

## **Modelos simples para estimar cobertura de suelo agrícola a partir de Imágenes MODIS: aplicación a la zona central de Córdoba (Argentina)**

Mónica Bocco<sup>1</sup>, Gustavo Ovando<sup>1</sup>, Silvina Sayago<sup>1</sup> y Enrique Willington<sup>1</sup>

<sup>1</sup> Facultad de Ciencias Agropecuarias, Universidad Nacional de Córdoba. Córdoba (Argentina).  
[mbocco@gmail.com](mailto:mbocco@gmail.com), [gugovan@gmail.com](mailto:gugovan@gmail.com), [silvinasayago@gmail.com](mailto:silvinasayago@gmail.com), [enriquewillington@gmail.com](mailto:enriquewillington@gmail.com)

**Resumen.** Las imágenes provenientes de sensores remotos constituyen una importante fuente de información sobre cultivos que puede utilizarse para obtener parámetros agronómicos. La soja (*Glycine max* (L.) Merrill) y el maíz (*Zea mays* L.) son los cultivos más importantes en Argentina, por área sembrada y réditos económicos producidos. En este trabajo se desarrollaron modelos matemáticos simples para evaluar porcentaje de cobertura de suelo por soja y maíz, a partir de diferentes índices de vegetación derivados del Moderate-resolution Imaging Spectroradiometer (MODIS). Los índices de vegetación considerados fueron: de diferencia normalizada (NDVI), Índice ajustado por el suelo SAVI, su modificación MSAVI, la Razón Simple (SR) y el índice perpendicular de vegetación (PVI). El comportamiento de los modelos fue muy bueno y los resultados mostraron que, excepto para SR, un modelo lineal puede predecir porcentaje de cobertura de suelo por soja y maíz, con valores de  $R^2 > 0,86$ .

**Palabras clave:** modelos, cultivos, índice de vegetación, MODIS.

### **1 Introducción**

La producción agrícola extensiva, en particular la de soja y maíz, es una de las principales actividades económicas y el principal uso del espacio rural en Argentina. Por esto, existe gran interés por estimar anticipadamente su volumen y posibles variaciones. Predecir la producción de granos requiere estimar la superficie sembrada con cada cultivo y su rendimiento; este último implica un gran desafío ya que presenta una gran variabilidad espacial y temporal a diferentes escalas [1].

La teledetección brinda información espacial extensiva del estado real de los cultivos, en particular los datos de satélites proveen una visión espacial y periódica del estado de los cultivos [2]. El Moderate-resolution Imaging Spectroradiometer (MODIS) con una resolución espacial de 250 m y una cobertura temporal diaria ofrece un gran potencial para la estimación de los parámetros biofísicos de un cultivo [3]. Las imágenes satelitales diarias, en una serie de tiempo continua, no siempre describen en forma precisa la condición de los cultivos durante la estación de crecimiento, dado que la nubosidad puede disminuir la calidad de distintos índices.

Consecuentemente, una solución trabajar con imágenes compuestas que ofrezcan como producto final datos tomados durante los días de menor contaminación por nubes [4].

Las características agronómicas y biofísicas de los cultivos, así como su productividad, pueden ser inferidos a partir de los datos de reflectancia espectral a través del cálculo de índices de vegetación (IV). Estas relaciones entre los IV y los parámetros del cultivo, como el índice de área foliar (IAF), porcentaje de cobertura, contenido de clorofila, biomasa, radiación fotosintéticamente activa absorbida, entre otras, son empíricas [5].

En la actualidad los IV desarrollados a partir de imágenes satelitales, pueden clasificarse dentro de dos categorías: los índices cocientes y los ortogonales. Entre los más comunes, a partir de transformaciones cocientes usadas para estimar el estado de la vegetación, están la Razón Simple (SR) que se obtiene dividiendo las reflectancias infrarroja cercana (NIR) y roja (Red) y el Índice de Vegetación de la Diferencia Normalizada (NDVI). EL Índice de Vegetación Perpendicular (PVI), desarrollado por [6], es uno de los más usuales entre los que involucran una transformación ortogonal en dos dimensiones.

La soja es el cultivo más importante en Argentina teniendo en cuenta el rendimiento obtenido por los productores y el área sembrada (18.671.000 ha en 2011–2012), seguido por el maíz con 5.000.300 ha. En particular, la provincia de Córdoba es la segunda productora de soja y maíz en Argentina con aproximadamente 5.014.250 ha y 1.272.000 ha en 2011–2012, respectivamente [7].

El objetivo de este trabajo fue ajustar modelos matemáticos simples, construidos a partir de índices de vegetación derivados de imágenes MODIS, para estimar porcentaje de cobertura de suelo por residuos de cultivos de soja y maíz. Se evaluó su aplicabilidad a la zona central de Córdoba (Argentina).

## **2 Materiales y métodos**

### **2.1 Área de estudio**

La zona de aplicación de los modelos es la llanura central de la provincia de Córdoba, Argentina (Figura 1), subregión conocida como “Pampa Alta”, la cual presenta un relieve de lomas muy extendidas, casi planas. Todos los suelos del área se clasifican como Haplustol éntico, con textura limosa gruesa, mineralogía mixta, de un régimen térmico de temperatura del suelo [8]; las precipitaciones promedio anuales son de 800 mm, aproximadamente, concentradas en verano. El clima en el área de estudio se clasifica como seco sub-húmedo. En esta zona los dos cultivos predominantes, en verano, son soja y maíz [2].

### **2.2 Datos a campo**

Los datos de cobertura de suelo por cultivo de soja y maíz (179 en total) fueron relevados continuamente a lo largo de la estación de crecimiento de ambos cultivos, en 33 lotes, los cuales son representativos de la zona por la homogeneidad y tipo de uso del suelo del área. Dado que en el área cultivada la relación entre los lotes sembrados de maíz con respecto a soja era, en el momento del estudio, del 26% [7], el número de lotes registrados para cada tipo de cultivo fue de 7 sembrados con maíz y 26 con soja. Todos los lotes comprendían un área mayor que 50 ha, a fin de ajustarse a la resolución del sensor MODIS.



**Fig. 1.** Área de estudio en Córdoba, Argentina (Imagen LANDSAT). Marcas amarillas indican los lotes relevados. Figura adaptada de [2].

En esta región, la producción agrícola es principalmente en secano. La soja es sembrada por siembra directa con un espaciamiento entre surcos de 35cm, corresponde a grupos de madurez 3 y 4 y variedades transgénicas resistentes al glifosato, sin aplicación de fertilizante [9]. El maíz es sembrado entre finales de octubre y principios de noviembre, también por siembra directa con una distancia de 53 cm (aproximadamente) entre surcos y una densidad promedio de 76.000 plantas/ha [10].

En esta zona de estudio, la soja y el maíz muestran una distribución uniforme, por lo cual para cada lote tres fotografías digitales verticales a 1,5 m de altura se usaron para estimar el porcentaje de cobertura (fCover) [2]. Estas fotografías se clasificaron, usando el algoritmo máxima verosimilitud, en dos clases: vegetación verde y suelo (Figura 2).

### 2.3 Datos satelitales

Para cubrir el período en estudio se utilizaron once imágenes provenientes del satélite AQUA haciéndolas corresponder al día de adquisición de datos a campo. Estas

imágenes provinieron de MODIS-MYD13Q1/Aqua 16-Day integrated L3 Global 250 m SIN Grid, Tile h12v12 y fueron obtenidas por el Land Processes Distributed Active Archive Center (LPDAAC)-US Geological Survey (USGS) for Earth Resources Observation and Science (EROS) Data Center.

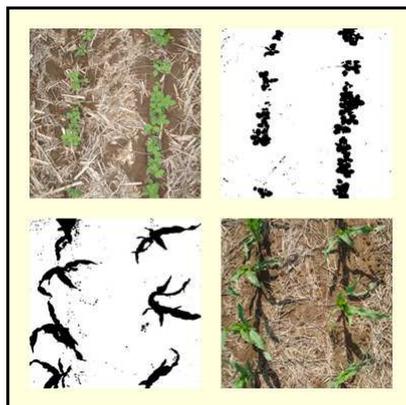


Fig. 2. Fotos digitales de cultivos de soja y maíz y sus correspondientes imágenes clasificadas en suelo y vegetación verde.

Como el propósito del trabajo fue desarrollar un modelo para la estimación remota del porcentaje de cobertura por vegetación verde, se consideraron las reflectancias de MODIS roja (Red, 620–670 nm) e infrarroja cercana (NIR, 841–876 nm), para los píxeles centrales en cada uno de los 33 lotes.

## 2.4 Índices de vegetación

El NDVI definido como:

$$NDVI = \frac{NIR - Red}{NIR + Red} \quad (1)$$

es un indicador de la densidad de cobertura de la vegetación y del crecimiento integral del cultivo [11]. Numerosos estudios han mostrado que este índice se satura si la densidad del cultivo es alta [12] y puede ser inestable, variando con el suelo, las condiciones atmosféricas y/o presencia de rastrojo. Por lo cual muchos investigadores han intentado corregirlo de modo que se consideren variaciones de suelo y atmosféricas [13].

La Razón Simple (SR) y el Índice de Vegetación Ajustado por Suelo (SAVI) se definen como:

$$SR = \frac{NIR}{Red} \quad (2)$$

$$SAVI = \frac{NIR - Red}{NIR + Red + L}(1 + L) \quad (3)$$

donde  $L$  es una constante determinada empíricamente ( $L \approx 0,5$  para rangos intermedios de cobertura de vegetación) que minimiza el efecto del suelo [14].

El índice MSAVI (un SAVI modificado) y el Índice Perpendicular de Vegetación (PVI) se definen a través de una función que considera el efecto del suelo [15-16]:

$$MSAVI = \frac{2NIR + 1 - \sqrt{(2NIR + 1)^2 - 8(NIR - Red)}}{2} \quad (4)$$

$$PVI = \frac{NIR - a_1 Red - a_0}{\sqrt{1 + a_1^2}} \quad (5)$$

donde  $a_0$  y  $a_1$  son la ordenada y la pendiente, respectivamente, de la línea de suelo desnudo.

## 2.5 Modelos

Se desarrollaron tres modelos matemáticos simples: lineal (6), cuadrático (7) y exponencial (8), cuyas fórmulas generales son:

$$fCover(VI) = a + bVI \quad (6)$$

$$fCover(VI) = a + bVI + cVI^2 \quad (7)$$

$$fCover(VI) = a + b \exp(cVI) \quad (8)$$

donde  $a$ ,  $b$  y  $c$  son los coeficientes de cada modelo y las variables independientes consideradas fueron los índices de vegetación: NDVI, SR, SAVI, MSAVI y PVI. Por lo cual de la combinación de los tres tipos de ecuaciones con los cinco IV, quedaron determinados quince modelos.

El coeficiente de determinación ( $R^2$ ) y la raíz del error medio cuadrático (RMSE) entre los valores de porcentaje de cobertura observados y estimados, fueron los estadísticos usados para la evaluación y validación de los modelos.

## 3 Resultados y discusión

Para todos los lotes y registros, el porcentaje de cobertura de suelo por vegetación verde varió entre 0 y 98%. La Tabla 1 muestra los valores de los coeficientes de

determinación ( $R^2$ ) para los modelos utilizados; en la misma se observa que, en general, todos los modelos tienen un buen desempeño para todos los IV usados.

**Tabla 1.** Coeficientes de las funciones que modelizan porcentaje de cobertura por soja y/o maíz a partir de diferentes índices de vegetación y valores de los coeficientes de determinación.

Modelos	Índice de Vegetación	Coeficientes			$R^2$
		<i>a</i>	<i>b</i>	<i>c</i>	
Lineal	NDVI	-33,348	131,439		0,88
Cuadrático		-12,692	36,921*	87,477	0,88
Exponencial		-70,6959	53,1947	1,2379	0,88
Lineal	SR	5,908	5,225		0,68
Cuadrático		-15,674	13,854	-0,412	0,85
Exponencial		91,4525	-132,07	-0,2361	0,89
Lineal	SAVI	-25,273	169,223		0,89
Cuadrático		-33,132	219,350	-61,516	0,89
Exponencial		297,632	-330,715	-0,669*	0,89
Lineal	MSAVI	-16,731	146,620		0,88
Cuadrático		-31,482	242,534	-110,83	0,89
Exponencial		-1350,78*	1335,21*	0,10*	0,87
Lineal	PVI	5,003	343,227		0,87
Cuadrático		1,102*	520,264	-710,54	0,89
Exponencial		138,365	-164,470	-3,909	0,90

Símbolo \* indica que los coeficientes no son estadísticamente significativos ( $p < 0,05$ ).

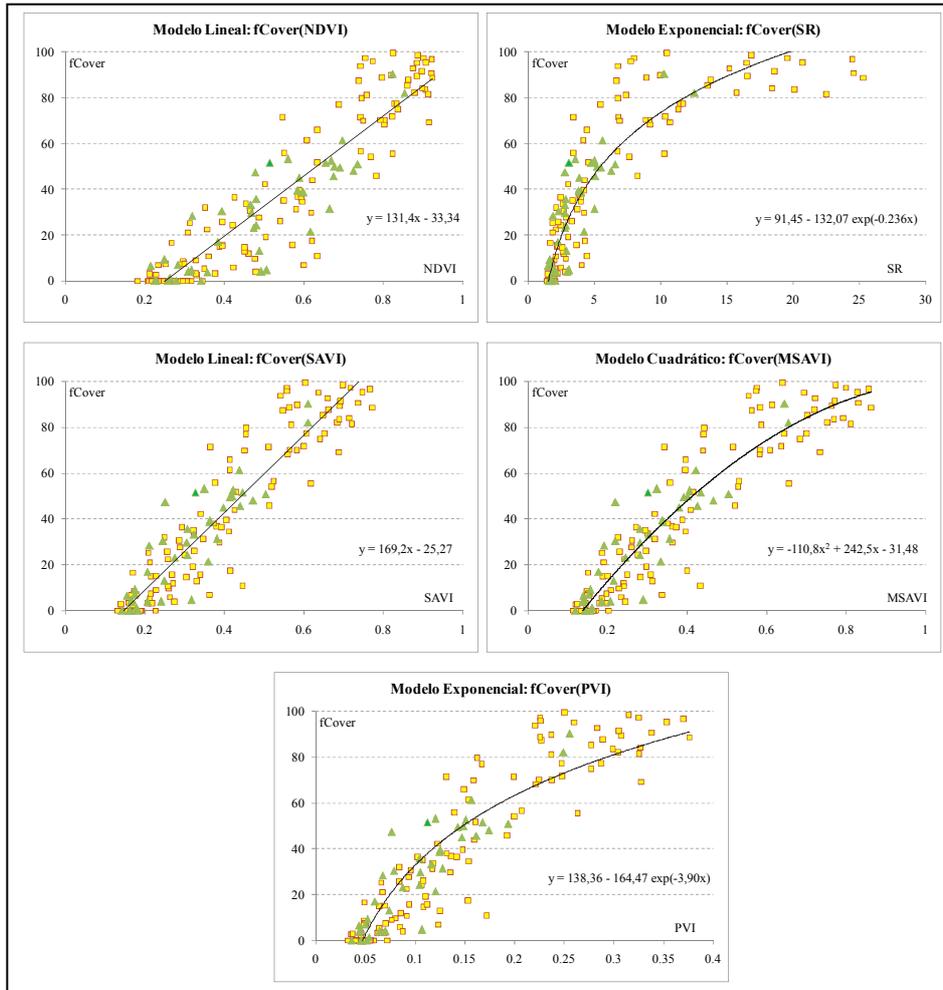
Analizando los resultados se puede concluir que, debido a su simplicidad y el valor de los estadísticos de ajuste obtenidos, los modelos lineales son apropiados para casi todos los índices y podrían siempre considerarse como buenos estimadores de fCover. No obstante, el modelo que considera como entrada el SR, presenta mejor ajuste con las ecuaciones cuadrática y exponencial.

Los coeficientes de determinación obtenidos en nuestro estudio son similares a los reportados por [17], quienes correlacionaron varios índices de vegetación (NDVI, SAVI, y MSAVI) calculados con datos hiperspectrales de Compact Airborne Spectrographic Imager (CASI) con fracciones de cobertura medidas para maíz, soja y trigo. En su trabajo encontraron correlaciones que alcanzan  $R^2 = 0,90$ . González-Dugo y Mateos [18] también encontraron una relación lineal entre cobertura de suelo y SAVI, para campos comerciales de algodón y remolacha azucarera a partir de datos satelitales, estos autores observaron que la relación entre fCover y el IV, cuando el cultivo ha crecido, es más sensible a errores si se utiliza NDVI en lugar del SAVI, es variable de entrada. Con este último índice obtuvieron para los modelos considerados un valor de  $R^2 = 0,89$ .

La Fig. 3 muestra los modelos que ajustan las relaciones entre cobertura por maíz o soja, y el IV, para el mejor coeficiente de determinación obtenido.

Los errores entre fCover estimada y observada fueron cuantificados usando RMSE. Para el modelo lineal, los valores de este estadístico fueron de 11,7% y 10,7% cuando NDVI y SAVI se consideraron como variables de entrada, respectivamente. El

modelo cuadrático, usando MSAVI, presentó RMSE = 10,3 % y para la ecuación exponencial, considerando PVI y SR como variables, se obtuvieron valores de 10,6% y 11,0%, respectivamente.



**Fig. 3.** Mejores funciones de ajuste para porcentaje de cobertura estimada en función de los distintos índices (NDVI – SR – SAVI – MSAVI - PVI) para cultivos de soja (■) y maíz (▲).

Zhang *et al.* [19] cuando estimaron cobertura de pasturas en Canadá, a partir de un modelo lineal con variable de entrada NDVI, obtenido de LANDSAT 5 TM, reportaron  $R^2 = 0,55$  y  $RMSE = 5,71\%$ . Aunque el modelo lineal usando NDVI obtenido a partir de imágenes de un sensor con menor resolución espacial, en nuestro trabajo presentó un valor de RMSE más alto, el valor del coeficiente de determinación fue en cambio mayor ( $R^2 = 0,88$ ).

Para diferentes cultivos en España, Jiménez-Muñoz *et al.* [20] estimaron la cobertura con valores de RMSE entre 13% y 19% mediante modelos lineales y utilizando NDVI a partir de CHRIS/Proba.

## 4 Conclusiones

Modelos matemáticos simples permiten describir adecuadamente el porcentaje de cobertura de suelo por soja y maíz a partir de índices de vegetación, obtenidos de las reflectancias roja y NIR del sensor MODIS.

Utilizando modelos lineales con NDVI, MSAVI, SAVI y PVI, que presentan la ventaja práctica de simplicidad y buena precisión, se obtienen los mejores estadísticos para las estimaciones de cobertura, mientras que para SR el mejor ajuste se logra con un modelo exponencial.

**Agradecimientos.** Los autores expresan su gratitud a la Secretaría de Ciencia y Técnica – Universidad Nacional de Córdoba - Argentina (Secyt-UNC) por el apoyo financiero que permitió la realización de este trabajo.

## Referencias

1. Hansen, J. W., Indeje, M.: Linking dynamic seasonal climate forecasts with crop simulation for maize yield prediction in semi-arid Kenya. *Agricultural and Forest Meteorology*, 125, 143--157 (2004).
2. Bocco, M., Ovando, G., Sayago, S., Willington, E., Heredia, S.: Estimating soybean ground cover from satellite images using neural networks models. *International Journal of Remote Sensing*, 33(6), 1717--1728 (2012)
3. Doraiswamy, P.C., Hatfield, J.L., Jackson, T.J., Akhmedov, B., Prueger, J., Stern, A.: Crop condition and yield simulation using LANDSAT and MODIS. *Remote Sensing of Environment*, 91, 548--559 (2004)
4. Báez-González, A.D., Chen, P.Y., Tiscareño-López, M., Srinivasan, R.: Using satellite and field data with crop growth modeling to monitor and estimate corn yield in Mexico. *Crop Science*, 42, 1943--1949 (2002)
5. Liu, W., Gao, W., Gao, Z., Wan, X.: Correlation analysis between the biomass of oasis ecosystem and the vegetation index at Fukang. In: *Remote Sensing and Modeling of Ecosystems for Sustainability III*, SPIE, pp. 1--7. San Diego, California, USA (2006), <http://uvb.nrel.colostate.edu/UVB/publications/BiomassatFukang.pdf>
6. Richardson, A.J., Wiegand, C.L.: Distinguishing vegetation from soil background information. *Photogrammetric Engineering and Remote Sensing*, 43, 1541--1552 (1977)
7. MAGyP.: Producción, área sembrada y cosechada, cotizaciones nacionales e internacionales. Ministerio de Agricultura, Ganadería y Pesca, Presidencia de la Nación, Argentina, (2013), <http://www.siiia.gov.ar/index.php/series-por-tema/agricultura>
8. Agencia Córdoba Ambiente e Instituto Nacional de Tecnología Agropecuaria: Los suelos. Ed. Gobierno de la Provincia de Córdoba. (2006)
9. Piatti, F., Ferreira, L.: Evaluación de cultivares comerciales de soja. Campaña 2008/09. Cartilla Digital Manfredi-INTA-EEA (2009), <http://agrolluvia.com/wp-content/uploads/2010/02/eea-inta-manfredi-evaluacion-de-cultivares-comerciales-de-soja-2008-2009.pdf>

10. Piatti, F., Ferreira L.: Ensayos comparativos de rendimiento de maíz: Red interna de INTA Manfredi, campaña 2007-08. Cartilla Digital Manfredi-INTA- EEA (2008), <http://agrolluvia.com/wp-content/uploads/2010/03/eea-manfredi-ensayos-comparativos-de-rendimiento-de-maiz-red-interna-campana-2007-08.pdf>
11. D'Urso, G., Richter, K., Calera, A., Osann, M. A., Escadafal, R., Garatuza-Pajan, J., Hanich, L., Perdigão, A., Tapia, J.B., Vuolo, F.: Earth Observation products for operational irrigation management in the context of the PLEIADeS project. *Agricultural Water Management*, 98, 271--282 (2010)
12. Srinivas, P., Das, B.K., Saibaba, J., Krishnan, R.: Application of distance based vegetation index for agricultural crops discrimination. In: XXth ISPRS Congress, pp.1. Istanbul, Turkey (2004), <http://www.isprs.org/proceedings/XXXV/congress/comm7/papers/215.pdf>
13. Huete, A.R., Liu, H.Q.: An Error and Sensitivity Analysis of The Atmospheric-Correcting and Soil-Correcting Variants of the NDVI For The Modis-Eos. *IEEE Transactions on Geoscience and Remote Sensing*, 32, 897--905 (1994)
14. Zhang, J., Zhang, L., Zhang, M., Watson, C.: Prediction of soybean growth and development using artificial Neural Network and statistical models. *Acta Agronomica Sinica*, 35, 341--347 (2009)
15. Qi, J., Chehbouni, A., Huete, A.R., Kerr, Y.H., Sorooshian, S.: A modified soil adjusted vegetation index. *Remote Sensing of Environment*, 48, 119--126 (1994)
16. Maas, S., Rajan, N.: Estimating ground cover of field crops using medium-resolution multispectral satellite imagery. *Agronomy Journal*, 100, 320--327 (2008)
17. Liu, J., Miller, J. R., Haboudane, D., Pattey, E., Hochheim, K.: Crop fraction estimation from *casi* hyperspectral data using linear spectral unmixing and vegetation indices. *Canadian Journal of Remote Sensing*, 34: S124--S138 (2008)
18. González-Dugo, M.P., Mateos, L.: Spectral vegetation indices for benchmarking water productivity of irrigated cotton and sugarbeet crops. *Agricultural Water Management*, 95, 48--58 (2008)
19. Zhang, Y., Smith, A.M., Hill, M.J.: Estimating fractional cover of grassland components from two satellite remote sensing sensors. In: 34th International Symposium on Remote Sensing of Environment, pp. 1. Sydney, Australia (2011), <http://www.isprs.org/proceedings/2011/isrse-34/211104015Final00252.pdf>
20. Jiménez-Muñoz, J.C., Sobrino, J.A., Plaza, A., Guanter, L., Moreno, J., Martínez, P.: Comparison between fractional vegetation cover retrievals from vegetation indices and spectral mixture analysis: Case study of PROBA/CHRIS data over an agricultural area. *Sensors*, 9, 768--793 (2009)