

Estimación de la humedad superficial del suelo mediante sensores remotos: Sistema aerotransportado UAVSAR

Matías Barber¹, Francisco Grings¹ y Haydeé Karszenbaum¹

¹ Grupo de Teledetección Cuantitativa, Instituto de Astronomía y Física del Espacio (IAFE), Int. Güiraldes s/n, Pabellón IAFE, Ciudad Universitaria, Ciudad Autónoma de Buenos Aires, Argentina

Mail de contacto: mbarber@iafe.uba.ar

RESUMEN

La humedad del suelo es una variable clave relacionada con el desarrollo y rendimiento de los cultivos. Condiciones de exceso o escasez en la humedad disponible tienen efectos igualmente devastadores para los cultivos. Por ende, la estimación de la humedad del suelo resulta particularmente relevante en zonas agrícolas. En respuesta a esta demanda de información, se ha hecho un esfuerzo sistemático para desarrollar mapas de humedad del suelo. Los radares de apertura sintética (SAR) ofrecen la oportunidad de estimar el contenido de humedad a diferentes escalas y bajo casi cualquier condición meteorológica. Los sistemas SAR hacen uso de la sensibilidad conocida que la señal retrodispersada posee a los parámetros superficiales del suelo, incluyendo la humedad y la rugosidad. Sin embargo, la relación entre la señal retrodispersada y los parámetros del suelo no es sencilla. En este trabajo se realizó un estudio experimental para evaluar el desempeño de un enfoque bayesiano para estimación de humedad superficial del suelo. Se analizaron los datos de un sistema aerotransportado SAR banda L conocido como UAVSAR provenientes de campos agrícolas en San Antonio de Areco y Bell Ville. La humedad del suelo así obtenida se compara con mediciones en tierra.

Palabras clave: humedad del suelo, sistemas SAR, enfoques bayesianos

ABSTRACT

Soil moisture is a key variable related to crop development and yield. Excess or deficit soil moisture can have each devastating effects. Consequently, the early assessment of soil moisture reserves, and monitoring moisture changes, is particularly important over agricultural areas. In response to this demand for information, a systematic effort has been made to develop maps of soil moisture over agricultural areas. Orbiting microwave synthetic aperture radar (SAR) systems offer the opportunity to monitor moisture content at different scales and under almost any weather condition. SAR systems leverage the known sensitivity that the backscattered signal exhibits to soil parameters, including soil moisture and soil roughness. However, the relationship between the backscattered signal and soil parameters is not straightforward. In this paper, an experimental study is carried out to assess the performance of a Bayesian approach for soil moisture retrieval. Data from an airborne L-band SAR system named UAVSAR are analyzed over agricultural fields in San Antonio de Areco and Bell Ville. Retrieved soil moisture is then compared to ground measurements.

Keywords: soil moisture, SAR systems, Bayesian approaches.

INTRODUCCIÓN

Se espera que las misiones satelitales en curso que involucran Radars de Apertura Sintética (o SAR de sus siglas en inglés) proporcionen información significativa y oportuna sobre el estado del suelo, siendo la cantidad de humedad retenida en él tal vez la más importante (Kerr 2007). Las misiones SAOCOM de CONAE (www.conae.gov.ar/eng/satelites/saocom.html) y SMAP de la NASA (Entekhabi et al. 2010a), planificadas para ser lanzadas en 2015 y finales del 2014 respectivamente, han sido diseñadas específicamente para desarrollar un producto de humedad superficial del suelo. Estas misiones harán uso de la banda L para sensar el suelo, la cual ha demostrado ser más precisa en la obtención de humedad del suelo que otras bandas y al mismo tiempo menos sensible a la cobertura de rastrojo habitual en labranzas conservacionistas o de siembra directa. Sobre la base de un producto operativo, la comunidad internacional de Teledetección ha dedicado un gran esfuerzo en desarrollar algoritmos de inversión para obtención de humedad del suelo.

A este respecto, en este trabajo se presenta una metodología bayesiana para obtención de humedad superficial del suelo. El enfoque bayesiano apunta a incorporar las incertezas en los parámetros del suelo así como el ruido *speckle*, los cuales son conocidos por dificultar la inversión de los modelos directos que describen la interacción entre la radiación electromagnética y las características geométricas y dieléctricas del suelo. Al tratar con las incertezas en los parámetros del suelo, el enfoque bayesiano utiliza una distribución *a priori* que permite incluir la información sobre los parámetros del suelo con sus incertezas asociadas. Por otro lado, el ruido *speckle* residual, luego del proceso habitual para disminuir su incidencia (*multilooking process*), se incluye por medio de una distribución de Wishart (Lee et al. 1994).

El enfoque bayesiano se evalúa mediante un estudio experimental llevado a cabo con el sistema aerotransportado UAVSAR sobre dos campos agrícolas situados en San Antonio de Areco (Bs. As.) y en Bell Ville (Cba.). El estimador bayesiano se compara con el correspondiente estimador de inversión por tablas (*look-up table*). El error en las estimaciones a campo se analiza en detalle, ya que en la etapa de validación se toman en cuenta tanto los errores instrumentales como la variabilidad intrínseca de la humedad del suelo, ambos provenientes de la recolección de muestras en tierra.

MATERIALES Y MÉTODOS

1.1 La formulación bayesiana en el contexto de productos SAR

El enfoque bayesiano presentado en este trabajo se basa en la versión bivariada del Teorema de Bayes. Sean Z_1 y Z_2 dos variables aleatorias cada una función de la constante dieléctrica ε y de la altura RMS s , entre otras (por ejemplo, longitud de correlación, ángulo de incidencia, longitud de onda, etc.). Eventualmente, cada Z_1 y Z_2 representará una imagen en intensidad para las polarizaciones HH y VV adquiridas sobre un mismo blanco en una misma pasada del sensor.

Una expresión para la probabilidad condicional (o probabilidad posterior en la jerga de Bayes) de medir un cierto conjunto de parámetros del suelo (ε y s) dadas mediciones de coeficiente de retrodispersión z_1 y z_2 se puede obtener usando el Teorema de Bayes

$$P(\varepsilon, s; z_1, z_2) = \frac{P_{Z_1 Z_2}(z_1, z_2; \varepsilon, s) P_{ES}(\varepsilon, s)}{P_{Z_1 Z_2}(z_1, z_2)} \quad (1)$$

donde $P_{Z_1 Z_2}(z_1, z_2; \varepsilon, s)$ es la probabilidad de medir un cierto conjunto (z_1, z_2) de coeficientes de retrodispersión dadas mediciones de constante dieléctrica ε y altura RMS s (la función de verosimilitud o *likelihood function*), P_{ES} es la distribución conjunta a priori (o prior) de ε y s (que involucra toda la información conocida de antemano acerca de ε y s) y $P(z_1, z_2)$ (la evidencia) es un factor de normalización global y es la probabilidad de medir un cierto conjunto (z_1, z_2) .

La función de verosimilitud es una versión estocástica del modelo directo y determina el grado de compatibilidad entre cierta medición SAR y ciertos parámetros del suelo restringido a algún modelo directo dado. Mientras mayor la verosimilitud, más probable es que la medición SAR provenga de aquella combinación específica de parámetros del suelo. La función de verosimilitud toma en cuenta el modelo directo así como también el ruido *speckle* y en consecuencia su dispersión se debe a la incerteza con que se conocen los parámetros del suelo ϵ y s y a la incerteza proveniente del ruido *speckle* residual (Barber et al. 2012). El prior contiene toda la información disponible sobre los parámetros del suelo ϵ y s . Dicha información puede provenir de registros históricos, estimaciones de otros sensores, datos en tierra y/o información contextual. En lo que sigue se supondrá independencia entre la constante dieléctrica y la altura RMS,

$$P_{ES}(\epsilon, s) = P_E(\epsilon) P_S(s) \quad (2)$$

Con la función de verosimilitud y la distribución prior, el posterior se calcula como el producto punto a punto entre ellos. De esta manera, siempre que la distribución condicional (1) sea exacta, el estimador óptimo insesgado para el valor medio de ϵ que posee la mínima varianza es (MacKay 2003)

$$\epsilon^{bay} = \iint_D \epsilon P(\epsilon, s; z_1, z_2) d\epsilon ds \quad (3)$$

y de manera similar el cuadrado del desvío estandar $std[\cdot]$ del estimador es

$$std[\epsilon^{bay}]^2 = \iint_D (\epsilon - \epsilon^{bay})^2 P(\epsilon, s; z_1, z_2) d\epsilon ds \quad (4)$$

donde una expresión explícita para (1) debe encontrarse para calcular ϵ^{bay} y su desvío estandar. El dominio de integración D en (3) y (4) abarca el rango de validez del modelo directo respecto de (ϵ, s) . El desvío estándar $std[\epsilon^{bay}]$ puede usarse como una medida del error ϵ_{est} de la estimación ϵ^{bay} ,

$$\epsilon_{est} = std[\epsilon^{bay}] \quad (5)$$

1.2 Inversión por tablas (LUT)

El procedimiento de inversión por tablas se basa en la minimización de la distancia euclidiana d , también conocida como función de costo, para algún conjunto de parámetros,

$$d = \sqrt{(HH_{med} - HH_{tab}(\epsilon, s))^2 + (VV_{med} - VV_{tab}(\epsilon, s))^2} \quad (6)$$

donde los subíndices *med* y *tab* se refieren a los valores medidos y tabulados, respectivamente, de los coeficientes de retrodispersión HH y VV. En la expresión (6) se suponen conocidos la longitud de correlación al igual que los parámetros del radar. Luego, de acuerdo a este procedimiento, los estimadores ϵ^{lut} y s^{lut} serán aquellos relacionados a los coeficientes de retrodispersión más cercanos (en el sentido de la distancia d) a los valores medidos. Matemáticamente,

$$(\epsilon^{lut}, s^{lut}) = \min_{\epsilon, s} d \quad (7)$$

Para llevar a cabo este procedimiento, se define una grilla de discretización para ϵ y s : ϵ barre de 3 a 30 con un paso 0.1 y s barre de 0.5 cm a 4 cm con una paso de 0.25 cm.

1.3 Constante dieléctrica y humedad volumétrica

Los estimadores definidos en las expresiones (3) y (7) son estimadores para la parte real de la constante dieléctrica. Sin embargo, la validación de las estimaciones SAR con frecuencia se llevan a cabo comparando estimaciones a campo de humedad volumétrica. La conversión del constante dieléctrica a humedad volumétrica se realiza por medio de una relación empírica (Hallikainen et al. 1984), a saber,

$$\varepsilon = a(f, S, C) + b(f, S, C)m_v + c(f, S, C)m_v^2 \quad (8)$$

donde los coeficientes a , b y c dependen de la frecuencia f , S y C son las fracciones de arena y arcilla presentes en el suelo. Los coeficientes para 1.4 GHz (banda L), entre otras frecuencias, se muestran en la Tabla II de Hallikainen et al. (1984). Como la expresión (8) es un polinomio de segundo orden, su inversión para obtener m_v es directa,

$$m_v = \frac{-b(f, S, C) + \sqrt{b(f, S, C)^2 - 4c(f, S, C)[a(f, S, C) - \varepsilon]}}{2c(f, S, C)} \quad (9)$$

Adicionalmente, el error en la estimación de m_v se puede calcular a partir del error en ε como sigue

$$\text{std}[m_v^{\text{bay}}] = \left| \frac{dm_v}{d\varepsilon} \right|_{\varepsilon^{\text{bay}}} \text{std}[\varepsilon^{\text{bay}}] \quad (10)$$

donde $\text{std}[m_v^{\text{bay}}]$ es el error calculado como el desvío estándar del estimador de humedad del suelo y la derivada total se evalúa en ε^{bay} .

1.4 Ruido speckle

Los estimadores derivados de los procedimientos estocástico (bayesiano) y determinista (LUT) descritos en las Secciones 1.1 y 1.2, respectivamente, se ven afectados por el ruido *speckle*. Ambos procedimientos se basan en un etapa de preprocesamiento para disminuir el ruido *speckle*, con el fin de lograr estimadores confiables. Sin embargo, el enfoque bayesiano incluye un modelo para el ruido *speckle* y en consecuencia puede tratar con el ruido residual luego de la etapa de preprocesamiento, mientras que el estimador LUT no tiene esta posibilidad.

La etapa de preprocesamiento consiste en promediar píxeles vecinos (proceso multivistas) sobre un blanco homogéneo (por ejemplo, un campo) para una imagen en intensidad. Para mejorar el desempeño del proceso multivistas, los píxeles primero se decorrelacionan por métodos tradicionales. Las propiedades estadísticas de la imagen resultante se describen por medio de una distribución de Wishart de 2×2 (Lee et al. 1994), a saber

$$P_Z^{(n)}(Z) = \frac{n^{2n} |Z|^{n-2} \exp[-n \text{Tr}(C^{-1}Z)]}{K(n) |C|^n} \quad (11)$$

donde

$$Z = \frac{1}{4\pi} \begin{bmatrix} HH_{med} & \sqrt{HH_{med}VV_{med}} r e^{i\alpha} \\ \sqrt{HH_{med}VV_{med}} r e^{-i\alpha} & VV_{med} \end{bmatrix} \quad (12)$$

La matriz C es el valor de expectación de Z , es decir, $C = E[Z]$, y esta dada por medio del modelo directo que predice el valor de C en términos de la constante dieléctrica, la rugosidad, el ángulo de incidencia y la longitud de onda. En la expresión (11), n es el número de píxeles decorrelacionados usados para calcular HH_{med} y VV_{med} , C^{-1} es la inversa de la matrix C , $\text{Tr}(C^{-1}Z)$ indica la traza la matrix $C^{-1}Z$ y $K(n) = \pi I(n) \dots I(n-3)$. En la expresión (12), HH_{med} y VV_{med} , son los coeficientes de retrosipersion medidos luego del procesamiento multivistas y r es el coeficiente de correlación entre ellos, estimado a partir de los datos multivistas. Debido a que el esquema de inversión tratado en este trabajo usa la imagen en intensidad (es decir, no la imagen compleja), la fase α en la expresión (12) se supone igual a cero.

Como se mencionó, el modelo directo mapea la constante dieléctrica ε y la rugosidad s y l , en la matrix $C = C(\varepsilon, s, l; \theta, \lambda)$. El valor medido de $Z = (HH_{med}, VV_{med})$ difiere de C por diversos motivos, como pueden ser errores instrumentales, el ruido *speckle* residual y la influencia de parametros del suelo adicionales que afectan la respuesta de radar del blanco y que no se toman en cuenta

en el modelo directo. También posibles inhomogeneidades dentro de la celda de resolución del radar pueden representar una fuente de discrepancia ya que la relación $C(\varepsilon, s, l; \theta, \lambda)$ es no lineal.

1.5 Construcción de la función de verosimilitud

La función de verosimilitud se construye siguiendo el esquema mostrado en la Fig.1. En primer lugar, se genera una grilla para ε y s dentro del dominio de validez del modelo directo. El resto de los parámetros (l, θ, λ) se suponen fijos. En segundo lugar, cada (ε, s) se convierte en coeficiente de retrodispersión a través del modelo directo, resultando en una grilla de pares (X_{HH}, X_{VV}) la cual representa las propiedades deterministas de retrodispersión del blanco. La varianza debida al ruido *speckle* residual (Y_{HH}, Y_{VV}) se modela por medio de una distribución de Wishart, como se describe en la Sección 1.4. Por último, se genera cierta cantidad de realizaciones (Y_{HH}, Y_{VV}) con valores medios $E[Y_{HH}] = 1$, $E[Y_{VV}] = 1$ y luego se multiplican escalarmente con cada par (X_{HH}, X_{VV}) para así obtener (Z_{HH}, Z_{VV}) . De esta manera, cada par (ε, s) se asocia a una distribución bivariada bidimensional $P_{Z_{HH}Z_{VV}}(hh, vv; \varepsilon, s)$. Esto es la verosimilitud.

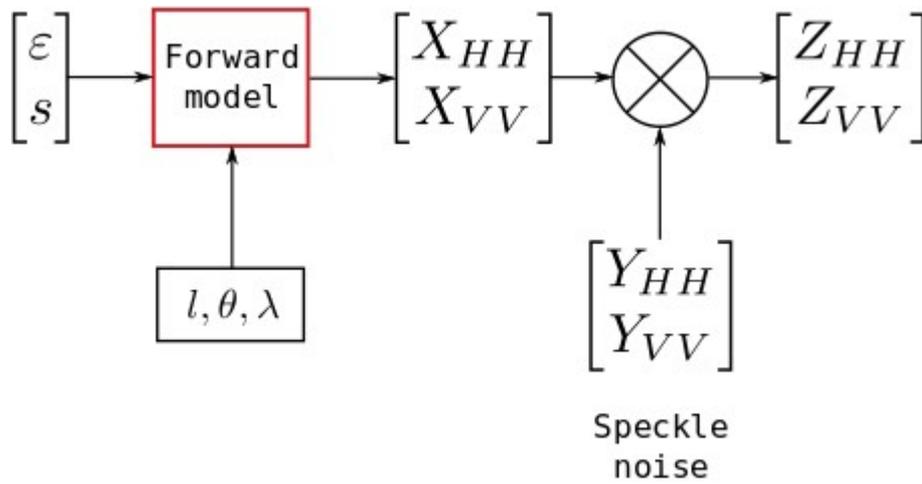


Figura 1 – Esquema para generar numéricamente la función de verosimilitud o *likelihood function*.

1.6 Modelo directo

El modelo directo empleado en este trabajo es el modelo de la ecuación integral avanzado (o AIEM de sus siglas en inglés) (Chen et al. 2003), el cual es una versión mejorada del reconocido IEM, desarrollado para describir la dispersión de ondas por parte de una superficie rugosa. En la formulación del AIEM, el coeficiente de retrodispersión se escribe como la suma de dos términos, a saber

$$\sigma_{qp}^0 = \sigma_{qp}^0(S) + \sigma_{qp}^0(M) \quad (10)$$

donde $\sigma_{qp}^0(S)$ es un término de dispersión simple, $\sigma_{qp}^0(M)$ es un término de dispersión múltiple y los subíndices q, p denotan las polarizaciones recibidas y transmitidas, respectivamente. Matemáticamente, el término de dispersión simple $\sigma_{qp}^0(S)$ se corresponde con términos numéricamente fáciles de evaluar, mientras que $\sigma_{qp}^0(M)$ involucra términos que poseen integrales de dimensión 4 o 6, extremadamente difíciles de evaluar. Para evitar el cálculo del término de dispersión múltiple, dando lugar a la aproximación $\sigma_{qp}^0 \approx \sigma_{qp}^0(S)$, deben cumplirse las siguientes condiciones (Fung et al. 2010)

$$ks < 2 \quad (11a)$$

$$s/l < 0.3 \quad (11b)$$

con $k=2\pi/\lambda$, s la altura RMS y l la longitud de correlación. En banda L, la condición (11a) es

fácilmente alcanzable sobre suelos agrícolas. Sin embargo, la condición (11b) debe evaluarse en cada caso particular.

1.7 Evaluación de las incertezas en las estimaciones a campo

Mientras que la técnicas de teledetección SAR proveen una metodología efectiva para mapear la humedad del suelo en área extensas, también promedia la variabilidad intra-pixel enmascarando de esta manera la heterogeneidad subyacente observada sobre el terreno. Esta variabilidad debe comprenderse bien para evaluar rigurosamente el desempeño del sensor y para mejorar la utilidad de las estimaciones satelitales (Famiglietti et al. 2008)

A partir de un estudio experimental realizado por Famiglietti et al. (2008), puede estimarse el desvío estándar esperable que posee la humedad del suelo medida en el terreno sobre un campo agrícola de lado L (Barber 2014)

$$\sigma_{terr}^S = (L / X_0)^D \quad (12)$$

donde el supraíndice S indica la escala donde se calcula el desvío estándar s, X0 es una constante ($X_0 = 2.879 \cdot 10^{17} \text{m}$) y D es un exponente fractal ($D = 0.086$). El desvío estándar soportado por la expresión (12) posee un rango dinámico de $0.040 \text{cm}^3/\text{cm}^3$ para la escala espacial $S = 256 \text{m}^2$ a $0.060 \text{cm}^3/\text{cm}^3$ para la escala espacial $S = 2.56 \text{km}^2$.

La variabilidad expresada en (12) es intrínseca al campo agrícola y no puede ser medida por una imagen multivistas SAR. Sin embargo, dicha variabilidad se torna relevante al definir un esquema de validación para las estimaciones SAR basado en mediciones a campo.

A la incerteza definida en la expresión (12) debe agregarse la incerteza instrumental ϵ_{inst} producto del proceso de medición a campo. Por ejemplo, el método gravimétrico extensamente usado posee un error típicamente de $\epsilon_{inst} = 0.040 \text{cm}^3/\text{cm}^3$ (Gardner 1986, Capítulo 21). Finalmente, el error total ϵ_{terr} en la estimación a campo de la humedad es

$$\epsilon_{terr} = \sqrt{\epsilon_{inst}^2 + \sigma_{terr}^2} \quad (13)$$

donde ϵ_{inst} es el error instrumental y σ_{terr} es el error en relación a la variabilidad espacial.

1.8 Métricas de desempeño

Una variedad de métricas de desempeño se utilizan para la validación de estimaciones SAR. Ninguna métrica por si misma puede capturar todos los atributos de un variable geobiofísica. Cada métrica es robusta con respecto a algunos atributos y relativamente insensible con respecto a otros (Entekhabi et al. 2010b). Como consecuencia, a continuación se describen algunas métricas que serán usadas para evaluar el desempeño de las estimaciones SAR con respecto a las estimaciones a campo. Cada métrica es complementaria entre sí y son válidas tanto para el enfoque determinista (LUT) como para el enfoque estocástico (bayesiano).

Sea m_v^0 la humedad superficial volumétrica verdadera (a una escala dada) del suelo y sea m_v^{est} la correspondiente estimación SAR. Luego, el error cuadrático medio RMSE es simplemente

$$RMSE = \sqrt{E[(m_v^{est} - m_v^0)^2]} \quad (14)$$

donde $E[.]$ indica valor de expectación. Esta métrica penaliza cuadráticamente los desvíos de la estimación con respecto al valor verdadero de humedad (en cm^3/cm^3) y es una medida de la exactitud de la estimación compacta y fácil de entender. Esta métrica, sin embargo, conlleva problemas en caso de sesgos presentes en la media o en la varianza de m_v^{est} . En consecuencia, una segunda métrica de desempeño es el sesgo medio b

$$b = E[m_v^{est}] - E[m_v^0] \quad (15)$$

Otra métrica de error, robusta con respecto a los sesgos, es el coeficiente de correlación r , expresado como

$$r = \frac{E[(m_v^{est} - E[m_v^{est}])(m_v^0 - E[m_v^0])]}{\sigma_{est} \sigma_0} , \quad (16)$$

donde σ_{est} y σ_0 son las varianzas de la estimación SAR y a campo de la humedad del suelo, respectivamente, para la escala espacial considerada. Esta métrica captura la correspondencia en fase entre las estimaciones SAR y las estimaciones a campo, pues $-1 \leq r \leq 1$. En este sentido, provee una perspectiva sobre el desempeño de la inversión diferente al error cuadrático medio RMSE.

Por último, el error absoluto máximo o MAE se usará como una métrica de error en el sentido estricto, en contraste al RMSE y r que pueden considerarse como métricas de error globales. Matemáticamente,

$$MAE = \max_{0 \leq i \leq K} |m_v^{est} - m_v^0| , \quad (17)$$

donde K es el número de estimaciones SAR con sus correspondientes estimaciones a campo.

1.9 UAVSAR

La campaña descrita a continuación es producto de una colaboración entre USDA (U.S. Department of Agriculture), CONAE y el IAFE y se realizó en Abril del 2013. El sistema aerotransportado UAVSAR pertenece a la NASA y posee un SAR que opera a una frecuencia de 1.26 GHz ($\lambda=23,84$ cm). Las imágenes son de polarización completa y poseen una exactitud de 1 dB.

1.10 Descripción de los sitios

En la zona de San Antonio de Areco, Pcia. de Buenos Aires, el experimento de campo se llevó a cabo en la única parcela agrícola que presentaba suelo desnudo, de aproximadamente 11 ha. La clase textural de la misma se estima en franco arcillo-limosa. En simultáneo con el vuelo, hubo trabajo de campo y se recolectaron mediciones de humedad gravimétrica. El ángulo de incidencia para esta parcela resultó ser $\theta=30^\circ$.

Por otro lado, en la zona de Bell ville, Pcia. de Córdoba, se contó con dos parcelas agrícolas de suelo desnudo de 86 ha y de 24 ha. La clase textural de las mismas se estima en franco-limosa. Se tomaron dos adquisiciones SAR. En simultáneo con las pasadas, se recolectaron mediciones de humedad gravimétrica. El ángulo de incidencia para cada parcela resultó ser de 43° y 51° para la primer pasada y de 30° y 41° para la segunda pasada, respectivamente.

RESULTADOS Y DISCUSIÓN

Las estimaciones de humedad volumétrica para los cinco puntos descriptos en la Sección 1.9 se muestran a continuación. En la Fig.3 se muestran los resultados del método de inversión por tablas. En la Fig.4 se muestran los resultados del método de inversión bayesiano. Las barras de error en las mediciones a campo se fijaron en $0.040 \text{ cm}^3/\text{cm}^3$, lo que corresponde a la incerteza típica asociada al método gravimétrico para estimar humedad del suelo (Gardner, 1986). Las barras de error en las estimaciones del enfoque bayesiano se corresponden con lo indicado en la expresión (5). Las métricas de desempeño descriptas en la Sección 1.8 se usan para evaluar los distintos métodos.

El enfoque de inversión por tablas (Fig.3) muestra una pobre concordancia con respecto a las mediciones a campo, con un error RMSE = $0.140 \text{ cm}^3/\text{cm}^3$. Dichas estimaciones tampoco presentan sensibilidad con respecto a las mediciones a campo. Por otro lado, las estimaciones bayesianas (Fig.4) presentan una buena concordancia global, con un error RMSE = $0.093 \text{ cm}^3/\text{cm}^3$ y un bajo sesgo. La incidencia del ruido *speckle* residual en el estimador LUT es mayor que en el estimador bayesiano, ya que el mismo no está contemplado en la expresión (6) y en cambio sí está modelado en la expresión (1) via el procedimiento descrito en la Sección 1.5.

Otra fuente de error puede ser la cobertura de rastrojo de los campos, el cual modifica la señal retrodispersada y no se toma en cuenta en el modelo directo AIEM. El enfoque bayesiano puede disminuir el impacto de esta fuente de error a través del prior, el cual fuerza a que la distribución posterior esté centrada en un valor de altura RMS esperable ($s=1.00$ cm para suelos de siembra directa). Los resultados obtenidos en términos del desempeño propio del método bayesiano, y en comparación con el método de inversión por tablas, es consistente con el hallado analizando otros conjuntos de datos bajo otras condiciones (suelos secos, sensores orbitales, banda C, etc.) como se desprende de (Barber 2014).

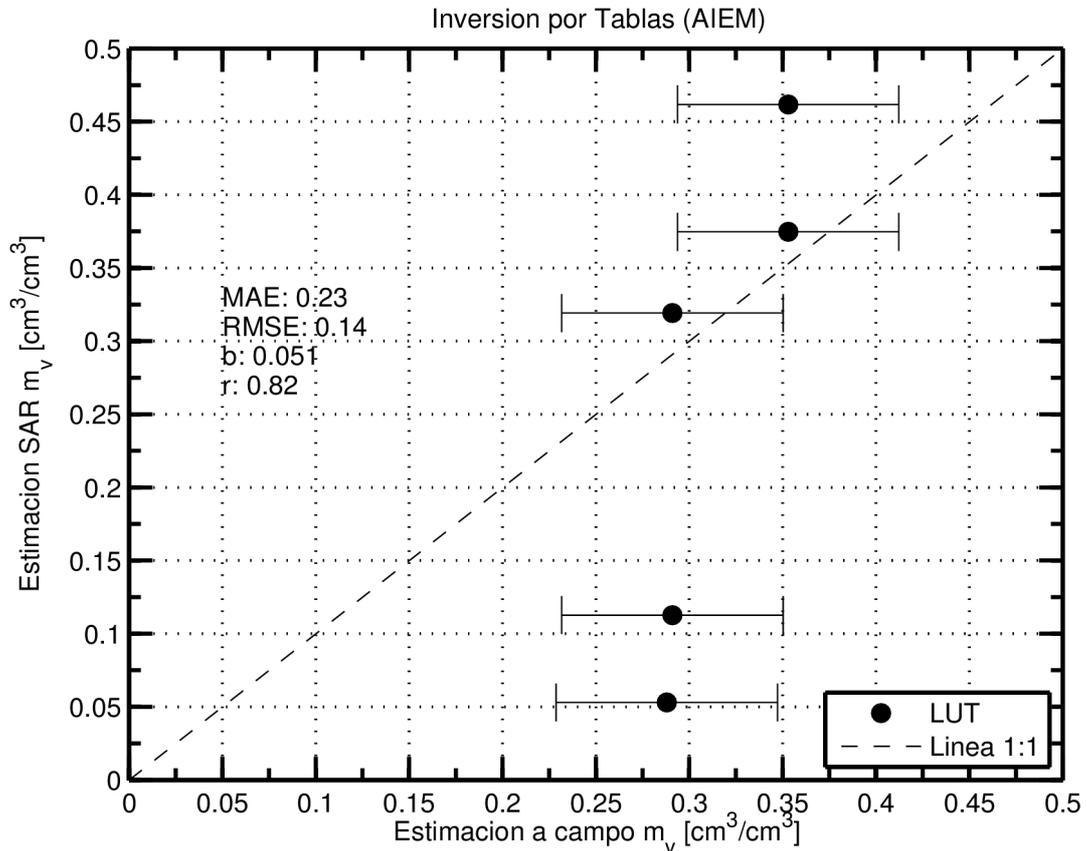


Figura 3 - Comparación de las estimaciones de inversión por tablas de humedad volumétrica del suelo contra las estimaciones a campo. Las métricas de error MAE y RMSE se miden en cm^3/cm^3 .

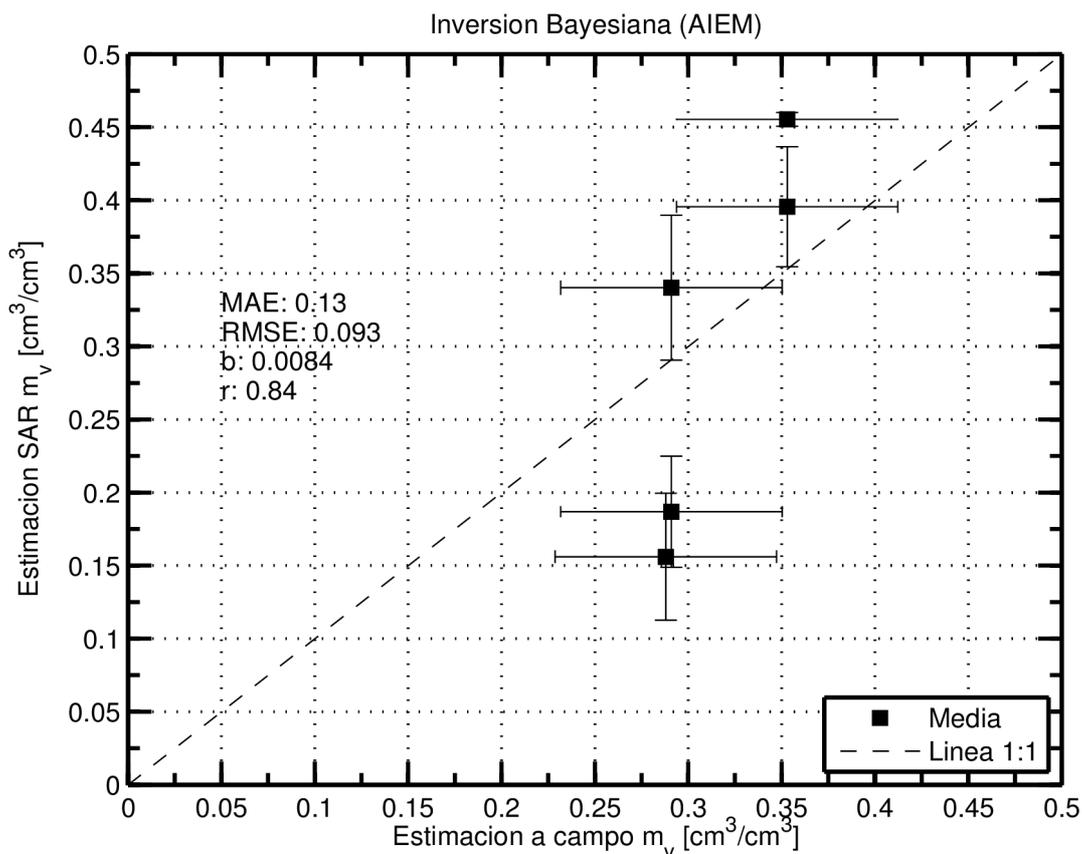


Figura 4 - Comparación de las estimaciones bayesianas de humedad volumétrica del suelo contra las estimaciones a campo. Las métricas de error MAE y RMSE se miden en cm^3/cm^3 .

CONCLUSIONES

La búsqueda de un algoritmo operativo para obtener humedad del suelo está motivada por las misiones planificadas SAR en banda L. La contribución que hace este trabajo es presentar una metodología de inversión basada en el teorema de Bayes. La misma posee las siguientes ventajas, (1) no depende de ningún modelo directo en particular, (2) permite incluir diversas fuentes de error, (3) permite asimilar información sobre las variables involucradas de manera sistemática a través del prior y (4) cuantifica de manera sistemática el error en la estimación SAR. Con respecto a la afirmación (2), en este trabajo se modeló únicamente el error proveniente del ruido *speckle* residual. Otras fuentes de error pueden ser errores provenientes de la ingeniería del sensor SAR (desbalances, acoples, otros) o provenientes del modelo directo usado, el cual se supone perfecto.

Asociado a estas problemáticas, se presenta también una metodología para validación que toma en cuenta los errores asociados a las estimaciones a campo de la humedad del suelo y un conjunto de métricas de desempeño adecuadas. Las discrepancias en las estimaciones SAR y las estimaciones a campo pueden deberse a (1) una descripción incompleta del blanco por parte del modelo directo empleado, (2) errores instrumentales en la determinación de los parámetros del blanco o (3) ruido *speckle* residual.

Agradecimientos

Los autores desean agradecer a CONAE por incluir al Grupo de Teledetección Cuantitativa en la campaña realizada con el UAVSAR y al Dr. Thomas Jackson por gestionar el vuelo del mismo

sobre el sitio de San Antonio de Areco. Nuestro especial agradecimiento también al Dr. Marco Brogioni (IFAC) por facilitarnos desinteresadamente una versión del AIEM en FORTRAN y brindar su ayuda en el uso y comprensión de la misma. La campaña se realizó con fondos del proyecto AO SAOCOM N°17.

REFERENCIAS

- Barber, M., Maas, M., Perna, P., Grings, F., Karszenbaum, H., 2012. A Bayesian approach to retrieve soil parameters from SAR data: effect of prior information. *Proc. SPIE* 8536, SAR Image Analysis, Modeling, and Techniques XII.
- Barber, M., 2014. *Parametrización y optimización de modelos de inversión para la obtención de humedad del suelo a partir de datos satelitales de Radars de Apertura Sintética (SAR)*, Tesis de Doctorado, Universidad de Buenos Aires.
- Chen, K., Wu, T.-D., Tsang, L., Li, Q., Shi, J., Fung, A., 2003. Emission of rough surfaces calculated by the integral equation method with comparison to three-dimensional moment method simulations, *IEEE Transactions on Geoscience and Remote Sensing*, 41:90–101.
- Entekhabi, D., Njoku, E., O'Neill, P., Kellogg, K., Crow, W., Edelstein, W., Entin, J., Goodman, S., Jackson, J., Johnson, J., Kimball, J., Piepmeier, J., Koster, R., Martin, N., McDonald, K., Moghaddam, M., Moran, S., Reichle, R., Shi, J.-C., Spencer, M., Thurman, S., Tsang, L., Van Zyl, J., 2010a. The soil moisture active passive (SMAP) mission. *Proceedings of the IEEE*, 98:704–716.
- Entekhabi, D., Reichle, R., Koster, R., Crow, W., 2010b. Performance Metrics for Soil Moisture Retrievals and Application Requirements. *Journal of Hydrometeorology* 11:832-840.
- Famiglietti, J. S., Ryu, D., Berg, A. A., Rodell, M., Jackson, T. J., 2008. Field observations of soil moisture variability across scales, *Water Resour. Res.* 44: W01423 .
- Fung, A. K., Chen, K. S., 2010. *Microwave Scattering and Emission Models for Users*, Artech House, 2010.
- Gardner, W. H., 1986. Methods of soil analysis, Part I. Physical and Mineralogical Methods, *American Society of Agronomy-Soil Science Society of America*.
- Hallikainen, M., Ulaby F., Dobson, M., El-Rayes, M., Wu, L.-K., 1985. Microwave Dielectric Behavior of Wet Soil-Part I: Empirical Models and Experimental Observations, *IEEE Transactions on Geoscience and Remote Sensing*, 23:25–34.
- Kerr, Y., 2007. Soil moisture from space: Where are we? *Hydrogeology Journal*, 15:117–120.
- Lee, J. S., Hoppel, K. W., Mango, S. A., Miller, A. R., 1994. Intensity and Phase Statistics of Multilook Polarimetric and Interferometric SAR Imagery, *IEEE Transactions on Geoscience and Remote Sensing* 32:1017–1028.
- MacKay, D. J. C., 2003. Information Theory, Inference, and Learning Algorithms, *Cambridge University Press*.