

# Determinación de la humedad de suelo mediante regresión lineal múltiple con datos TerraSAR-X

García, G.<sup>\*1,3</sup>, Brogioni, M.<sup>4</sup>, Venturini, V.<sup>1</sup>, Rodríguez, L.<sup>1</sup>, Fontanelli, G.<sup>4</sup>, Walker, E.<sup>1</sup>, Graciani, S.<sup>2</sup>, Macelloni, G.<sup>4</sup>

<sup>1</sup> Centro de Estudios Hidro-Ambientales, Facultad de Ingeniería y Ciencias Hídricas (FICH), Universidad Nacional del Litoral (UNL), Argentina.

<sup>2</sup> Facultad de Ingeniería y Ciencias Hídricas (FICH), Universidad Nacional del Litoral (UNL), Argentina.

<sup>3</sup> Consejo Nacional de Investigaciones Científicas y Técnicas (CONICET), Argentina.

<sup>4</sup> Consiglio Nazionale delle Ricerche (CNR) – Istituto di Fisica Applicata “N. Carrara” (IFAC), Italia.

---

**Resumen:** Los primeros cinco centímetros del suelo forman una interfaz donde se producen los principales intercambios de flujos de calor entre la superficie terrestre y la atmósfera. La teledetección ha demostrado ser una excelente herramienta para el seguimiento de datos espacial y temporalmente distribuidos de las características sobresalientes de la superficie terrestre, incluidos los parámetros del suelo. Los sensores de microondas activos (*Synthetic Aperture Radar* - SAR) ofrecen la posibilidad de monitorizar la humedad de suelo (HS) a escala global, regional y local, mediante la modelación de los procesos involucrados. Diversos algoritmos de inversión han sido desarrollados para derivar información geofísica, como HS, a partir de información SAR. Muchos de ellos utilizan modelos electromagnéticos para simular el coeficiente de retrodispersión y se basan en técnicas estadísticas tales como redes neuronales, métodos de inversión y modelos de regresión. Estudios recientes han demostrado que las técnicas simples de regresión múltiple arrojan resultados aceptables. Las variables geofísicas implicadas en estas metodologías son descriptivas de la estructura del suelo, las características de las microondas y la cobertura del suelo. Por esto, en este trabajo se propone desarrollar un modelo de regresión lineal múltiple para estimar HS en zonas de llanura combinando datos de la misión satelital TerraSAR-X y datos de una estación meteorológica. La modelación propuesta involucra las variables hidrológicas que caracterizan las zonas de llanura, donde los movimientos verticales de agua en el suelo predominan sobre el escurrimiento horizontal. Los resultados obtenidos muestran que la retrodispersión, la precipitación y la humedad relativa del aire son las variables explicativas de HS. El modelo obtenido arrojó un RMSE de 5,4 y un  $R^2$  de 0,6.

**Palabras clave:** humedad de suelo, regresión múltiple, TerraSAR-X.

## Soil moisture estimation using multi linear regression with terraSAR-X data

**Abstract:** The first five centimeters of soil form an interface where the main heat fluxes exchanges between the land surface and the atmosphere occur. Besides ground measurements, remote sensing has proven to be an excellent tool for the monitoring of spatial and temporal distributed data of the most relevant Earth surface parameters including soil's parameters. Indeed, active microwave sensors (*Synthetic Aperture Radar* - SAR) offer the opportunity to monitor soil moisture (HS) at global, regional and local scales by monitoring involved processes. Several inversion algorithms, that derive geophysical information as HS from SAR data, were developed. Many of them use electromagnetic models for simulating the backscattering coefficient and are based on statistical techniques, such as neural networks, inversion methods and regression models. Recent studies have shown that simple multiple regression techniques yield satisfactory results. The involved geophysical variables in these methodologies are descriptive of the soil structure,

\* Autor para la correspondencia: [ggarcia@fich.unl.edu.ar](mailto:ggarcia@fich.unl.edu.ar)

microwave characteristics and land use. Therefore, in this paper we aim at developing a multiple linear regression model to estimate HS on flat agricultural regions using TerraSAR-X satellite data and data from a ground weather station. The results show that the backscatter, the precipitation and the relative humidity are the explanatory variables of HS. The results obtained presented a RMSE of 5.4 and a  $R^2$  of about 0.6.

**Key words:** soil moisture, multiple regression, TerraSAR-X.

## 1. Introducción

La gestión del agua y la producción agrícola requieren de estimaciones de media-alta resolución espacial (10-100 m) de la humedad del suelo (HS) (Ranney *et al.*, 2015). Burt y Butcher (1985) establecieron la primera relación entre HS y diferentes factores topográficos que controlan su variabilidad. Posteriormente, varios autores estudiaron relaciones similares, por ejemplo Grayson *et al.*, (1997), Western *et al.*, (1999), Brocca *et al.*, (2006). Otros estudios relacionaron la variabilidad espacial de la HS con las variaciones de las propiedades del suelo, incluyendo la porosidad, la conductividad hidráulica, la textura y la profundidad del suelo (Tromp-van Meerveld *et al.*, 2006; Takagi y Li, 2011; Martínez-García *et al.*, 2014). Qiu *et al.* (2010) analizaron la relación entre los principales atributos ambientales y la HS, y desarrollaron diferentes métodos de regresión lineal múltiple. Recientemente, Ranney *et al.* (2015) generalizaron el modelo *Equilibrium Moisture from Topography* (EMT) incluyendo información de la variación espacial de la vegetación.

Los datos remotamente obtenidos con sensores de microondas activos y pasivos han probado ser los mejores instrumentos para cuantificar la HS en los primeros 5 cm de suelo (Engman y Chauman, 1995).

La tecnología *Synthetic Aperture Radar* (SAR) ha evolucionado en los últimos diez años y hoy en día se dispone de información satelital de sensores con diferentes frecuencias. Los sistemas SAR montados en satélites ERS-1, ERS-2, ENVISAT, Sentinel-1, RADARSAT-1 y 2 operaban sólo en la banda C (5 cm), que es afectada por la rugosidad del suelo, sobre todo por la cobertura vegetal (Paloscia *et al.*, 2008). Por otra parte TerraSAR-X y Cosmo-SkyMed, provee información en banda X (3 cm), que poseería sensibilidad a la humedad de suelo (HS) equivalente a la de la banda C (Baghdadi *et al.*, 2008; Baghdadi *et al.*,

2012). En los últimos años se ha puesto énfasis en los sistemas SAR en banda L (1.4 Ghz-20 cm), por ejemplo las misiones ALOS-PALSAR, actualmente ALOS-2. Esta tendencia continúa con la misión SMAP (lanzada en 2015) y futuras misiones como SAOCOM (fecha de lanzamiento 2016).

Los datos obtenidos con sensores SAR han sido utilizados para determinar HS con modelos de diferente naturaleza (Shi *et al.*, 1997; Dubois *et al.*, 1995). Estos se pueden clasificar en modelos semiempíricos y empíricos, teóricos, numéricos y analíticos de la retrodispersión tal como se detalla en Kornelsen y Coulibaly (2013).

Las metodologías propuestas para la estimación de HS a partir de imágenes SAR pueden agruparse según las condiciones de aplicabilidad y sus propiedades intrínsecas. Para condiciones de ausencia de vegetación, es decir suelos desnudos, se han desarrollado tanto modelos semiempíricos como el de Oh *et al.* (1992) y el de Dubois *et al.* (1995), modelos electromagnéticos de base física como el modelo *Integral Equation Method* (IEM) (Fung *et al.*, 1992; Fung, 1994), *Geometrical Optics Model* (GOM) y el modelo *Small Perturbation Model* (SPM) (Ulaby *et al.*, 1982), así como también modelos empíricos basados en técnicas de detección de cambios (Lievens y Verhoest, 2012; Balenzano *et al.*, 2012) o los basados en métodos estadísticos.

Entre los métodos estadísticos desarrollados, se pueden mencionar los métodos de inteligencia computacional como redes neuronales (Said *et al.*, 2008; Ahmad *et al.*, 2010; Paloscia *et al.*, 2010; Kseneman *et al.*, 2012) y máquinas de soporte vectorial (Pasolli *et al.*, 2011, 2012) y por otro lado, los métodos bayesianos (Mattia *et al.*, 2006; Notarnicola *et al.*, 2008; Paloscia *et al.*, 2008; Pierdicca *et al.*, 2014).

La mayoría de estos modelos han sido utilizados en regiones con terrenos de pendientes moderadas a pronunciadas, donde los movimientos horizontales

del agua dominan la variabilidad de HS (Forte Lay *et al.*, 2008). Los estudios que han estimado HS para zonas de llanuras, relacionan la variabilidad de la misma con parámetros que caracterizan el suelo, pero no representan los movimientos verticales del agua, que dan origen a las variaciones de HS en estos ambientes. Por ejemplo, Ranney *et al.* (2015) describen que la influencia de las propiedades del suelo puede ser mayor durante condiciones húmedas. Estos autores estudiaron la cuenca Tarrawarra en Australia, donde los movimientos laterales del agua controlan los patrones de HS durante la humidificación. Sin embargo, durante los periodos secos, los flujos verticales controlan la HS y el índice de radiación solar potencial queda estrechamente asociado con los patrones de HS. Paloscia *et al.* (2008) estudiaron diferentes modelos para estimar HS a partir de la retrodispersión del sensor ENVISAT/ASAR en una llanura de Italia. Los autores aplicaron redes neuronales y métodos basados en el teorema de Bayes utilizando la relación entre la retrodispersión y HS.

En este trabajo se propone aplicar un método simple de regresión lineal múltiple (RLM) para estimar la variación de HS en zonas de llanuras no solo a partir de la retrodispersión ( $\sigma^0$ ) sino también de datos meteorológicos que representen la variabilidad de HS. En la llanura, el escurrimiento lateral del agua es despreciable frente a los flujos verticales representados por la precipitación –evapotranspiración. Por esto, se propone explicar la variabilidad de la HS con variables tales como la precipitación, la temperatura del aire y del suelo, y la humedad relativa del aire.

## 2. Métodos

El método propuesto para estimar la HS a partir de información SAR es el método estadístico de RLM, con el que se ajusta una función lineal a un conjunto de variables independientes ( $X_i$ ) aproximando la variable dependiente ( $Y$ ). El objetivo de este método es calcular los valores de los coeficientes ( $\beta_i$ ) de la siguiente ecuación:

$$Y = \beta_0 + \beta_1 \times X_1 + \beta_2 \times X_2 + \dots + \beta_p \times X_p + \varepsilon \quad (1)$$

Para estimar  $\beta_i$  se utiliza el método de mínimos cuadrados y se define el error como suma de las diferencias al cuadrado (Helsel y Hirsch, 2002).

El modelo de regresión antes detallado requiere que las variables de entrada sean explicativas de la variable de salida, y además, que cada una de las variables de entrada incorpore información diferente. Por ello, primero se analiza si existe significación estadística de las variables de entrada. Entonces, se calcula el estadístico-t para todos los coeficientes y luego se contrasta con el valor de t por tabla, obtenido según los grados de libertad que tenga el bloque de datos a utilizar (Downing y Clark, 1997). Otro estadístico que describe la significancia de las variables independientes es el  $p$ -valor que determina si se acepta la hipótesis planteada (Weisberg, 2005).

Posteriormente, una vez seleccionadas las variables de entrada representativas del comportamiento de la variable de salida, se analiza la multicolinealidad entre ellas. Para detectar el tipo de multicolinealidad, se utiliza el Factor de Inflación de la Varianza (FIV) (Harrell, 2001; Fox, 2002). Si las variables de entrada no son redundantes, entonces FIV es igual a 1 (Glantz y Slinker, 1990). Valores de FIV mayores que 4 sugieren la existencia de multicolinealidad, y valores mayores que 10 indican la existencia de multicolinealidad grave (Montgomery y Peck, 1992; Fox, 2002; Cohen *et al.*, 2003). Otros autores sugieren que el límite del FIV es 5-10 (Marquardt, 1970).

Para llevar a cabo el análisis del modelo se utiliza el coeficiente de determinación múltiple  $R^2$  que representa la proporción de la variación de los datos explicada por el modelo.

## 3. Área de estudio y datos

### 3.1. Área de estudio

El área de estudio se ubica en la Provincia de Santa Fe, Argentina, con centro en la localidad de Ataliva (Figura 1). Esta provincia integra la región agrícola-ganadera e industrial de Argentina, que concentra gran parte de la actividad del sector y de la población del país. 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. Las precipitaciones se concentran en el semestre noviembre–abril, con un 75% del total anual. Los suelos de la zona pertenecen a asociaciones de Argiudoles Típicos. La localidad

de Ataliva se caracteriza fundamentalmente por la producción agrícola y tambera, y en menor medida por la ganadera. Los principales cultivos son soja, maíz y alfalfa.

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 ( $30^{\circ}59'45,8''S$ ;  $61^{\circ}25'55,5''O$ ), Provincia de Santa Fe, Argentina.

### 3.2. Datos

Los valores de HS corresponden a los días 03/09/2012, 14/09/2012, 25/09/2012, 30/11/2012, 22/04/2013 y 14/05/2013, fechas en las que se extrajeron muestras de suelo a una profundidad de 3-5 cm para análisis gravimétrico en laboratorio. En cada fecha se muestrearon en promedio 10 parcelas cuyos tamaños varían entre 1,5 y 40 ha, resultando 63 registros. Mayor información de las campañas está disponible en Brogioni *et al.* (2014).

Durante las campañas se identificaron los siguientes tipos de cobertura: rastrojo (soja, sorgo, maíz, trigo), barbecho, pastos (verdeo, alfalfa). Algunos campos se encontraban arados y otros sembrados con soja en diferentes estados fenológicos.

Como variables de entrada al método RLM se utilizó la información que se detalla a continuación: por un lado se trabajó con imágenes del satélite TerraSAR-X que posee un sensor SAR en la longitud de onda X de 31 mm. Los productos adquiridos son en modo single look *Stripmap* en polarización HH, con ángulo de incidencia del centro de la escena de  $24^{\circ}$  y fecha de adquisición coincidente con los datos de campo. Las

imágenes fueron pre-procesadas con el software Sarmap-SarScape<sup>®</sup>: primero se les aplicó la operación de *Multilooking* ( $5 [Azimuth] \times 5 [Range]$ ) para reducir el ruido (*Speckle*); luego, se realizó la geocodificación de la información utilizando el sistema de referencia POSGAR junto con la calibración radiométrica de la retrodispersión mediante el uso de datos de elevación obtenidos del DEM SRTM4 (resolución plana 90 m). Finalmente, cada imagen fue remuestreada a un pixel de dimensión 10 m utilizando el método convolución cúbica, obteniendo de esta manera  $\sigma^{\circ}$ . La calidad de la geocodificación fue comprobada mediante la superposición de cada escena SAR preprocesada con una imagen Landsat 7, comúnmente utilizada como referencia para el chequeo de geocodificación.

Otra variable de entrada fue el Índice de Vegetación Normalizado (NDVI), obtenido a partir del sensor MODIS a bordo de la misión satelital Terra (EOS AM-1), el cual proporciona cada 16 días el producto MOD13A1 que posee el índice de vegetación con una resolución espacial de 500 m.

La única estación meteorológica con datos utilizables se encuentra en la localidad de Rafaela, Santa Fe, perteneciente a la red de estaciones experimentales agropecuarias del Instituto Nacional de Tecnología Agropecuaria (INTA). Rafaela está aproximadamente a 32 km al sur de Ataliva, por lo que previo a su utilización se verificó la homogeneidad de las precipitaciones medias mensuales en la zona mediante la base de datos CRU-TS 3.2 (Krepper y Venturini, 2009).

Los datos meteorológicos utilizados fueron precipitación (PP), temperatura del aire ( $T_a$ ) y suelo ( $T_s$ ) y la humedad relativa del aire (HR), las cuales fueron pre-procesadas para obtener valores acumulados para el caso de la precipitación y valores promedio para las restantes variables. Se utilizó una ventana de 7 días previos a la fecha de las muestras. En la tabla 1 se presenta la distribución temporal de las imágenes satelitales de TerraSAR-X y MODIS.

Todas estas variables de entrada fueron analizadas para comprobar su influencia sobre la variable dependiente, HS expresada en % gravimétrico, como así también la influencia de cada variable independiente sobre las demás. El objetivo es que cada variable independiente posea una fuerte influencia sobre HS pero casi nula en las demás.

**Tabla 1.** Inventario de las imágenes y los datos de campo utilizados

Fecha SAR	3/9/2012	14/09/2012	25/09/2012	30/11/2012	22/04/2013	14/05/2013
Fecha NDVI	28/08/2012	13/09/2012	29/09/2012	2/12/2012	23/04/2013	9/5/2013

#### 4. Resultados

Las variables de entrada obtenidas para el área de estudio fueron:  $\sigma^0$  (dB), NDVI, PP (mm),  $T_a$  (°C),  $T_s$  (°C) y HR (%). Un análisis teórico previo de las variables, puso en manifiesto la relación que existen entre  $T_a$  y  $T_s$  (Parton, 1984). Para evitar problemas de colinealidad entre estas variables, se decidió tomar el diferencial de temperatura ( $\Delta T = T_a - T_s$ ).

Con el conjunto de datos de las variables  $\sigma^0$ , NDVI, PP,  $\Delta T$  y HR, se generó un modelo completo con un  $R^2$  de 0,631. Luego, en base a los estadísticos se discriminaron las variables menos significativas. En la tabla 2 se presentan los coeficientes de las variables explicativas, error estándar, estadístico-t y  $p$ -valor para cada una de las variables explicativas. El modelo final contiene las siguientes variables  $\sigma^0$ , PP y HR arrojando un  $R^2$  de 0,630.

El movimiento vertical del agua en el sistema suelo - atmósfera ocurre de manera espontánea por gradientes de energía desde el suelo al aire circundante. El flujo de calor latente, que representa la evapotranspiración (ET), al igual que el flujo de calor sensible, que representa el aumento de  $T_s$ , dependen de los gradientes de humedad. La incorporación de vapor de agua en el aire es dependiente del calor latente o ET y está cuantificado mediante HR. De esta manera se relaciona la HS con HR y la pérdida vertical de agua debida a la ET y se explicaría por qué el método seleccionó esta variable.

Una vez establecido el modelo, se continuó con el análisis de multicolinealidad mediante el parámetro FIV. Las variables PP, HR y  $\sigma^0$  presentan

valores de FIV similares siendo 1,045, 1,074 y 1,075, respectivamente.

Posteriormente, con las variables se procedió a calcular los coeficientes del modelo final. Para esto se determinó la cantidad óptima de datos para entrenar y validar el modelo mediante el análisis del error de entrenamiento y el error verdadero de predicción. El error de entrenamiento se obtiene comparando los valores simulados con los datos de HS utilizados para obtener los coeficientes de la regresión; mientras que el error verdadero es el error de validación, es decir contrastando las simulaciones obtenidas con datos no utilizados para definir el modelo. Por consiguiente se fue variando la cantidad de datos utilizados para estimar los coeficientes y los errores mencionados a fin de obtener un porcentaje óptimo de datos para cada proceso.

Por esto el entrenamiento, es decir el cálculo de los coeficientes, se realizó con 30% de los datos (18 registros) y el 70% restante se utilizó para realizar la validación del mismo. Los coeficientes de determinación de entrenamiento y validación fueron 0,65 y 0,60 respectivamente, siendo el RMSE de entrenamiento igual a 5,68 mientras que el de validación fue de 5,41.

Finalmente, el modelo queda estructurado como sigue:

$$\hat{Y} = -36,744 + 1,426 \times \sigma^0 + 6,655 \times PP + 0,667 \times HR \quad (2)$$

Con esta ecuación se podrían estimar los valores de HS en la zona en estudio, utilizando información meteorológica y SAR en banda X.

**Tabla 2.** Análisis de las variables.

Parámetro	Coefficiente	Error Estándar	Estadístico-t	$p$ -valor
Constante	-24,6724	11,022	-2,238	0,029
Retrodispersión	1,8289	0,529	3,456	0,001
Precipitación	6,6740	0,840	7,943	0,000
Humedad relativa del aire	0,5550	0,114	4,871	0,000



Posteriormente se efectuó un análisis del aporte que cada variable *per se* hace a la dinámica de HS. Se muestra que el ingreso o egreso de agua solamente no explican la HS, por el contrario es necesario representar ambos procesos simultáneamente. De este modo, en el primer análisis se consideró solo los valores de  $\sigma^0$  como variable de entrada. Se obtuvo un RMSE igual a 7,68 [que representa 19,7% del valor de HS máximo] (Figura 2) y un  $R^2$  igual a 0,201. Esto demuestra que retrodispersión es una variable significativa, pero no explica HS por si sola.

En el segundo análisis se agregó la variable PP. El error se redujo a RMSE=6,48 [16,62% de HS máx.] (Figura 3) y un  $R^2$  igual a 0,431. Sin duda la precipitación introduce información sustancial pero sigue siendo insuficiente.

Por último se validó el modelo con todas las variables. En este caso, el contraste con los datos de campo arroja un RMSE=5,41 [13,89% del valor de HS máx.] y un  $R^2$  igual a 0,603 (Figura 4).

Utilizando HR, el RMSE se reduce y además el  $R^2$  mejora considerablemente.

### 5. Discusión

La retrodispersión depende de variables tales como ángulo de incidencia, rugosidad, textura y humedad de la superficie. Por esto, tradicionalmente se obtiene HS mediante la inversión de los modelos de retrodispersión, y no con las variables climáticas que afectan la HS. En el caso del modelo propuesto, la retrodispersión es la variable que representa las propiedades físicas del suelo, mientras que las otras variables están relacionadas con la dinámica de HS.

El estudio de la colinealidad a través de métodos estadísticos objetivos es fundamental para evaluar la relación entre las variables que describen los procesos físicos asociados a HS. Si bien la utilización de transformaciones de las variables para eliminar la colinealidad es muy común, en este trabajo se evitaron para poder verificar la robustez de la hipótesis planteada. Se hicieron varias pruebas, entre las que se consideró  $T_a$ ,  $T_s$ , NDVI, HR, y PP. La  $T_a$  y  $T_s$  no son suficientemente significativas por lo que se consideró utilizar la diferencia  $\Delta T=(T_s-T_a)$ . La diferencia de temperaturas genera movimientos verticales de humedad entre el suelo




Figura 2. Modelo RLM con Retrodispersión.




Figura 3. Modelo RLM con Retrodispersión+Precipitación.




Figura 4. Modelo RLM Retrodispersión + Precipitación + Humedad relativa del aire.

y el aire. Por otra parte la evaporación está relacionada a la radiación neta y a la tensión de vapor del agua, que depende de la HR y de  $\Delta T$ . Por esto se especulaba que  $\Delta T$  quedaría seleccionada en el modelo dado que su relación física con ET y HS está bien documentada, sin embargo esto no ocurrió.

El NDVI fue descartado del conjunto de entrada por no ser una variable explicativa, probablemente por la diferencia en las fechas de los datos de SAR y las imágenes de NDVI. Aunque los datos fueron registrados en parcelas sin vegetación activa, se observaron rastros de diferentes cultivos. Si bien el NDVI es una variable cuasi-estable en 15 días es posible que las fechas de muestreo estén entre periodos de cosecha o siembra.

Estadísticamente hablando, la importancia relativa de las variables está dada por el estadístico-t, que asigna el mayor valor a  $\sigma^0$ , seguido por la PP y por último HR.

Los valores de RMSE que arrojó el modelo son comparables con los publicados con el radar TRMMPR (Puri *et al.*, 2011). Kseneman *et al.* (2012) aplican un modelo de redes neuronales para obtener HS con imágenes de TerraSarX reportando valores de RMSE de 13. Baghdadi *et al.* (2012) utilizando imágenes TerraSarX con diferentes ángulos de observación obtienen errores RMSE de aproximadamente 4.

## 6. Conclusiones

En este trabajo se presentaron resultados preliminares de la aplicación del método de regresión lineal múltiple utilizando como variables de entrada imágenes TerraSAR-X y datos meteorológicos registrados en una región llana, donde los movimientos predominantes del agua son verticales.

Se enfatiza que el método selecciona las variables que representan la entrada y salida de agua al sistema. La entrada de agua queda incorporada por PP y la pérdida de agua por HR, que está directamente relacionada a ET, mientras que la retrodispersión de la onda X aporta el efecto de la rugosidad del suelo.

Se debe destacar que los datos meteorológicos, podrían estar subestimando la variabilidad climática de la zona en estudio. El análisis de esta información indicaría que, de disponer una mayor

distribución espacial de la precipitación, temperatura del aire y humedad relativa así como también de un mejor índice de verdor, los resultados mejorarían. Sin embargo en este trabajo se muestra que es factible construir un modelo, aplicando un principio hidrológico simple a las imágenes SAR, que representa la dinámica de la HS en zonas de llanuras. Actualmente, se comenzó a explorar el método con nuevas misiones SAR cuyas longitudes de onda son más sensibles a HS y con mejor distribución de los datos meteorológicos.

Por otra parte, es necesario realizar un análisis más profundo de las características de los rastros en relación con el NDVI y de la representatividad de dicho índice en HS. Como así también debe investigarse la influencia de la variable  $\Delta T$  en HS ya que están físicamente relacionadas, sin embargo en este trabajo  $\Delta T$  no fue seleccionada como variable de entrada al modelo.

## Referencias

- Ahmad, S., Kalra A., Stephen, H. 2010. Estimating soil moisture using remote sensing data: A machine learning approach. *Advances in Water Resources*, 33(1), 69-80. doi:10.1016/j.advwatres.2009.10.008
- Baghdadi, N., Zribi, M., Loumagne, C., Ansart, P., Anguela, T. 2008. Analysis of Terra-SAR-X data and their sensitivity to soil surface parameters over bare agricultural fields. *Remote Sensing of Environment*, 112(12), 4370-4379. doi:10.1016/j.rse.2008.08.004
- Baghdadi, N., Aubert, M., Zribi, M. 2012. Use of TerraSAR-X Data to Retrieve Soil Moisture Over Bare Soil Agricultural Fields. *IEEE Geoscience and Remote Sensing Letters*, 9(3), 512-516. doi:10.1109/LGRS.2011.2173155
- Balenzano, A., Mattia, F., Satalino, G., Pauwels, V., Snoeij, P. 2012. SMOSAR algorithm for soil moisture retrieval using Sentinel-1 data. *Proceedings of the 2012 IEEE International Geoscience and Remote Sensing Symposium*, Munich, Germany, July 22-27, pp. 1200-1203. doi:10.1109/IGARSS.2012.6351332
- Brocca, L., Morbidelli, R., Melone, F., Moramarco, T. 2007. Soil moisture spatial variability in experimental areas of central Italy. *Journal of Hydrology*, 333(2-4), 356-373. doi:10.1016/j.jhydrol.2006.09.004
- Brogioni, M., Rodriguez, L., Graciani, S., Fontanelli, G., Muller C., Paloscia, S. 2014. Aplicación de Red Neuronal Artificial sobre imágenes SAR para determinar la humedad del suelo. En: *Memorias 2º Congreso Internacional de Hidrología de Llanuras*, Santa Fe, Argentina, 23-26 Sept.

- Burt, T., Butcher, D. 1985. Topographic controls of soil moisture distributions. *Journal of Soil Science*, 36(3), 469-486. doi:10.1111/j.1365-2389.1985.tb00351.x
- Cohen, J., Cohen, P., West, S., Aiken, L. 2003. *Applied Multiple Regression/Correlation Analysis for the Behavioral Sciences*. Third edition. Lawrence Erlbaum Associates, Inc., Publishers, Mahwah, NJ, USA.
- Downing, D., Clark J. 1997. *Statistics the Easy Way*. Third edition. Barron's E-Z. Barron's educational series. Easy Way Series, Inc., Huppauge, New York, U.S.
- Dubois, P.C., Zyl, J. van, Engman, T. 1995. Measuring soil moisture with imaging radars. *IEEE Transactions on Geoscience and Remote Sensing*, 33(4), 915-926. doi:10.1109/36.406677
- Engman, E., Chauman, N. 1995. Status of microwave soil moisture measurements with remote sensing. *Remote Sensing of Environment*, 51(1), 189-198. doi:10.1016/0034-4257(94)00074-W
- Forte Lay J., Scarpati, O., Capriolo A. 2008. Precipitation variability and soil water content in Pampean Flatlands (Argentina). *Geofisical International*, 47(4), 341-354.
- Fox, J. 2002. *An R and S-PLUS Companion to Applied Regression*. SAGE Publications. Inc. Thousand Oaks, CA, USA.
- Fung, A.K., Li, Z., Chen, K.S. 1992. Backscattering from a randomly rough dielectric surface. *IEEE Transactions on Geoscience and Remote Sensing*. 30(2), 356-369. doi:10.1109/36.134085
- Fung, A., 1994. *Microwave Scattering and Emission Models and their Applications*. Artech House, Inc., Norwood, USA.
- Glantz, S., Slinker, B. 1990. *Primer of Applied Regression and Analysis of Variance*. The McGraw-Hill Companies, Inc., New York, NY, USA.
- Grayson, R.B., Western, A.W., Chiew, F.H.S., Blöschl, G. 1997. Preferred states in spatial soil moisture patterns: local and nonlocal controls. *Water Resources Research*, 33(12), 2897-2908. doi:10.1029/97wr02174
- Harrell, F.E. 2001. *Regression Modeling Strategies: With Applications to Linear Models, Logistic Regression, and Survival Analysis*. Springer Series in Statistics. Springer-Verlag New York, Inc., New York, NY, USA. doi:10.1007/978-1-4757-3462-1
- Helsel, D., Hirsch, R. 2002. *Statistical Methods in Water Resources Techniques of Water Resources Investigations*, Book 4, Chapter A3. U.S. Geological Survey, 295-297.
- Kornelsen, K.C., Coulibaly, P. 2013. Advances in soil moisture retrieval from synthetic aperture radar hydrological applications. *Journal of Hydrology*, 476, 460-489. doi:10.1016/j.jhydrol.2012.10.044
- Kseneman, M., Gleich, D., Potočník, B. 2012. Soil-moisture estimation from TerraSAR-X data using neural networks. *Machine Vision and Applications*, 23(5), 937-952. doi:10.1007/s00138-011-0375-3
- Krepper C., Ventunini V. 2009. Assessing interannual water balance of La Plata river basin. *Atmósfera*, 22(4), 387-398.
- Lievens, H., Verhoest, N.E.C. 2012. Spatial and temporal soil moisture estimation from Radarsat-2 imagery over Flevoland, The Netherlands. *Journal of Hydrology*, 456-457, 44-56. doi:10.1016/j.jhydrol.2012.06.013
- Marquardt, D. 1970. Generalized inverses, ridge regression, biased linear estimation, and nonlinear estimation. *Technometrics*, 12(3), 591-612. doi:10.1080/00401706.1970.10488699
- Mattia, F., Satalino, G., Dente, L., Pasquariello, G. 2006. Using a priori information to improve soil moisture retrieval from ENVISAT ASAR AP data in semiarid regions. *IEEE Transactions on Geoscience and Remote Sensing*, 44(4), 900-912. doi:10.1109/TGRS.2005.863483
- Martínez García, G., Pachepsky, Y.A., Vereecken, H. 2014. Effect of soil hydraulic properties on the relationship between the spatial mean and variability of soil moisture. *Journal of Hydrology*, 516, 154-160. doi:10.1016/j.jhydrol.2014.01.069
- Montgomery, D., Peck, E. 1992. *Introduction to Linear Regression. Analysis*. Second edition. A Wiley-Inter science Publication. Wiley Series in Probability and Mathematical Statistics: Applied Probability and Statistics Section. John Wiley & Sons, Inc., New York, NY, USA.
- Notarnicola, C., Angiulli, M., Posa, F. 2008. Soil moisture retrieval from remotely sensed data: Neural network approach versus Bayesian method. *IEEE Transactions on Geoscience and Remote Sensing*, 46(2), 547-557. doi:10.1109/TGRS.2007.909951
- Oh, Y., Sarabandi, K., Ulaby, F.T. 1992. An empirical model and an inversion technique for radar scattering from bare soil surfaces. *IEEE Transactions on Geoscience and Remote Sensing*, 30(2), 370-381. doi:10.1109/36.134086
- Parton, W. 1984. Predicting soil temperatures in shortgrass steppe. *Soil Science*. 138(2), 93-101. doi:10.1097/00010694-198408000-00001
- Paloscia, S., Pampaloni, P., Pettinato, S., Santi, E. 2008. A Comparison of Algorithms for Retrieving Soil Moisture from ENVISAT/ASAR Images. *IEEE Transactions on Geoscience and Remote Sensing*, 46(10), 3274-3284. doi:10.1109/TGRS.2008.920370
- Paloscia, S., Pampaloni, P., Pettinato, S., Santi, E. 2010. Generation of soil moisture maps from ENVISAT/ASAR images in mountainous areas: a case study. *International Journal of Remote Sensing*, 31(9), 2265-2276. doi:10.1080/01431160902953891



- Pasolli, L., Notarnicola, C., Bruzzone, L., Bertoldi, G., Della Chiesa, S., Hell, V., Niedrist, G., Tappeiner, U., Zebisch, M., Del Frate, F., Vaglio Laurin, G. 2011. Estimation of Soil Moisture in an Alpine Catchment with RADARSAT2 Images. *Applied and Environmental Soil Science*, 2011(175473). doi:10.1155/2011/175473
- Pasolli, L., Notarnicola, C., Bruzzone, L. 2012. Multi-Objective Parameter Optimization in Support Vector Regression: General Formulation and Application to the Retrieval of Soil Moisture From Remote Sensing Data. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 5(5), 1495-1508. doi:10.1109/JSTARS.2012.2197178
- Pierdicca N., Pulvirenti L., Pace G. 2014. A Prototype Software Package to Retrieve Soil Moisture from Sentinel 1 Data by Using a Bayesian Multitemporal Algorithm. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 7(1), 153-166. doi:10.1109/JSTARS.2013.2257698
- Qiu, Y., Fu, B., Wang, J., Chen, L., Meng, Q., Zhang, Y. 2010. Spatial prediction of soil moisture content using multiple-linear regressions in a gully catchment of Loess Plateau, China. *Journal of Arid Environments*, 74(2), 208-220. doi:10.1016/j.jaridenv.2009.08.003
- Ranney, K.J., Niemann, J.D., Lehman, B.M., Green, T.R., Jones, A.S. 2015. A method to downscale soil moisture to fine resolutions using topographic, vegetation, and soil data. *Advances in Water Resources*, 76, 81-96. doi:10.1016/j.advwatres.2014.12.003
- Said, S., Kothyari, U., Arora, M., 2008. ANN-based soil moisture retrieval over bare and vegetated areas using ERS-2 SAR data. *Journal of Hydrologic Engineering*, 13(6), 461-475. doi:10.1061/(ASCE)1084-0699(2008)13:6(461)
- Shi, J., Wang, J., Hsu, A.Y., O'Neil, P.E., Engman, E.T. 1997. Estimation of bare surface soil moisture and surface roughness parameter using L-band SAR image data. *IEEE Transactions on Geoscience and Remote Sensing*. 35(5), 1254-1266. doi:10.1109/36.628792
- Takagi, K., Lin, H.S. 2011. Temporal dynamics of soil moisture spatial variability in the shale hills critical zone observatory. *Vadose Zone Journal*, 10(3), 832-842. doi:10.2136/vzj2010.0134
- Tromp-van Meerveld, H.J., McDonnell, J.J. 2006. On the interrelations between topography, soil depth, soil moisture, transpiration rates and species distribution at the hillslope scale. *Advances in Water Resources*, 29(2), 293-310. doi:10.1016/j.advwatres.2005.02.016
- Ulaby, F., Moore, R., Fung, A. 1982. *Microwave Remote Sensing, Active and Passive, Volume I: Radar Remote Sensing: Fundamentals and Radiometry*. Artech House, Inc. Norwood, USA.
- Western, A.W., Grayson, R.B., Blöschl, G., Willgoose, G., McMahon, T.A. 1999. Observed spatial organization of soil moisture and its relation to terrain indices. *Water Resources Research*, 35(3), 797-810. doi:10.1029/1998WR900065
- Weisberg, S. 2005. *Applied Linear Regression*, Third Edition. Hoboken NJ: Wiley. doi:10.1002/0471704091
- Zhu, Q., Lin, H. 2011. Influences of soil, terrain, and crop growth on soil moisture variation from transect to farm scales. *Geoderma*, 163(1-2), 45-54. doi:10.1016/j.geoderma.2011.03.015