

Aplicación de Red Neuronal Artificial sobre imágenes TerraSAR para determinar la humedad del suelo

Silvio Graciani¹
Marco Brogioni²
Leticia Rodríguez¹

¹ Universidad Nacional del Litoral (UNL),
Ciudad Universitaria. Ruta Nacional N° 168 - Km 472,4. (CP3000) - Santa Fe, Argentina
sgraciani@fich.unl.edu.ar

² Consiglio Nazionale delle Ricerche - Istituto di Fisica Applicata,
Via Madonna del Piano, 10, 50019 Sesto Fiorentino (FI), Italia
m.brogioni@ifac.cnr.it

Abstract. Soil moisture (SM) is a key variable that directly influences the redistribution of radiant energy, evapotranspiration, infiltration, etc. Knowing its spatial distribution is strategic for agricultural activities. The In situ measurements of SM are time consuming, providing only point information. Synthetic aperture radar – SAR images bring the possibility of estimating SM over extensive areas (about 40x40 km²), with adequate spatial and temporal coverage. Work was developed in a sector of the Castellanos Department - Province of Santa Fe, in the same HS maps were obtained from the application of an Artificial Neural Network (ANN) on a data set of satellite measurements and field. Seven X-band SAR images from the satellite TerraSAR were calibrated and processed. Soil moisture was measured in situ by means of a TDR probe, samples were taken from the field for gravimetric water content determination. Days for field campaigns were performed as close as possible to the image days. These measured data of SM were used to validate those obtained with ANN, showing consistency when compared.

Palavras-chave: SAR, soil moisture, in-situ measurements, Artificial Neural Network.

1. Introducción

La estimación de las variaciones espaciales y temporales de la humedad del suelo resulta crítica para la agricultura siendo necesario conocer la llamada “humedad de siembra”. En este sentido, es muy interesante la posibilidad brindada por sensores instalados en satélites, con una cobertura completa y periódica de la superficie terrestre, para estimar la humedad del suelo (HS) en una gran área (aprox. 1600 km²). Durante las tres últimas décadas, la teledetección ha brindado una perspectiva creciente para las mediciones espaciales e instantáneas de esta variable (Wang y Qu, 2009). Por ejemplo, el sensor de microondas activo SAR, es hoy ampliamente utilizado para mapear la humedad de suelo en grandes superficies, sea en banda L y S, aunque también se usan C y X exitosamente (Jackson et al., 1996; Piles et al., 2009; Das et al., 2011).

Debido a la menor sensibilidad de la banda L a la rugosidad de la superficie muchos trabajos están basados en modelos simples, empíricos o semi-empíricos, fáciles de ser invertidos al momento de recuperar parámetros del suelo. Sin embargo, buena parte de las investigaciones fueron realizadas utilizando banda C debido a la disponibilidad de imágenes en dicha banda. Diversas investigaciones han demostrado que los sensores operando bandas P y L, son capaces de medir HS a una profundidad que depende de las características del suelo y de su perfil de humedad.

En un reciente trabajo, Paloscia et al. (2009) compararon tres metodologías diferentes para derivar la humedad del suelo a partir de imágenes ENVISAT/ASAR. Los algoritmos considerados fueron una Red Neuronal Artificial (RNA) “feedforward” con dos capas ocultas (cada una de 10 perceptrón), un método estadístico basado en el teorema de Bayes y un algoritmo iterativo basado en el método directo de búsqueda de Nelder-Mead.

Por otro lado, las mediciones in situ de la HS se llevan a cabo a nivel puntal o de lote, lo que dificulta la obtención de su variabilidad espacial en grandes extensiones, además de ser costosas y consumir un tiempo importante de campo. No obstante, siguen siendo fundamentales para validar las determinaciones resultantes de los modelos aplicados tanto a imágenes SAR como a cualquier otro tipo de modelo hidrológico.

En este trabajo se presentan resultados del procesamiento conjunto de imágenes SAR TerraSAR y mediciones concomitantes de humedad de suelo en un sector de la Provincia de Santa Fe, Argentina, investigación realizada en el marco del proyecto CAI+D 2011 denominado “Desarrollo de algoritmos para determinar el contenido de humedad del suelo desde imágenes SAR” (Cód. 50120110100465LI), financiado por la Universidad Nacional del Litoral - UNL de Argentina.

1.1 Área de Estudio

El área de interés se ubica en el Departamento Castellanos en la Provincia de Santa Fe, con centro en la localidad de Ataliva (Figura 1). La misma integra la región agrícola-ganadera e industrial de la Provincia, concentrando gran parte de la actividad del sector. Desde el punto de vista climático, la zona de estudio se caracteriza por un clima templado pampeano; la isoterma media anual es de 18°C y la precipitación media anual es de 950 mm. La distribución de las precipitaciones se concentra en el semestre noviembre-abril con un 75% del total anual. Los suelos de la zona pertenecen a asociaciones de Argiudoles. Se trata de una zona de llanura, de suave pendiente, en la que en épocas normales, los flujos verticales de agua predominan sobre los horizontales.

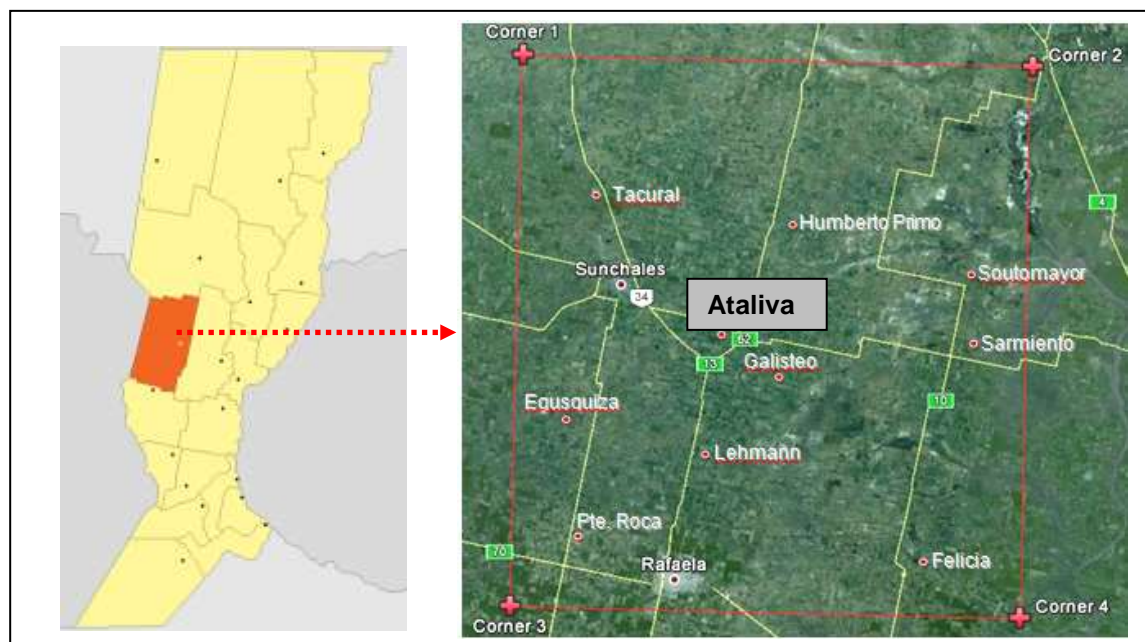


Figura 1. Ubicación del área de estudio, centrada en la localidad de Ataliva (31° 00' S; 61° 26' W), Departamento Castellanos - Provincia de Santa Fe.

2. Metodología de Trabajo

2.1 Materiales

Se realizaron nueve (9) salidas a campo, seis durante el año 2012 los días 03/09, 14/09, 25/09, 19/10, 30/11 y 11/12 y tres más en el 2013 los días 22/04, 14/05 y 30/07, concomitantes, en la mayoría de los casos, con el día de adquisición de la imagen. Se relevó la humedad del suelo mediante sonda TDR en un número promedio de 12 lotes por fecha considerada, se extrajeron muestras de suelo a una profundidad de 3 a 5 cm para análisis

gravimétrico en laboratorio y para determinación de densidad aparente. Cada sitio fue georreferenciado, se relevó el tipo de cobertura vegetal, la orientación de los surcos, la condición climática, la hora de toma de muestra y la rugosidad superficial. La Figura 2 muestra diferentes coberturas de los suelos relevados en campo y la Tabla 1 los días de adquisición de las imágenes.



Figura 2. Diferentes coberturas de rastrojo en los campos de muestreo.

Tabla 1. Día de adquisición y características de las imágenes TerraSAR.

	Fecha	Modo	Ángulo Incidencia	Polarización	Pasada
1	03/09/2012	SSC	23.94°	HH	Ascendente
2	14/09/2012	SSC	23.94°	HH	Ascendente
3	25/09/2012	SSC	23.94°	HH	Ascendente
4	06/10/2012	SSC	23.94°	HH	Ascendente
5	17/10/2012	SSC	23.94°	HH	Ascendente
6	30/11/2012	SSC	23.94°	HH	Ascendente
7	11/12/2012	SSC	23.94°	HH	Ascendente

2.2 Método

A continuación, se explica en detalle el procedimiento seguido y algunas características de la RNA desarrollada para la obtención de la HS. Se puede observar en la Figura 3 el algoritmo, en forma de diagrama de bloque, el cual permite estimar la HS a partir del backscattering (σ^0) de las imágenes SAR, integrando información complementaria.

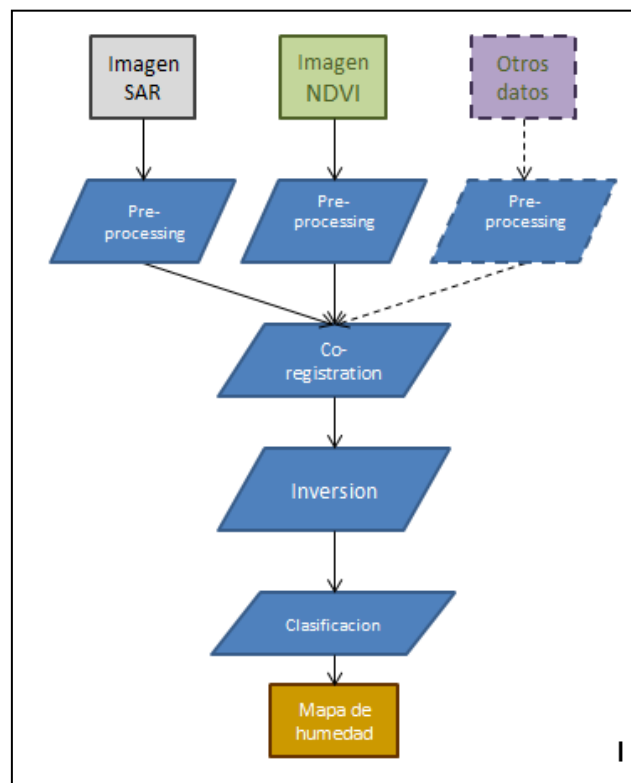


Figura 3. Algoritmo para determinación de la humedad del suelo.

El primer paso es considerar los datos de entrada al algoritmo, tales como:

Imágenes SAR. En este proyecto las imágenes de backscattering provienen del satélite TerraSAR-X. Las imágenes están en formato Single Look Complex (SLC) con el fin de pre-procesarlas y filtrarlas adecuadamente antes de ser utilizadas en la etapa de inversión.

Imágenes de NDVI. En este proyecto se recurrió al producto MOD 13 del sensor MODIS. Dado que todos los datos de campo fueron relevados en lotes con suelo desnudo, en el algoritmo implementado, el NDVI es usado para enmascarar los lotes que presentan cobertura vegetal. Cabe recordar que la profundidad de penetración de las ondas electromagnéticas de la banda-X en la vegetación es muy poco profunda, por lo tanto, cuando la cobertura vegetal es uniforme y completa, los datos SAR se vuelven insensibles a la humedad de suelo debajo de la vegetación.

Datos auxiliares. Se sabe que los datos de backscattering son sensibles a la HS pero también a la rugosidad del suelo. A medida que la longitud de onda se acorta, esa dependencia aumenta. Para compensar este efecto y mejorar la performance general del algoritmo, el algoritmo de inversión se diseñó para aceptar otros datos auxiliares como precipitación, rugosidad del suelo o mapas de uso del suelo.

El segundo paso del algoritmo es el pre-procesamiento de los datos de entrada. Cada dato requiere su propia técnica:

Las imágenes SAR deben ser multi-look a fin de reducir el ruido de speckle que las afecta. El procedimiento multi-looking se lleva a cabo para reducir la dispersión de los histogramas de backscattering (σ^0) requerido para determinar el valor del backscattering en cada lote.

El tercer paso en el algoritmo de HS es el co-registro de todos los datos de entrada sobre la misma grilla y la re-proyección en el sistema cartográfico, en este caso Gauss-Kruger - Faja 5, EPSG (22195).

Una vez que todos los datos fueron pre-procesados y co-registrados, se ingresan al bloque de inversión. La inversión se realiza mediante la RNA, que es flexible y brinda resultados precisos. El algoritmo desarrollado es lo más general posible, la técnica de inversión puede sustituirse por un algoritmo Bayesiano o algoritmos semi-empíricos.

Por último, el tercer paso es la clasificación del mapa de HS. De acuerdo al NDVI, las áreas vegetadas se enmascaran dado que en ellas no puede obtenerse la HS. Además, los píxeles del mapa de HS que poseen un backscattering muy alto, se clasifican como urbanas/forestadas y cuando el valor es muy bajo (debajo de -20 dB) se clasifica como sin/dato. Luego de este paso, se obtiene el mapa final de HS.

3. Resultados y Discusión

3.1 Análisis de backscattering de las imágenes SAR

La polarización HH fue seleccionada debido a que es más sensible a la humedad del suelo y es menos afectada por la cobertura de biomasa vegetal, comparada con la VV. Todas las imágenes SAR fueron corregidas geoméricamente, empleando la proyección cartográfica Gauss-Kruger-Faja 5 y luego ortorectificadas con el modelo digital del terreno SRTM4.

Cada imagen SAR fue entonces importada dentro de un SIG para relacionarla con las mediciones del terreno (humedad y rugosidad del suelo). Es necesario comentar que el número de píxeles que caen dentro de los lotes de campo medidos in situ, es del orden de los 100 hasta 5000, siendo cada píxel de 10x10 m², asegurando de esta manera que las estadísticas medias del lote estén bien estimadas. Para cada campo o lote medido in situ, se extrajo y analizó el backscattering que los mismos presentaban en las imágenes SAR. A continuación, se verificó la uniformidad de estos valores sobre cada lote a través de sus histogramas para comprobar si se ajustaban a la forma gaussiana regular y, en tal caso, obtener el valor de backscattering promedio (Figura 4).

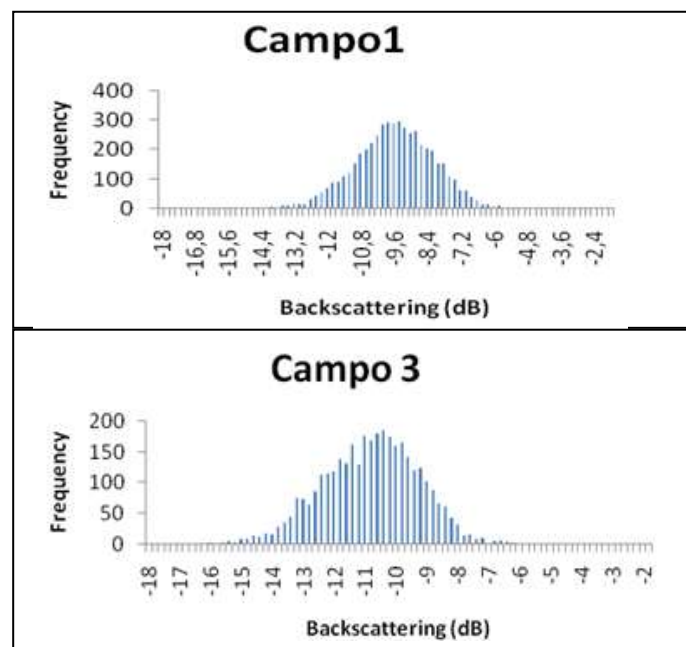


Figura 4. Backscattering promedio para diferentes lotes de la imagen del 03/09/2012.

Se observa en los gráficos de la Figura 4 que el backscattering medio es de -9,4 dB y -10,6 dB, para los campos 1 y 3, respectivamente.

3.2 Multi-looking de las imágenes SAR

Cuando un blanco estadísticamente homogéneo es captado por el sensor SAR (en este trabajo lotes con suelo desnudo), la imagen resultante no es homogénea sino que está afectada

por el ruido denominado “speckle”. El valor de σ^0 de los píxeles sobre el blanco no es único sino que se distribuye de acuerdo a una distribución Gamma cuya varianza depende principalmente del speckle. Si la sensibilidad del backscattering (σ^0) a un parámetro del blanco es del mismo orden que la desviación estándar de σ^0 sobre el blanco, la imagen no puede utilizarse luego, en la inversión de σ^0 a HS, debido a que la incertidumbre en los datos de entrada es comparable a la sensibilidad del proceso.

En orden a reducir el ruido y obtener el valor medio correcto del backscattering en el blanco, un procedimiento efectivo es el multi-looking. Este procedimiento produce, por un lado, una reducción del ruido con lo cual los histogramas de la distribución de σ^0 extraídos de un área homogénea tienden a lucir como gaussianos (agrupados alrededor de la media) con el incremento del factor multi-looking. Por otro lado, este procedimiento causa la degradación de la resolución espacial de la imagen. Luego, el balance entre la resolución espacial de la imagen y el ruido aceptado en el proceso depende de la sensibilidad de σ^0 a los parámetros deseados (en este caso HS) y también, de las dimensiones del blanco (en este caso el tamaño de los lotes). En la recuperación de HS a partir de datos SAR banda-X, polarización HH, la sensibilidad esperada de σ^0 a la HS es alrededor de 3 dB (decibeles) en el rango $5\% < HS < 45\%$. Si se quiere clasificar σ^0 en 4 clases, se necesita una desviación estándar mejor que 0,75 dB.

A modo de ejemplo se muestra el procesamiento de 12 lotes. La dimensión de los píxeles de cada imagen fue adaptada a la nueva resolución espacial, que varía debido al factor de multi-looking aplicado sobre la imagen. La Tabla 2 muestra para cada lote de interés los distintos factores de multi-looking empleados, sobre la imagen Terrasar-X captada el 03/09/2012, y los correspondientes valores de media y desvío estándar de σ^0 obtenidos, como así también, el número de píxeles incluidos en cada lote.

Tabla 2. Media y desvío estándar para diferentes factores de Multi-looking.

LOTE	Multi-looking 5 (pixel res 10m)			Multi-looking 10 (pixel res 20m)			Multi-looking 50 (pixel res 100m)			Multi-looking 100 (pixel res 200m)		
	mean dB	stdev dB	n. pixel	mean dB	stdev dB	n. pixel	mean dB	stdev dB	n. pixel	mean dB	stdev dB	n. pixel
1	-9.161	1.300	2153	-9.122	0.818	545	-9.029	0.530	25	-8.961	0.236	3
2	-8.123	1.275	666	-8.159	0.669	164	-8.492	0.373	7	-8.832	0.776	2
3	-9.910	1.395	8311	-9.937	0.911	2070	-9.773	0.555	80	-9.568	0.578	24
4	-8.622	1.235	838	-8.592	0.782	216	-8.504	0.247	8	-8.836	0.346	2
5	-9.862	1.286	2170	-9.837	0.735	535	-9.767	0.267	23	-9.625	0.288	7
6	-8.957	1.286	343	-8.924	0.741	89	-8.854	0.159	5	-8.456		1
7	-12.250	1.176	472	-12.145	0.634	111	-11.410	0.899	4	-10.343	1.177	2
8	-11.750	1.087	325	-11.694	0.536	82	-11.120	0.914	3	-12.027		1
9	-9.399	1.238	861	-9.392	0.705	223	-9.136	0.412	7	-8.995	0.486	2
10	-8.104	1.319	3590	-8.102	0.785	899	-8.125	0.435	37	-8.319	0.299	10
11	-7.949	1.208	8190	-7.957	0.682	2017	-7.927	0.297	72	-7.954	0.235	18
12	-7.252	1.142	1295	-7.246	0.599	325	-7.251	0.174	12	-7.774	0.473	4

Los Lotes marcados en verde corresponden a los de mayor tamaño. A pesar de que el factor de multi-looking se incrementa y la resolución espacial del pixel decrece, el número de píxeles sigue siendo alto. En este caso, el desvío estándar de la distribución de σ^0 disminuye mientras que la media se mantiene aproximadamente constante. En el caso de los lotes de tamaño pequeño (color anaranjado), la degradación de la imagen debido al multi-looking ocasiona un cambio en la media de σ^0 . Las dimensiones de las celdas se vuelven muy grandes como para ser incluidas dentro del perímetro del ROI. Esto significa que no es posible

determinar la media de σ^0 con la suficiente precisión para su inversión a HS, estos lotes deberían ser evitados en la inversión (Figura 5).

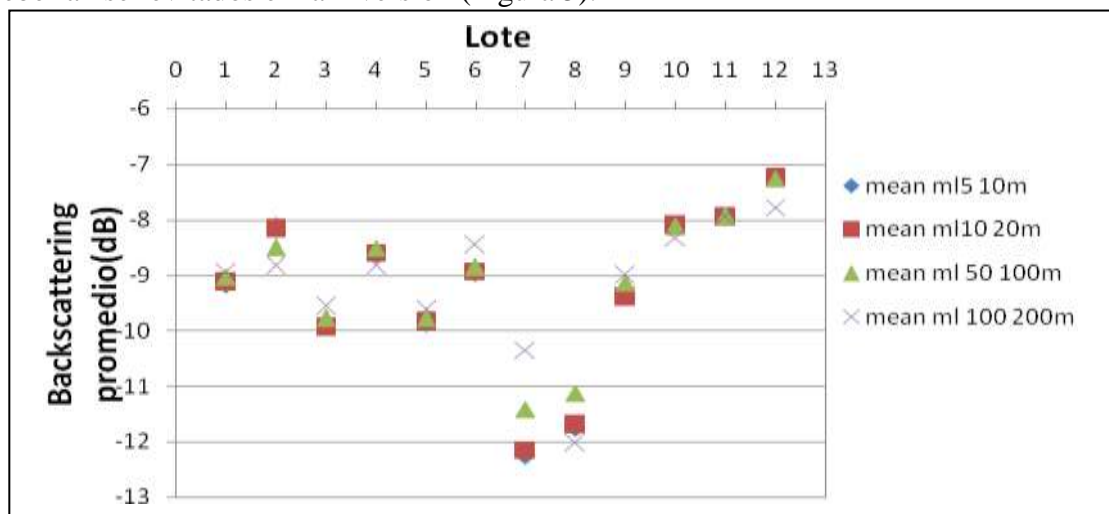


Figura 5. Media del backscattering para diferentes resoluciones espaciales.

3.3 Entrenamiento de la red neuronal

En el algoritmo para estimar la HS, la inversión del backscattering se realiza por medio de una red neuronal artificial (RNA). Esta técnica es muy flexible y permite construir relaciones entre datos de entrada diferentes, como por ejemplo: backscattering, NDVI, datos auxiliares, etc. En este estudio la RNA relaciona σ^0 de banda-X con la HS, aunque el algoritmo desarrollado es flexible y puede aceptar otros datos de entrada en orden a mejorar la performance de la inversión (por ejemplo σ^0 en banda-L o datos de precipitación).

Dado que las campañas de campo fueron muy intensivas y proveyeron un valioso juego de datos, se seleccionó el 75% de los datos recolectados para entrenar la RNA, reservando el resto para testear la validez de la red. Utilizando el conjunto de datos de entrenamiento, se seleccionó el número de neuronas de la capa oculta. Se entrenaron varias RNA, cada una con diferente tamaño de la capa oculta, luego utilizando los datos para testear la validez, se analizó el error cuadrático medio (RMSE) de la HS estimada, ver Figura 6.

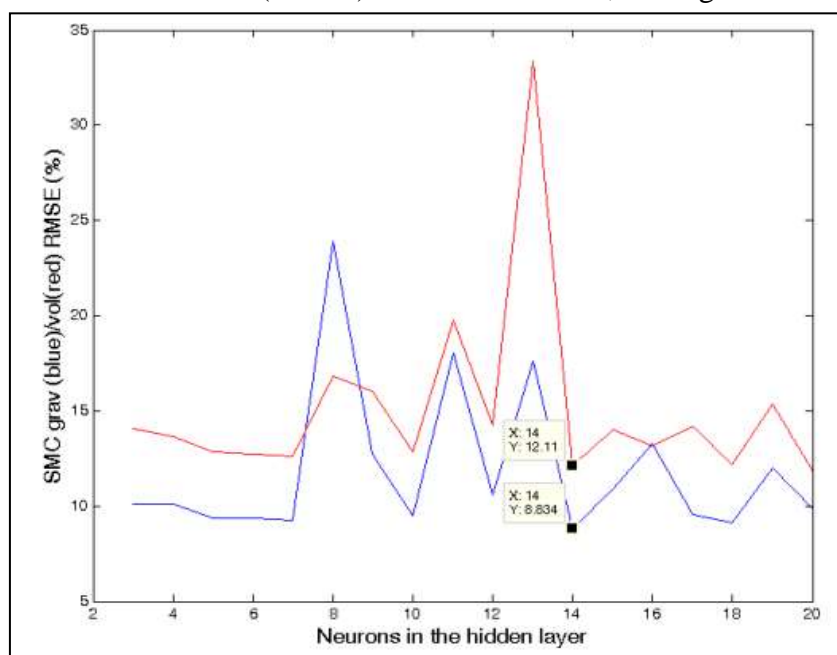


Figura 6. Error cuadrático medio (RMSE) de la HS gravimétrica y volumétrica estimada.

El menor valor de RMSE se obtuvo para una capa oculta compuesta por 14 neuronas: el RMSE del contenido gravimétrico de agua fue 8,83% y del contenido volumétrico 12,11%.

Finalmente se aprecia un mapa de HS elaborado a partir del algoritmo de inversión de la RNA aplicado sobre la imagen TerraSAR-X del 03/09/2012 (Figura 7).




Figura 7. Mapa de humedad del suelo (HS) para el 03/09/2012 derivado de la RNA.

4. Conclusiones

En principio se apreció que para lotes con valores de contenido volumétrico de agua similares medido en campo se obtienen valores diferentes de backscattering (σ^0). Esto podría deberse a la diferencia de cobertura de los distintos lotes, como rastrojo de soja o maíz. Otro factor que afectaría los resultados es el porcentaje de dicha cobertura (por unidad de área).

La inversión del backscattering para estimar HS, se realiza por medio de una RNA. En este estudio la RNA relaciona σ^0 de banda-X y HS, el algoritmo es muy flexible y puede aceptar otros datos de entrada en orden a mejorar la performance de la inversión.

Una primera comparación realizada entre la HS obtenida de la inversión realizada con la RNA para una imagen TerraSAR-X mostró que la misma arrojó valores de HS cercanos a los medidos en campo.

Agradecimientos

Los autores agradecen a la Universidad Nacional del Litoral - UNL de Argentina y al Instituto de Física Aplicada - IFAC de Italia por el financiamiento recibido para la ejecución del trabajo. Asimismo agradecen al MINCYT de Argentina y la MAE de Italia, por su apoyo en el proyecto de investigación SAR-INAGRO (IT1303).

Referencias Bibliográficas

- Das, N.N.; Entekhabi, D.; Njoku, E. An algorithm for merging SMAP radiometer and radar data for high resolution soil-moisture retrieval. *IEEE Transactions on Geosciences and Remote sensing*, Vol. 49, 5, 1504/1512, 2011.
- Jackson, T. J.; Schmugge, T. J.; Engman, E.T. Remote sensing applications to hydrology: Soil moisture. *Hydrological Sciences Journal*, vol. 41, no. 4, p. 517–530, 1996.
- Paloscia, S., Pampaloni, P., Pettinato, S. and Santi, E., 2009, A comparison of algorithms for retrieving soil moisture from ENVISAT/ASAR images. *IEEE. Remote Sensing* Vol. 47/9, 2991-2994
- Piles, M.; Entekhabi, D.; Camps, A. A change detection algorithm for retrieving high-resolution soil moisture from SMAP radar and radiometer observations. *IEEE Transactions on Geosciences and remote sensing*, Vol. 54, 12, 4125-4131, 2009.
- Wang, L.; Qu, J.J. Satellite remote sensing applications for surface soil moisture monitoring: A review. *Front. Earth Science China*, 3(2), 237–247. DOI 10.1007/s11707-009-0023-7, 2009.