



RIA. Revista de Investigaciones Agropecuarias

ISSN: 0325-8718

ISSN: 1669-2314

revista.ria@inta.gob.ar

Instituto Nacional de Tecnología Agropecuaria

Argentina

Frolla, Franco; Zilio, J.P.; Kruger, H.

Selección de bandas e índices espectrales relacionados con la profundidad efectiva de los suelos en la región Pampeana Austral de Argentina

RIA. Revista de Investigaciones Agropecuarias, vol. 46, núm. 3, 2020, Septiembre-, pp. 404-413

Instituto Nacional de Tecnología Agropecuaria
Argentina

Disponible en: <https://www.redalyc.org/articulo.oa?id=86465821015>

- Cómo citar el artículo
- Número completo
- Más información del artículo
- Página de la revista en redalyc.org

UAEM  redalyc.org

Sistema de Información Científica Redalyc

Red de Revistas Científicas de América Latina y el Caribe, España y Portugal

Proyecto académico sin fines de lucro, desarrollado bajo la iniciativa de acceso abierto

Selección de bandas e índices espectrales relacionados con la profundidad efectiva de los suelos en la región Pampeana Austral de Argentina

FROLLA, F.D.¹; ZILIO, J.P.¹; KRUGER, H.¹

RESUMEN

El sudoeste de la provincia de Buenos Aires (Argentina) se caracteriza por la presencia de un horizonte subsuperficial calcáreo que limita la exploración radical de los cultivos y la captación de agua. El objetivo del trabajo fue plantear y validar una metodología para la selección de imágenes satelitales que permitan detectar la variación espacial de la profundidad del suelo. Se utilizaron 180 a 190 capas de información derivadas de bandas e índices espectrales del satélite LANDSAT 5 TM durante el período 1992-2011, provenientes de seis campos de producción agrícola-ganadera. En dichos campos se realizaron observaciones de profundidad efectiva del suelo (PES) y se seleccionaron las escenas que presentaron mayor correlación. El modelo se validó utilizando un conjunto independiente de datos e índices de error (RMSE, MAE y R^2). No se observó una banda o índice con mayor ajuste a los restantes en todos los sitios y fechas. Sitios con mayor proporción de suelos someros y valores distribuidos en el rango 0-100 cm obtuvieron los mayores coeficientes R^2 . La utilización de una larga serie histórica del satélite LANDSAT 5 TM con la metodología propuesta permitió la identificación y selección de imágenes de buena correlación con la PES.

Palabras clave: profundidad de suelos, agricultura de precisión, teledetección, Landsat, R.

ABSTRACT

The Pampeana Region, in the southwest of the Buenos Aires province (Argentina), is characterized by the presence of a calcareous subsurface horizon with limiting water retention capacity and root penetration. The objective of the work was to propose and validate a methodology for the selection of satellite images scenes showing high correlation between reflectance and soil depth spatial variation. Six fields under agricultural-livestock production were studied. For them 180-190 layers of information were derived from bands and spectral indices of LANDSAT 5 TM satellite for 1992-2011 periods. In these fields, observations of effective soil depth (PES) were made and scenes showing the highest correlation between reflectance and PES were selected. The model was validated using an independent dataset and error indexes (RMSE, MAE and R^2). No supremacy of any band or index was observed across the sites and dates. Sites with low relative PES and values well distributed in the 0-100 cm range obtained higher R^2 coefficients. The review of long series of satellite LANDSAT 5 TM images using the proposed methodology allowed the identification and selection of scenes with a good reflectance/PES correlation.

Keywords: soil depth, precision agriculture, remote sensing, Landsat, R.

¹Instituto Nacional de Tecnología Agropecuaria (INTA), Estación Experimental Agropecuaria (EEA) Bordenave, Ruta 76 km 36,5, Bordenave, Argentina. Correo electrónico: frolla.franco@inta.gob.ar

INTRODUCCIÓN

La región Pampeana argentina comprende 50 millones de hectáreas y es considerada una de las zonas de mayor producción de granos y forrajes en el mundo (Satorre y Slafer, 1999). Su sector meridional denominado Pampa Austral por Viglizzo *et al.* (2003), de unas cuatro millones de hectáreas, se caracteriza por la presencia de un horizonte subsuperficial calcáreo con distintos grados de cementación (Pazos y Mestelan, 2002). Esta capa recibe distintas denominaciones ("tosca", "caliche", "calcrete") y limita la capacidad de retención de agua, la exploración radical de los cultivos y su rendimiento (Sadrás y Calviño, 2001). También afecta negativamente la disponibilidad de algunos nutrientes como fósforo (Salih *et al.*, 1989) y hierro (Volmer Buffa y Ratto, 2005). Su influencia resulta de mayor importancia en la porción sudoeste de dicha región, por tratarse de un ambiente semiárido donde la disponibilidad de agua suele ser el principal factor limitante de la producción. Los efectos negativos sobre los cultivos varían, en oportunidad y magnitud, en función de la interacción entre la profundidad de dicho horizonte, el contenido de agua del suelo y la distribución de las precipitaciones. Investigaciones previas han mostrado variaciones significativas de los rendimientos de cultivos de verano (Sadrás y Calviño, 2001) y de invierno en función de la profundidad efectiva del suelo (PES), estableciéndose para el área de estudio un umbral de 40-50 cm para lotes de producción agrícola (Bravo *et al.*, 2004; Krüger *et al.*, 2018).

La cartografía de la PES en campos de producción resulta útil para delimitar ambientes de manejo diferencial. Frolla *et al.* (2015) determinaron que observaciones georreferenciadas en forma de grilla, con densidades entre 0,5 y 2 obs ha⁻¹ produjeron mapas con un detalle adecuado a este objetivo, otros estudios indican densidades superiores para lograr relaciones con el rendimiento de los cultivos (Ross, 2012). Para la realización de mapas se requiere un importante trabajo de campo y sus resultados pueden variar en función de la autocorrelación de los datos recolectados. En situaciones de relieve normal, con transiciones bajo-loma, los modelos geoestadísticos ofrecen alta autocorrelación e interpolaciones correctas, con buenos ajustes a los puntos de validación. En lotes con relieve plano o subnormal, la distribución espacial de la profundidad del suelo puede ser extremadamente variable y con transiciones bruscas, por lo que resulta difícil de predecir por los métodos cartográficos tradicionales (Krüger y Venanzi, 2009). Si bien el mapeo es realizado una sola vez, el trabajo que requiere los muestreos limita su uso en gran escala. La utilización de sensores que permitan asociar datos espaciales a la profundidad de suelos pueden ayudar a determinar de forma más sencilla la variabilidad de la profundidad de los suelos (Ross, 2012). Castro Franco *et al.* (2017) lograron grandes avances en este aspecto, aunque los equipamientos utilizados (rastra de conductividad eléctrica, GNSS topo geográfico) no siempre están disponibles en la región y presentan un costo adicional para su uso, traslado e interpretación de resultados.

La detección de suelos someros puede apoyarse en el uso de imágenes satelitales, las cuales pueden obtener-

se de forma gratuita. En la región semiárida bonaerense los índices ópticos NDVI y GNDVI permitieron diferenciar la profundidad efectiva del suelo durante la etapa de floración del cultivo de trigo (Frolla *et al.*, 2017). Sin embargo, no todas las imágenes resultaron efectivas para este propósito. Esta relación índice espectral-PES se cumplió en algunos años en que coincidieron precipitaciones mayores a las normales durante el período previo al cultivo (barbecho) con precipitaciones menores a las normales durante el ciclo del cultivo. Esta afirmación es válida para cultivos de cosecha invernales (trigo, cebada), pero no contempla aquellos casos donde se realicen cultivos de verano de cosecha (maíz, soja) o cultivos para forraje (avena, centeno) pudiendo existir otras fechas más apropiadas en función del historial del lote y las condiciones climáticas. En otros casos puede no contarse con información detallada del historial del lote requiriendo metodologías apropiadas para dichas situaciones.

La disponibilidad gratuita de largas series históricas de imágenes satelitales multispectrales como las de misiones LANDSAT (U.S. Geological Survey) ofrece información que puede ser utilizada para caracterizar los suelos, por lo que es una herramienta ampliamente difundida en la confección de mapas digitales de suelo (Boettinger *et al.*, 2008). Las misiones LANDSAT presentan una cobertura temporal desde 1984 al presente con un tiempo de revisita de 16 días, pudiendo consultar información en distintas épocas del año donde ocurren distintos cultivos y manejos. A su vez, lenguajes de programación libres como R (R core team, 2017) permiten una fácil interacción con grandes volúmenes de información, automatizando la consulta de estas y la generación de informes apropiados (Matloff, 2011).

Dado que en largas series históricas de imágenes satelitales solo algunas fechas, bandas e índices expresan atributos relacionados con la PES, se hipotetiza que el desarrollo de un programa que automatice las búsquedas en grandes volúmenes de información permitirá detectar las mejores imágenes que presenten relación con la PES. El objetivo es plantear y validar una metodología sencilla, económica y automática para la selección de dichas imágenes, utilizando un conjunto reducido de observaciones de PES, una biblioteca de imágenes LANDSAT relativamente amplia y algoritmos e interfaces gráficas en lenguaje R que permitan lograr mapas de profundidad de suelos de una precisión igual o superior a mapas convencionales utilizando un menor número de observaciones.

MATERIALES Y MÉTODOS

Metodología para la selección de imágenes

La secuencia de pasos seguida para la selección de aquellas bandas/índices del satélite LANDSAT 5 TM más correlacionadas con la PES incluyó: 1) obtención en el sitio para estudiar de un conjunto de 15 a 30 observaciones georreferenciadas de PES, distribuidas en un rango de 0 a 100 cm que representa los valores más comunes en la región. 2) Conformación de una biblioteca de imágenes

LANDSAT incluyendo el área general de estudio y descompuesta en sus distintas fechas, bandas e índices obtenidos a partir de ellas (NDVI, SAVI entre otros). 3) Análisis de regresión lineal entre los valores de PES y de reflectancia correspondientes a las observaciones realizadas en cada una de las escenas de la biblioteca disponible. El procesamiento de los datos se automatizó mediante el desarrollo de un programa que permite, a partir de la biblioteca de imágenes satelitales, el recorte del sitio para estudiar, la generación de índices espectrales y la selección de aquellas bandas o índices espectrales con mayor valor del coeficiente de determinación R^2 a partir del modelo PES/reflectancia. Su único requerimiento es el ingreso de un polígono con el contorno del sitio de estudio y la información de latitud, longitud y profundidad de los puntos de entrenamiento/validación. La figura 1 muestra la interfaz gráfica del usuario y la salida de datos del programa diseñado para el análisis y selección de imágenes. Los requisitos para su uso consisten en tener instalado R y previamente descargar los paquetes requeridos, desde la interfaz gráfica se permite la descarga automática de los paquetes. El código puede descargarse del siguiente enlace: https://www.dropbox.com/s/m45xedn3ytjhoig/regresion_mapas.R?dl=0

Se analizó la relación entre la PES y la reflectancia con seis bandas del satélite Landsat 5 TM (bandas 1, 2, 3, 4, 5 y 7) y cuatro índices espectrales derivados de las anteriores, en 18 fechas en el path/row 227-86 y 19 fechas en el 227-87, abarcando el periodo 1992-2011. Fueron analizadas

entre 180 y 190 capas de información para cada sitio. Las escenas, con nivel de preprocesamiento L1TP, se descargaron desde el sitio web “Earth Explorer” del Servicio de Geología de los Estados Unidos, seleccionando imágenes con una nubosidad menor al 10%. Los valores de brillo del sensor, para cada banda y fecha, fueron transformados a reflectancia de superficie con correcciones atmosféricas por el método de DOS1 mediante el paquete “Semi-Automatic Classification Plugin” para el software QGIS (Congedo, 2016).

Se confeccionaron polígonos para cada sitio que fueron utilizados para recortar las bandas seleccionadas en cada fecha. Obtenido el corte de bandas, se calcularon distintos índices espectrales, índices relacionados con los niveles de biomasa de los cultivos: Índice Normalizado de Diferencia de Vegetación (NDVI) (ecuación 1) ampliamente utilizado para la detección de vegetación, producción de biomasa, diversidad y estrés hídrico (Nagendra *et al.*, 2013; Birtwistle *et al.*, 2016) e Índice de Vegetación de Suelo Ajustado (SAVI) (ecuación 2), modificación del NDVI que reduce los efectos de suelos desnudos o con baja cobertura ($L = 0,5$) utilizado para cartografía de vegetación en áreas áridas y semiáridas (Huete, 1988).

Mayores contenidos de CaCO_3 en la matriz del suelo generan una mayor reflectancia del suelo (Cierniewski y Uśnerek, 2010). Por lo cual se evaluaron índices más apropiados para suelos descubiertos, bajo labranza, o muy escasos de vegetación como lo ocurrido durante la




Figura 1. Vista de la interfaz gráfica de usuario y análisis de datos mediante la metodología propuesta.

sequía del periodo 2008-2009: CALC (ecuación 3) índice propuesto por Boettinger *et al.* (2008) para detección de sedimentos calcáreos y, VISIBLE, una sumatoria de bandas del espectro visible similar al "Índice de brillo" utilizado en otros trabajos (Ray *et al.*, 2004), pero de mayor facilidad de cálculo.

$$\text{NDVI} = (B4 - B3) / (B4 + B3) \text{ (Ecuación 1)}$$

$$\text{SAVI} = (1 + L) (B4 - B3) / (B4 + B3 + L) \text{ (Ecuación 2)}$$

$$\text{CALC} = (B5 - B2) / (B5 + B2) \text{ (Ecuación 3)}$$

$$\text{VISIBLE} = (B1 + B2 + B3) \text{ (Ecuación 4)}$$

Donde B1, B2, B3, B4, B5 y B7 corresponden a las bandas y longitudes de onda: 1 (0,45-0,52 μm), 2 (0,52-0,60 μm), 3 (0,63-0,69 μm), 4 (0,76-0,90 μm), 5 (1,55-1,75 μm) y 7 (2,08-2,35 μm) representando en el espectro electromagnético (en el orden que aparecen) el azul, verde, rojo, infrarrojo cercano e infrarrojo medio.

Validación de la metodología

Se estudió la profundidad efectiva del suelo en seis campos de producción agropecuaria, en el partido de Púan, al sudoeste de la provincia de Buenos Aires (figura 2). Los sitios A1, TG1 y A2 alternan ganadería y agricultura, mientras que los restantes (SG1, SG2 y SG3) conforman sistemas agrícolas puros.

Entre los años 2012 y 2018 se realizaron observaciones de la PES mediante el método de grilla y sonda mecánica, con un número de observaciones variable entre 0,6 y 2,2 obs ha^{-1} . Los datos fueron procesados para la eliminación de outliers e inliers según describe Córdoba *et al.* (2014), con posterior confección de semivariogramas omnidireccionales e interpolación por método de Kriging ordinario para elaborar mapas de profundidad efectiva en TG1, SG1, SG2 y SG3. Por falta de autocorrelación e imposibilidad de modelar el semivariograma, para la elaboración de los mapas en A1 y A2 se utilizó una interpolación por distancia inversa ponderada con exponente 2. A partir de los datos del muestreo de suelos, se calcularon histogramas descriptivos para cada sitio, con clases discretas de 20 cm por clase. Posteriormente se dividieron aleatoriamente los datos en partes iguales, obteniéndose un conjunto para entrenamiento de los modelos estadísticos y otro para la validación de estos.

Las relaciones se establecieron mediante regresión lineal utilizando la profundidad observada en los puntos de entrenamiento y los valores de reflectancia de las bandas en cada fecha y de los índices espectrales. El conjunto de datos tomados para el entrenamiento varió en función de la superficie y cantidad total de observaciones en cada lote. Las imágenes fueron ordenadas de mayor a menor según el coeficiente de determinación (R^2) eliminando aquellas regresiones no significativas ($p < 0,05$). El modelo con el mayor R^2 fue utilizado para la predicción de los valores de profundidad correspondiente a los puntos de validación.




Figura 2. Localización de los sitios experimentales y distribución de los puntos de entrenamiento (amarillo) y validación (rojo).

Para chequear el ajuste de cada modelo, además del R^2 de la etapa de validación, se seleccionaron el error de la raíz cuadrada de la media (RMSE) y el error absoluto medio (MSE) (Chai y Draxler, 2014).

En la automatización de las diversas tareas mencionadas se utilizaron distintos paquetes del software R: sp (Pebesma y Bivand, 2005), geoR (Ribeiro y Diggle, 2016), raster (Hijmans, 2016), rgdal (Bivand *et al.*, 2014) y metrics (Hamneret *et al.*, 2012), combinados mediante un programa "ad hoc".

RESULTADOS

La figura 3 muestra histogramas de las PES obtenidas en cada uno de los sitios de estudio. Los sitios A1 y A2 presentaron un bajo porcentaje de suelos inferiores a 40 cm. En TG1 se observó dispersión de profundidades con la mayor proporción de valores superiores a 90 cm. En SG1, SG2 y SG3 se observó una mayor proporción de suelos someros (<40 cm) y presencia de suelos muy someros (<20 cm).

En cada lote se seleccionaron las escenas con mayor coeficiente R^2 para las regresiones entre PES, reflectancia e índices (tabla 1), para el mes de septiembre no se encontraron imágenes libres de nubosidad por lo que no hubo información para dicho mes. La tabla muestra, ade-

más, los indicadores de desempeño utilizados en la etapa de validación.

En A1, 18 capas presentaron relaciones significativas con la PES ($p < 0,05$) con coeficientes R^2 en el rango de (0,21-0,47). El mejor modelo fue observado para la banda 5 en la fecha 30-11-2008 (figura 4), sin relación significativa para otras fechas. El índice VISIBLE fue el que presentó mayor cantidad de modelos (cinco) con relaciones significativas para distintas fechas ($R^2 = 0,21-0,28$). Las bandas 1, 2, 3, 4, 7 y los índices NDVI y SAVI mostraron por lo menos una fecha con relación significativa.

Para A2 solo la banda 4 en la fecha 29/08/2003 presentó relación con la PES, aunque con un bajo coeficiente R^2 y bajos valores de RMSE y MSE.

TG1 obtuvo relaciones significativas en 93 capas de información, las máximas correlaciones se observaron con el índice CALC ($R^2 = 0,39$) para el 19/10/2010 (figura 5), seguido por la banda 3 ($R^2 = 0,34$) y VISIBLE ($R^2 = 0,31$). Las bandas con información del espectro infrarrojo quedaron relegadas a posiciones de menor importancia, la banda 7 se colocó en el puesto cinco en orden de importancia ($R^2 = 0,29$) seguido por la banda 5 en el puesto 19, la banda 4 y NDVI no tuvieron un buen desempeño en este sitio, aunque estuvieron presentes a partir del puesto 25 con coeficientes R^2 menores a 0,25.




Figura 3. Histogramas para profundidad de suelos (cm) en cada uno de los sitios evaluados.

Entrenamiento				Validación		
Sitio	R ²	Capa	Fecha	RMSE	MSE	R ²
A1	0,47***	banda 5	30/11/2008	18,08	15,34	0,16*
A2	0,15**	banda 4	29/08/2003	14,48	10,66	0,14*
TG1	0,39***	CALC	19/10/2010	16,48	13,19	0,39***
SG1	0,47***	banda 4	25/01/2006	16,43	12,86	0,26***
SG2	0,79***	NDVI	14/01/2002	11,85	8,72	0,79***
SG3	0,83***	SAVI	11/03/2005	12,93	11,14	0,78***

Tabla 1. Indicadores de desempeño de los modelos utilizados en el entrenamiento y validación de las capas de información.
Referencias: * p<0,10; ** p<0,05; *** p<0,01; R²: coeficiente de determinación; RMSE: error de la raíz cuadrada de la media; MSE: error absoluto medio.




Figura 4. Izquierda: mapas de profundidad de suelo (cm) obtenidos por el método de distancia inversa ponderada con exponente 2. Derecha: Bandas o índices con la mayor correlación lineal entre las mediciones de profundidad y los valores de la capa de información.

En SG1, 128 capas mostraron relaciones significativas con la PES, con coeficientes R² en el intervalo 0,06-0,47. La banda 4 para el 25/01/2006 presentó el mejor ajuste (figura 5), seguida de NDVI, VISIBLE y SAVI para una misma fecha de observación (13/11/1996). Todas las capas de información analizadas mostraron entre 13 y 14 fechas con regresiones significativas salvo la banda 5 que solo lo hizo en nueve fechas. El índice CALC fue el de mayor número de regresiones

significativas (15/18 fechas disponibles). La validación del modelo indicó valores intermedios de RMSE y MSE.

En SG2, 118 capas presentaron regresiones significativas con coeficientes R² mayores a los observados en otros lotes (0,21-0,79), siendo el valor más alto el observado para NDVI el 14/01/2002 (figura 5), aunque la banda 7 presentó un ajuste muy similar para la misma fecha (R²=0,78), seguido por NDVI y SAVI en la fecha 11/03/2015

($R^2=0,78$ y $0,77$ respectivamente). En forma similar a SG1 cada banda o índice presentó nueve o más regresiones significativas, siendo la banda 4 la de mayor frecuencia (14/18 fechas) y las bandas 7 y 1 las de menor (9/18). La imagen del 19/10/2010 mostró la mayor cantidad de capas de información con regresiones significativas (10) y la del 21/06/2007 la de menor relación con la profundidad, con solo la banda 5 con relación significativa ($R^2=0,25$). En la validación del mejor modelo se observaron bajos valores de RMSE y MSE.

En SG3, 64 capas presentaron regresiones significativas, con un intervalo de coeficientes R^2 de rango más acotado y superior a los restantes (0,40-0,83). SAVI y NDVI para la fecha del 11/03/2005 obtuvieron los máximos R^2 (figura 5) seguido por NDVI y la banda 5 en la fecha 14/01/2002 (0,72 y 0,71 respectivamente). Las capas de información

presentaron como máximo nueve momentos con regresiones significativas (bandas 3 y 5) siendo CALC la de menor relación (una fecha) seguido por SAVI (tres fechas). El 19/10/2010 y el 22/12/2010 fueron las fechas con la mayor cantidad de capas de información con regresiones significativas (siete capas). Existieron cuatro fechas sin ninguna relación. La validación del modelo mostró valores intermedios a bajos de RMSE y MSE.

DISCUSIÓN

El mayor número de correlaciones significativas observadas en SG1, SG2, SG3 podría ser atribuido a una distribución de datos con mayor presencia de suelos someros y muy someros. Por su parte, en SG1 los menores valores de R^2 pueden estar relacionados con la distribución espa-




Figura 5. Izquierda: mapas de profundidad de suelo (cm) obtenidos por el método de Kriging ordinario. Derecha: Bandas o índices con la mayor correlación lineal entre las mediciones de profundidad y los valores de la capa de información.




Figura 6. Distribución de los coeficientes de correlación para todos los sitios y capas de información para distintos meses del año.

cial de los datos, en el lote se observaban cambios abruptos de profundidad de suelos a una escala menor que la resolución espacial del satélite evaluado.

En situaciones como A1 y A2 la discriminación de PES por la presente técnica no ofreció resultados satisfactorios. El escaso ajuste encontrado tiene relación con la baja proporción de suelos someros y la nula estructura de autocorrelación observada, la cual impidió la interpolación por el método de Kriging (datos no mostrados). A su vez una distribución sesgada a profundidades mayores puede no ser fácilmente detectable por sensores remotos dado que la variación de la PES por encima de ciertos valores no genera grandes cambios en la firma espectral del suelo desnudo ni en la biomasa aérea de la vegetación. Posiblemente las variaciones en la respuesta espectral del suelo y del cultivo se deba a otras propiedades físicas o químicas del suelo. En el área de estudio la textura del suelo es indicada como la variable en segunda importancia para la capacidad de retención de agua y rendimiento de los cultivos (Krüger y Venanzi, 2009).

A priori sería difícil establecer cuáles lotes son apropiados para la presente metodología ya que la autocorrelación espacial de los datos es dependiente de la densidad de muestreo (Aspexit, 2019). Aun así, frecuencias de suelos someros (<40 cm) similares a A1 y A2 (<15%) indicarían condiciones no apropiadas para el uso de la técnica.

En los restantes sitios, para una fecha dada, varias capas mostraron relaciones significativas. En promedio, las bandas del grupo infrarrojo cercano a medio presentaron mejores ajustes. La banda 4 (infrarrojo cercano) fue la única que presentó relaciones significativas en todos los lotes. Esta mejor performance de las bandas infrarrojas puede tener relación con la capacidad de censar el contenido de agua en cultivos (Liu *et al.*, 2010), característica altamente influenciada por la PES y las condiciones agroclimáticas. Si bien los índices derivados de estas (NDVI, SAVI) permitieron potenciar la detección de diferencias de profundidad entre suelos, no fue posible establecer bajo qué condiciones una capa de información será superior a las restantes. Ni el índice VISIBLE ni CALC mostraron mejor performan-

ce que el resto de los indicadores. La falta de predominancia de un indicador o banda sobre los restantes refuerza la necesidad de analizar diversas bandas e índices para una gran cantidad de fechas mejorando las probabilidades de obtener buenas correlaciones con la PES. Zhang *et al.* (2017) tampoco observaron diferencias a favor de los índices espectrales, en comparación con la utilización de bandas simples, en la clasificación de coberturas.

Para todos los sitios las mejores correlaciones se distribuyeron principalmente en los meses de octubre a marzo (figura 6), época coincidente con las de mayor acumulación de biomasa para cultivos invernales y estivales. La baja cantidad de relaciones significativas en el periodo abril-agosto podría ser explicado por el bajo desarrollo de los verdeos invernales, la senescencia de cultivos estivales y suelos sin cobertura vegetal en barbecho para cereales de invierno. En la región estudiada, dado las limitaciones agroclimáticas, predominan los verdeos y cereales de invierno sobre los estivales (Barragan *et al.*, 2016), por lo cual la presencia de barbechos para cultivos estivales en el periodo septiembre-marzo sería de menor importancia. Los presentes resultados indicarían que es factible la generación de bibliotecas de imágenes en el semestre octubre-marzo sin pérdida de buenos modelos de regresión, con la consiguiente reducción en el volumen de datos y mejora en los tiempos de ejecución. Para la serie estudiada, las imágenes del mes de septiembre siempre tuvieron una superficie con nubes mayor al 10%. Sería factible la obtención de mayor número de imágenes si se aumentara la tolerancia del porcentaje de superficie cubierta con nubes, y la reducción del área considerada en la biblioteca de imágenes, lo cual permitiría tener mayor probabilidades de encontrar fechas libres de nubosidad reduciendo, a su vez, el área de aplicación de la biblioteca.

No se pudieron establecer relaciones claras entre las condiciones agroclimáticas ocurridas (precipitaciones y temperatura) y la presencia de buenas correlaciones para PES. Se observó una tendencia a existir precipitaciones por debajo de la media meses previos a establecerse buenas correlaciones, aunque esta no fue consistente se

enmascara posiblemente por el efecto antrópico del manejo de cada lote.

Por una parte, los niveles de correlación observados en este trabajo, especialmente en los sitios SG2 y SG3, resultaron similares a los obtenidos por Johan *et al.* (2013) por medición directa de la conductividad eléctrica aparente mediante un sensor proximal tipo EM-38 Geonics® ($R^2=0,53$). Por otra parte, Domenech *et al.* (2017) lograron coeficientes de regresión superiores ($R^2=0,90$) mediante técnicas de interpolación que integran información auxiliar. Sería esperable que aquellas imágenes con alta correlación puedan ser utilizadas como variable auxiliar en la generación de mapas de PES. Otros autores han propuestos esquemas similares para la interpolación de propiedades edáficas utilizando información auxiliar obtenida de imágenes de suelos descubiertos (López-Granados *et al.*, 2005) o índices de vegetación (Hengl *et al.*, 2007). La presente metodología permitiría seleccionar aquellas imágenes de utilidad para su posterior uso en la estimación de la PES por técnicas híbridas de interpolación-correlación como universal kriging, regresión kriging o co-kriging (McBratney *et al.*, 2000).

Los valores de RMSE y MSE indicaron un nivel de predicción aceptable para la determinación de la PES. En promedio se observaron desviaciones cercanas a 15,2 cm para RMSE y 12 cm para MSE. El indicador RMSE es más sensible a valores extremos que MSE, siendo más apropiado cuando son indeseables errores de gran magnitud. Estudios cercanos a la región evaluada, con un mayor número de observaciones, permitieron construir modelos de profundidad de suelo mediante el uso de sensores proximales, modelos digitales de elevación y algoritmos de aprendizaje de máquinas con un RMSE = 13 cm (Castro Franco *et al.*, 2017). La obtención de dicha información base puede resultar costosa debido al requerimiento de maquinaria altamente específica y de baja disponibilidad en el territorio. La teledetección acoplada a mecanismos automatizados de búsqueda como el aquí presentado es relativamente económica permitiendo una buena aproximación a la profundidad real del horizonte petrocálcico, especialmente, si este se presenta de forma somera (<40 cm) y con una frecuencia mayor al 15%.

Con respecto a la cartografía tradicional, la ventaja de la técnica presentada se basa en requerir un menor control de campo con el consiguiente ahorro de tiempo y costos. La rapidez de ejecución del programa utilizado (tres minutos en promedio) y la posibilidad de ejecutarlo en un ordenador portátil permitiría realizar las observaciones de PES y selección de imágenes en el mismo sitio de estudio. La validación de los ambientes de manejo de suelos determinados sobre la base de las imágenes seleccionadas requiere un menor tiempo de trabajo de campo, si las observaciones de control se realizan en forma dirigida considerando las distintas unidades previamente delimitadas en la imagen.

CONCLUSIONES

La metodología propuesta permitió identificar imágenes relacionadas con la PES de forma automática en una larga

serie histórica del satélite LANDSAT 5 TM. Si bien las capas relacionadas con el espectro del infrarrojo cercano tuvieron en general un mejor ajuste, no se observó un desempeño superior de alguna banda o índice sobre los restantes. Se muestra factible la reducción de la biblioteca de imágenes al periodo octubre-marzo reduciendo los tiempos de ejecución y volúmenes de información. La validación de la correspondencia entre reflectancia, índices y PES en las imágenes seleccionadas permite asegurar una razonable precisión en la posterior definición de ambientes de manejo de suelos.

En futuras investigaciones se debería aplicar la presente metodología a otras misiones satelitales (Landsat 8, Sentinel 2), evaluar otras técnicas estadísticas avanzadas (random forest, SVM) y evaluar la ejecución de los algoritmos en la nube permitiendo independizarse de la descarga de imágenes.

AGRADECIMIENTOS

La investigación fue financiada por proyectos de INTA PN AGUA-1133021, PRETBASUR-1272205 y recursos del "Sector de Manejo y Conservación de Suelos de INTA Bordenave". Se agradece el trabajo a campo realizado por los técnicos Rubén Elorriaga y Damian Gaute.

BIBLIOGRAFÍA

- ASPEXIT. 2019. Variogram and spatial autocorrelation. (Disponible: <https://www.aspexit.com/en/variogram-and-spatial-autocorrelation/> verificado: 12 de abril de 2019).
- BARRAGÁN, F.; MARINI, F.; GUILLERO, A.; GARABITO C. 2016. Determinación del uso del suelo en una zona semiárida mediante un estudio multitemporal con imágenes Landsat. Actas II Congreso Nacional de Tecnologías de la Información Geográfica y II Jornadas de Sistemas de Información Geográfica realizados en el Campus de la Universidad Nacional de General Sarmiento, Buenos Aires, 3 y 4 de octubre de 2013, 12 p.
- BIRTWISTLE, A.N.; LAITURI, M.; BLEDSOE, B.; FRIEDMAN, J.M. 2016. Using NDVI to measure precipitation in semi-arid landscapes. *Journal of Arid Environments*, 131, 15-24.
- BIVAND, R.; KEITT, T.; ROWLINGSON, B. 2014. rgdal: Bindings for the geospatial data abstraction library. R package version 0.8-16. (Disponible: <https://CRAN.R-project.org/package=rgdal> verificado: 14 de abril de 2019).
- BOETTINGER, J.L.; RAMSEY, R.D.; BODILY, J.M.; COLE, N.J.; KIENAST-BROWN, S.; NIELD, S.J.; STUM, A.K. 2008. Landsat spectral data for digital soil mapping. In *Digital soil mapping with limited data*. Springer, Dordrecht. 193-202 pp.
- BRAVO, O.; AMIOTTI, N.; ROLLHAUSER, J.P.; ZALBA, P. 2004. Variabilidad de suelos y su incidencia en el rendimiento de trigo a nivel de predio. Resúmenes XIX CACS. Paraná, Argentina. 353 p.
- CASTRO FRANCO, M.; DOMENECH, M.; COSTA, J.L.; APARICIO, V.C. 2017. Modelling effective soil depth at field scale from soil sensors and geomorphometric indices. *Acta Agronómica*, 66(2), 228-234.
- CHAI, T.; DRAXLER, R.R. 2014. Root mean square error (RMSE) or mean absolute error (MAE)?—Arguments against avoiding RMSE in the literature. *Geoscientific model development*, 7(3), 1247-1250.
- CIERNIEWSKI, J.; KUŚNIEREK, K. 2010. Influence of several size properties on soil surface reflectance. *Quaestiones Geographicae*, 29(1), 13-25.

- CONGEDO, L. 2016. Semi-automatic classification plugin documentation. Release, 4(0.1), 29. DOI: <http://dx.doi.org/10.13140/RG.2.2.29474.02242/1>
- CÓRDOBA, M.; BRUNO, C.; AGUATE, F.; TABLADA, M.; BALZARINI, M. 2014. Análisis de la variabilidad espacial en los lotes agrícolas. En: BALZARINI M. (ed.). Manual de buenas prácticas agrícolas. Eudecor., Córdoba, Argentina.
- DOMENECH, M.B.; CASTRO FRANCO, M.; COSTA, J.L.; AMIOTTI, N.M. 2017. Sampling scheme optimization to map soil depth to petrocalcic horizon at field scale. *Geoderma*, 290, 75-82.
- FROLLA, F.D.; ZILIO, J.P.; KRÜGER, H. 2015. Variabilidad espacial de la profundidad del suelo. Métodos de interpolación para el sudoeste bonaerense. *Revista RIA 41 N.º 3*:309-316.
- FROLLA, F.D.; KRÜGER, H.R.; ZILIO, J.P. 2017. Relación entre índices ópticos y la profundidad de suelos en seis años de trigo. III Jornadas Nacionales de Suelos de Ambientes Semiáridos. INTA-UNS-CERZOS-CONICET. Bahía Blanca.
- HAMNER, B.M.; LEDELL, E. 2012. Metrics: Evaluation metrics for machine learning. R package version 0.1, 1. (Disponible: <https://CRAN.R-project.org/package=Metrics> verificado: 12 de abril de 2019).
- HENGL, T.; HEUVELINK, G.B.; ROSSITER, D.G. 2007. About regression-kriging: From equations to case studies. *Computers & geosciences*, 33(10), 1301-1315.
- HIJMANS, R.J. 2016. Raster: Geographic Data Analysis and Modeling. R package version 2.5-8. (Disponible: <https://CRAN.R-project.org/package=raster> verificado: 12 de abril de 2019).
- HUETE, A.R. 1988. A soil-adjusted vegetation index (SAVI). *Remote sensing of environment*, 25(3), 295-309.
- JOHAN, V.A.N.; BARNARD, J.; VAN RENSBURG, L.; PIETER, L.E. 2013. Soil depth inferred from electromagnetic induction measurements. *African Journal of Agricultural Research*, 8(6), 519-524.
- KRÜGER, H.; VENANZI, S. 2009. El agua y el rendimiento del trigo. Algunos cálculos. (Disponible: https://inta.gob.ar/sites/default/files/script-tmp-2_el_agua_y_el_rendimiento_de_trigo.pdf verificado: 27 de abril de 2019).
- KRÜGER, H.R.; FROLLA, F.; ZILIO, J. 2018. Profundidad efectiva del suelo y rendimientos de trigo en el sudoeste bonaerense. XXVI Congreso Argentino de la Ciencia del Suelo, Tucumán, Argentina.
- LIU, J.; PATTEY, E.; MILLER, J.R.; MCNAIRN, H.; SMITH, A.; HU, B. 2010. Estimating crop stresses, aboveground dry biomass and yield of corn using multi-temporal optical data combined with a radiation use efficiency model. *Remote Sensing of Environment*, 114(6), 1167-1177.
- MATLOFF, N. 2011. The art of R programming: A tour of statistical software design. No StarchPress.
- NAGENDRA, H.; LUCAS, R.; HONRADO, J.P.; JONGMAN, R.H.; TARANTINO, C.; ADAMO, M.; MAIROTA, P. 2013. Remote sensing for conservation monitoring: Assessing protected areas, habitat extent, habitat condition, species diversity, and threats. *Ecological Indicators*, 33, 45-59.
- MCBRATNEY, A.B.; ODEH, I.O.; BISHOP, T.F.; DUNBAR, M.S.; SHATAR, T.M. 2000. An overview of pedometric techniques for use in soil survey. *Geoderma*, 97(3-4), 293-327.
- PAZOS, M.S.; MESTELAN, S.A. 2002. Variability of depth to Tosca in Udolls and soil classification, Buenos Aires Province, Argentina. *Soil Sci. Soc. Am. J.* 66 (4), 1256-1264.
- PEBESMA, E.J.; BIVAND, R.S. 2005. Classes and methods for spatial data in R. *R News* 5 (2). (Disponible: <https://cran.r-project.org/doc/Rnews/> verificado: 12 de abril de 2019).
- RAY, S.; SINGH, J.; DAS, G.; PANIGRAPHY, S. 2004. Use of high resolution remote sensing data for generating site specific soil management plan. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences* (35): 127-132.
- R CORE TEAM. 2018. R: A language and environment for statistical computing. R Foundation for Statistical Computing, Vienna, Austria. (Disponible: <https://www.R-project.org/> verificado: 12 de abril de 2019).
- ROSS, F. 2012. Determinación espacial de la profundidad de suelo (tosca) y su relación con el rendimiento de cultivo. Congreso de Valor Agregado en Origen, Vol. 1, 1-3 pp.
- SADRAS, V.O.; CALVIÑO, P.A. 2001. Quantification of grain yield response to soil depth in soybean, maize, sunflower, and wheat. *Agron. J.* 93 (3), 577-583.
- SALIH, H.M.; YAHYA, A.I.; ABDUL-RAHEM, A.M.; MUNAM, B.H. 1989. Availability of phosphorus in a calcareous soil treated with rock phosphate or superphosphate as affected by phosphate-dissolving fungi. *Plant and soil*, 120 (2), 181-185.
- SATORRE, E.H.; SLAFER, G.A. 1999. Wheat Production Systems of the Pampas. Wheat: Ecology and Physiology of Yield Determination, Food Products Press, Nueva York, 333-348.
- VIGLIZZO, E.F.; PORDOMINGO, A.J.; CASTRO, M.G.; LÉRTORA F.A.A. 2003. Environmental assessment of agriculture at a regional scale in the Pampas of Argentina. *Environmental monitoring and assessment*, 87(2), 169-195.
- VOLMER BUFFA, E.; RATTO, S.E. 2005. Disponibilidad de cinc, cobre, hierro y manganeso extraíble con DTPA en suelos de Córdoba (Argentina) y variables edáficas que la condicionan. *Ciencia del suelo*, 23(2), 107-114.
- ZHANG, T.; SU, J.; LIU, C.; CHEN, W.H.; LIU, H.; LIU, G. 2017. Band selection in sentinel-2 satellite for agriculture applications. *Automation and Computing (ICAC)*, 2017 23 rd International Conference on. IEEE. 1-6 pp.