{ij} &= \sqrt{(\mathbf{M}_i - \mathbf{M}_j)^H (\mathbf{M}_i - \mathbf{M}_j)} \\ \mathbf{M}_i &= \frac{1}{n_i} \sum_{\mathbf{x} \in \text{clase } i} \mathbf{x}_i, \end{aligned} \quad (10)$$

donde $n_i = \# \{ \mathbf{x} \in \text{clase } i \}$.

B. Resultados

El índice de Davies-Bouldin fue aplicado a cada segmentación realizada en la Sección III. La Tabla I muestra los resultados, donde W5 y CEM5 denotan el método Wishart y CEM con datos promediados respectivamente, y RND indica inicialización aleatoria. Se ha incluido además el valor de dispersión máxima S_{\max} y distancia mínima entre clases M_{\min} para cada segmentación.

TABLA I. ÍNDICE DE DAVIES-BOULDIN.

Índice	Método						
	H/ α	W	W5	CEM	CEM5	CEM RND	CEM5 RND
S_{\max}	0.46	0.64	0.54	0.83	0.55	0.56	0.53
M_{\min}	18e-4	4.3e-4	8.4e-4	7.1e-4	18e-4	6.1e-4	15e-4
\bar{R}	114.94	150.04	101.25	111.37	57.55	82.44	80.58

V. DISCUSIÓN

De los resultados de la Tabla I, se observa lo siguiente:

- 1) \bar{R} refleja una mejor segmentación para los datos promediados que la correspondiente a los datos sin promediar, para los métodos Wishart y CEM.
- 2) La clasificación Wishart con datos sin promediar presenta \bar{R} mayor que la H/α , con la cual se inicializa. Esto no ocurre para los datos promediados.
- 3) Cuando CEM es inicializado de manera aleatoria (caso supervisado), presenta mejor desempeño que los casos CEM y Wishart con inicialización H/α , para datos sin promediar.
- 4) CEM con inicialización aleatoria presenta mejores resultados que la clasificación H/α .
- 5) Para el caso no-supervisado (inicialización H/α), el método CEM presenta un mejor desempeño que el Wishart, tanto para datos promediados como sin promediar.

La observación 1) coincide con lo que se espera intuitivamente. El efecto del promediado reduce la varianza de los datos, lo que favorece la separación de las clases.

La observación 2) indica que la clasificación Wishart requiere de filtrado para funcionar correctamente. En [2] los autores realizan un filtrado en matriz de covarianza sobre la que se aplica el clasificador, para reducir el ruido speckle y mejorar los resultados. Sin embargo, dicho proceso reduce la resolución de la imagen y puede provocar clasificaciones erróneas en la frontera entre clases. El compromiso entre reducción de speckle y desempeño en la clasificación es resuelto por el usuario de forma heurística.

Las observaciones 3) y 4) muestran un buen desempeño para CEM como clasificador supervisado, requiriendo mínima información inicial (sólo la cantidad de clases). Esto sugiere la posibilidad de utilizar los resultados de CEM como clasificador inicial. Utilizando el modelo de mezcla de Gaussianas, esto permitiría una inicialización basada en la estructura de la matriz de covarianza, en lugar de la inicialización basada en tipo de scattering de la clasificación H/α . De esta manera, podría utilizarse CEM para la identificación de objetivos con estructura conocida. En este sentido, en [8] se presenta la estructura de la matriz de covarianza en relación con la polarización de la onda reflejada, relacionando dicha matriz con un

tipo de objetivo.

La observación 5) resulta contra-intuitiva en vista de las Figs. 1(c) y 2(b). Aunque la clasificación CEM se presenta más ruidosa y dispersa, resulta mejor que la clasificación de Wishart en términos de \bar{R} . En [4], luego de aplicar CEM, se propone un post-procesamiento sobre la imagen segmentada para eliminar los pixeles mal clasificados que provocan el aspecto ruidoso del resultado.

VI. CONCLUSIONES

Se ha realizado la segmentación de imágenes SAR polarimétricas aplicando el método CEM con modelo de mezcla de Gaussianas. Se propuso el índice de Davies-Bouldin para comparar cuantitativamente las segmentaciones obtenidas con las de la clasificación Wishart, por ser este último un método ampliamente utilizado. La comparación mediante este índice mostró un desempeño similar para ambos métodos ante igual inicialización en datos sin promediar y un mejor desempeño de CEM para datos promediados. Por otro lado, CEM mostró un buen desempeño con inicialización aleatoria, sugiriéndolo como alternativa para una clasificación inicial.

Debe notarse que la definición de \bar{R} adoptada en este trabajo, sólo evalúa los resultados de las segmentaciones en base criterios de dispersión y distancia definidos a tal fin. Sin embargo, no tiene en cuenta otros factores igualmente importantes que inciden directamente en el desempeño global de un clasificador, como velocidad de convergencia, sensibilidad a los valores iniciales, entre otros. A este respecto y hasta donde los autores tienen conocimiento, el desarrollo de un índice que contemple el compromiso entre calidad de segmentación y resolución de la imagen no ha sido propuesto aún, por lo que constituye como un posible trabajo futuro.

AGRADECIMIENTOS

Este trabajo fue financiado a través de ANPCyT PICT 2011-11-0909, UNLP 11-I-166, CONICET PIP 2010-2012 y CICpBA.

REFERENCIAS

- [1] S. Cloude and E. Pottier, "An entropy based classification scheme for land applications of polarimetric SAR," *IEEE Trans. Geosci. Remote Sens.*, vol. 35, no. 1, pp. 68–78, Jan 1997.
- [2] J.-S. Lee, M. Grunes, T. Ainsworth, L.-J. Du, D. Schuler, and S.R.Cloude, "Unsupervised classification using polarimetric decomposition and the complex Wishart classifier," *IEEE Trans. Geosci. Remote Sens.*, vol. 37, no. 5, pp. 2249–2258, 1999.
- [3] K. Kayabol and J. Z. J., "Unsupervised amplitude and texture classification of SAR images with multinomial latent model," *IEEE Trans. Image Process.*, vol. 22, no. 2, pp. 561–572, Feb 2013.
- [4] L. Yuan, J. Song, W. Xue, and W. Zhao, "SAR image classification based on map via the EM algorithm," in *Intelligent Control and Automation, 2006. WCICA 2006. The Sixth World Congress on*, vol. 2, 2006, pp. 10116–10120.
- [5] D. L. Davies and D. W. Bouldin, "A cluster separation measure," *IEEE Trans. Pattern Anal. Mach. Intell.*, vol. PAMI-1, no. 2, pp. 224–227, April 1979.
- [6] G. J. McLachlan and T. Krishnan, *The EM Algorithm and Extensions*, 2nd ed., ser. Wiley Series in Probability and Statistics. John Wiley and Sons, 2008.
- [7] (2014) The PolSARPro website. [Online]. Available: <http://earth.eo.esa.int/polsarpro/>

- [8] B. Hochwald and A. Nehorai, "Polarimetric modeling and parameter estimation with applications to remote sensing," *IEEE Trans. Signal Process.*, vol. 43, no. 8, pp. 1923–1935, Aug 1995.



Juan I. Fernández Michelli received the Engineering degree in Electrical Engineering from the National University of La Plata in 2008. Currently, he is a Ph.D. student of the National Council of Scientific and Technical Research of Argentina (CONICET) and a teaching assistant in the Department of Electrical Engineering at National University of La Plata. His research interests are in the area of statistical signal processing and its applications in Synthetic Aperture Radar systems.



Martín Hurtado received the B.Eng. and M.Sc. degrees in electrical engineering from the National University of La Plata, Argentina, in 1996 and 2001, respectively. He received his Ph.D. degree in electrical engineering from Washington University in St. Louis in 2007. Currently, he is a research associate of the National Council of Scientific and Technical Research of Argentina and an adjunct professor in the Department of Electrical Engineering at National University of La Plata. His research interests are in the area of statistical signal processing, detection and estimation theory, and their applications in sensor arrays, communications, and remote sensing systems.



Javier A. Areta graduated as an Electronics Engineer from the National University of La Plata, Argentina, in 2001, and received the Ph.D. degree in Electrical Engineering from the University of Connecticut in 2008. He is an Associate Professor at the Department of the Electrical Engineering of the National University of Rio Negro in Bariloche, Argentina. His research interests are in the area of statistical signal processing, particularly in radar applications.



Carlos H. Muravchik (S'81-M'83-SM'99) was born in Argentina, June 11, 1951. He graduated as an Electronics Engineer from the National University of La Plata, Argentina, in 1973. He received the M.Sc. in Statistics (1983) and the M.Sc. (1980) and Ph.D. (1983) degrees in Electrical Engineering, from Stanford University, Stanford, CA. He is a Professor at the Department of the Electrical Engineering of the National University of La Plata and chairman of its Industrial Electronics, Control and Instrumentation Laboratory (LEICI). He is also a member of the Comisión de Investigaciones Científicas de la Pcia. de Buenos Aires. He was a Visiting Professor to Yale University in 1983 and 1994, to the University of Illinois at Chicago in 1996, 1997, 1999 and 2003 and to Washington University in St Louis in 2006 and 2010. Since 1999 he is a member of the Advisory Board of the journal *Latin American Applied Research* and was an Associate Editor of the *IEEE Transactions on Signal Processing* (2003–2006). His research interests are in the area of statistical and array signal processing with biomedical, communications and control applications, and in nonlinear control systems.