



“RELACIÓN ENTRE ÍNDICES DE VEGETACIÓN Y RENDIMIENTO EN MAÍZ”

ÁREA DE CONSOLIDACIÓN
MÉTODOS CUANTITATIVOS PARA LA INVESTIGACIÓN
AGROPECUARIA

Integrantes

Cittadini, Maximiliano

Del Boca, Agustín

Fuentes, Leandro

Nardi, Fabricio

Tutor

Ing. Agr. Córdoba, Mariano



Diciembre, 2016

RESUMEN

La agricultura de precisión (AP) debe ser comprendida como un concepto moderno de gestión agrícola basado en el uso de diferentes herramientas tecnológicas como la teledetección, que le permitan detectar la variabilidad que tiene una determinada explotación agrícola. Ésta herramienta estudia la vegetación a partir de medidas de reflectividad con independencia de todos los factores que perturban la señal radiométrica calculando para ello diferentes índices de vegetación. En este trabajo se comparan diferentes índices espectrales y combinación de todas las bandas a partir de un análisis de componentes principales (con y sin restricción espacial) en su capacidad predictiva del rendimiento del cultivo de maíz. Se calcularon coeficientes de correlación lineal de Pearson y se ajustaron modelos de regresión lineal evaluando las diferentes estrategias mediante un proceso de validación cruzada. Los resultados mostraron que ambos procedimientos presentan valores de correlación con el rendimiento similares. El modelo basado en el índice PRI resultó ser el que mejor capacidad predictiva presentó con un RMSE del 19,73 %.

PALABRAS CLAVE

agricultura de precisión, teledetección, modelos mixtos, análisis multivariado espacial, NDVI

INTRODUCCIÓN

En la agricultura, una característica importante del suelo es su gran variabilidad de las condiciones físico químicas que se traduce en alta variación espacial de la producción dentro de los lotes y dentro de las regiones (Muñoz et al., 2006). En este contexto surge la agricultura de precisión (AP), tecnología que hace uso de la variabilidad espacial intralote. La AP se basa en el manejo diferenciado de los cultivos utilizando para ello diferentes herramientas tecnológicas como la teledetección que permiten caracterizar la variabilidad espacial que tiene un lote agrícola y realizar una gestión integral del mismo.

La Teledetección tiene por finalidad identificar y caracterizar los materiales de la superficie terrestre y los procesos que en ella ocurren a partir de la radiación electromagnética procedente de la misma, entendiendo por tal tanto la emitida por la propia superficie terrestre como la reflectada de la que le llega del sol, prevaleciendo una sobre otra en función del intervalo espectral considerado (Baret et al., 1995). Para establecer una relación entre la medida efectuada por teledetección y los parámetros biofísicos que caracterizan una cubierta vegetal, es necesario derivar algún parámetro a partir de la reflectividad que normalice la influencia de todos los factores perturbadores de la señal radiométrica. Esto se logra a partir del cálculo de los denominados índices de vegetación, como por ejemplo NDVI, GVI, RVI, GNDVI, NRVI, PRI, GRE, X7, CWMI, HBC, HBS, RG y NIR (Diaz Garcia-Cervigon et al., 2015). De forma genérica se podría definir un índice de vegetación (IV) como un parámetro calculado a partir de los valores de la reflectividad a distintas longitudes de onda y que permite extraer de los mismos información importante para estudios relacionados con el uso, la ocupación y la producción de la superficie del suelo. La teledetección permite la obtención de información de campo a un menor costo respecto a otros métodos como así también la cobertura de grandes áreas y la repetición periódica a lo largo de todo el ciclo del cultivo (Massey et al., 2008; Bocco et al., 2014). En el contexto de la AP, esta herramienta es frecuentemente utilizada para estimar la cantidad de biomasa producida y el rendimiento de los cultivos utilizando como base los IV que combinan bandas espectrales de la región visible e infrarrojo cercano del espectro magnético (Stanhill et al., 1972; Sridhar et al., 1994; Taylor et al., 1998; Reynolds et al., 2000; Casanova et al., 1998; Serrano et al., 2000; Oberthur et al., 2007). Estos han permitido, en la actualidad, anticipar y estimar el rendimiento de un cultivo agrícola con mayor precisión (Wang et al., 2013).

Diversos estudios en distintas regiones del mundo muestran que los valores de NDVI muestran correlaciones significativas con los valores de rendimiento de diversos cultivos, en particular aquellos en los que el rendimiento es determinado por la biomasa vegetal. Estos

estudios son realizados frecuentemente a escala regional y no comparan las predicciones obtenidas con los diferentes IV o combinación de todas las bandas del espectro electromagnético (Groten,1993; Smith et al., 1995; Unganai y Kogan, 1998; Mika et al., 2002; Mkhabela et al.,2005; de la Casa y Ovando, 2007).

El uso combinado de la teledetección¹ y los sistemas de información geográfica representan una potente herramienta para los productores agrícolas, ingenieros agrónomos, entidades privadas y públicas, basada en el manejo integrado de los recursos naturales² y los sistemas de producción agropecuarios racionalizando el uso de los mismos. Asimismo permiten el estudio objetivo del impacto³ de las tecnologías sobre el medio ambiente de manera periódica, rápida y económica.

El presente trabajo tiene como objetivos: 1) estimar la correlación entre los diferentes índices de vegetación y el rendimiento del cultivo de maíz; y 2) identificar el índice de vegetación o combinación lineal de bandas espectrales que presente una mejor capacidad predictiva del rendimiento en el cultivo de maíz.

MATERIALES Y MÉTODOS

Datos

Se utilizaron datos pertenecientes a un programa de mejoramiento genético en cultivo de maíz. La base estuvo conformada con datos de 11 ensayos comparativos de rendimiento en el cual se evaluaron un total de 116 genotipos en un diseño en bloques completos al azar con tres repeticiones. Las variables registradas fueron el rendimiento del cultivo, coordenadas espaciales y la reflectancia de 62 bandas espectrales (desde 397nm a 847nm.)

Análisis Estadístico

Para el rendimiento y las bandas espectrales, se ajustó en cada ensayo un modelo de ANAVA con efecto fijo de genotipo. A los residuos obtenidos de los modelos se le sumo la

¹Indicadores sociales: Compromisos Éticos; Diálogo e Involucramiento de las partes interesadas (*Stakeholders*); Compromiso con el Desarrollo Profesional y la Empleabilidad; Gerenciamiento del Impacto de la Empresa en la Comunidad de Entorno; Relaciones con Organizaciones Locales; Liderazgo e Influencia Social; Participación en Proyectos Sociales Gubernamentales.

²Indicadores ambientales: Compromiso con la Mejoría de la Calidad Ambiental; Educación y Concientización Ambiental; Gerenciamiento de los Impactos sobre el Medio Ambiente y del Ciclo de Vida de Productos y Servicios; Sustentabilidad de la Economía Forestal; Minimización de Entradas y Salidas de Materiales; Planes de Gestión Ambiental.

³Indicadores económicos: Valor Económico e Intangible Generado; Impactos Socioeconómicos Generados; Política de Comunicación Comercial; Conocimiento y Gerenciamiento de los Daños Potenciales de Productos y Servicios.

media general de la variable (rendimiento o banda espectral) de cada ensayo. De esta forma se obtuvieron datos de rendimiento y bandas espectrales en los que la fuente de variación dada por el genotipo fue eliminada. Para cada observación se calcularon los índices de vegetación según las fórmulas y bandas de las Tablas 1 y 2, respectivamente. Un detalle de las mismas puede encontrarse en Diaz Garcia-Cervigon et al. (2015).

Tabla 1. Fórmulas de los diferentes Índices de Vegetación y bandas espectrales.

Índices de Vegetación (IV)
$NDVI = \frac{[B56_sG] - [B38_sG]}{[B56_sG] + [B38_sG]}$
$GNDVI = \frac{[B56_sG] - [B23_sG]}{[B56_sG] + [B23_sG]}$
$RVI = \frac{[B56_sG]}{[B38_sG]}$
$GVI = \frac{[B56_sG]}{[B23_sG]}$
$NGRDI = \frac{[B23_sG] - [B38_sG]}{[B23_sG] + [B38_sG]}$
$RG = \frac{[B38_sG]}{[B23_sG]}$
$NRVI = \frac{[B56_sG]}{[B38_sG]} - \frac{1}{\left(\frac{[B56_sG]}{[B38_sG]} + 1\right)}$
$HBS = \frac{[B62_sG] - [B40_sG]}{[B62_sG] + [B40_sG]}$
$HBC = \frac{[B22_sG] - [B17_sG]}{[B22_sG] + [B17_sG]}$
$mND = \frac{([B49_sG] - [B43_sG])}{([B49_sG] + [B43_sG])} - (2 * [B7_sG])$
$GRE = 322 * \left(\frac{[B54_sG]}{[B44_sG]} - 1\right) + 27$
$CWMI = \frac{[B62_sG]}{[B45_sG]}$
$NIR = \frac{[B53_sG]}{[B47_sG]}$
$X7 = \frac{[B50_sG]}{[B46_sG]}$
$PRI = \frac{[B19_sG] - [B24_sG]}{[B19_sG] + [B24_sG]}$

Tabla 2. Bandas espectrales y longitudes de onda en el Espectro Electromagnético.

Banda	Longitud de Onda (nm)	Color en el Espectro
B1-B8	380-450	Violeta
B9-B14	450-495	Azul
B15-B24	495-570	Verde
B25-B27	570-590	Amarillo
B28-B31	590-620	Naranja
B32-B48	620-750	Rojo
B49-B62	750-2600	NIR

Una vez que se obtuvieron los índices se procedió a evaluar la correlación con el rendimiento calculando coeficientes de correlación lineal de Pearson (Balzarini *et al.*, 2008).

Para evaluar la capacidad predictiva del rendimiento de los IV, se utilizaron diferentes estrategias (Tabla 3). En todas ellas se ajustaron diferentes modelos de regresión lineal. En el modelo 1 se utilizó un índice de vegetación que tuviera mejor correlación con el rendimiento a través de todos los ensayos evaluados. En el modelo 2 las variables regresoras fueron las componentes principales (CP1 y CP2) obtenidas a partir de un Análisis de Componentes Principales (PCA, Pearson, 1901) realizados sobre todas las bandas espectrales. El modelo 3 la variable regresora fue la componente principal espacial (CS1) obtenidas a partir de un Análisis

de Componentes Principales Espacial (MULTISPATI-PCA, Dray *et al.*, 2008) realizados sobre todas las bandas espectrales.

En cada estrategia el modelo de regresión ajustado fue realizado bajo el supuesto de independencia y también contemplando la posible correlación espacial entre las observaciones. Para ello, se ajustó un Modelo Lineal Mixto (MLM) (Gbur *et al.*, 2012) con diferentes modelos de correlación espacial (exponencial, gaussiano y esférico). Para la selección del mejor modelo de correlación espacial se utilizó el criterio de información de Akaike (AIC) (Schabenberger *et al.*, 2002).

Tabla 3. Modelos de Regresión Lineal utilizados.

	Modelo 1	Modelo 2	Modelo 3
Variable Respuesta	Rendimiento	Rendimiento	Rendimiento
Covariable(Efecto Fijo)	Índice de vegetación	CP1 y CP2	CS1
Criterio de Clasificación (Efecto Aleatorio)	Ensayo	Ensayo	Ensayo

Finalmente, para evaluar la capacidad predictiva de los modelos ajustados se procedió a realizar una validación cruzada utilizando un 80% de los datos para el ajuste de los modelos y el 20% restante para evaluar la capacidad predictiva de cada modelo. A partir de las diferencias entre los observados y predichos por los modelos, se calcularon el error cuadrático medio (MSE) y la raíz cuadrada del error cuadrático medio (RMSE).

- $MSE = \frac{\sum (O_i - E_i)^2}{N}$
- $RMSE = \sqrt{MSE}$
- $RMSE(\%) = RMSE / \text{Rendimiento promedio}$

En donde N es el número de observaciones, O_i es el valor observado y E_i es el valor estimado; $RMSE(\%)$ o RE es el error relativo. El modelo perfecto es cuando b (pendiente de la regresión lineal) = $r^2 = 1$ y $MSE = RMSE = RMSE(\%) = 0$. El mejor modelo debe tender a los límites anteriores, siendo bueno el ajuste del modelo cuando, $RMSE(\%) \leq 20\%$ (Pereira, 2004; Stockle *et al.*, 2004; Cai *et al.*, 2007). Todos los análisis estadísticos fueron realizados utilizando el software estadístico InfoStat (Di Rienzo *et al.*, 2016).

RESULTADOS Y DISCUSIÓN

En la Fig. 1, se observa que los índices no presentaron diferencias entre sí respecto a los coeficientes de correlación entre las bandas y el rendimiento del maíz a través de todos los ensayos. El índice HBC presentó la mayor variabilidad y mND fue el que tuvo menor variación a través de los ensayos. El índice RG fue el único que mostró una correlación negativa con el rendimiento.

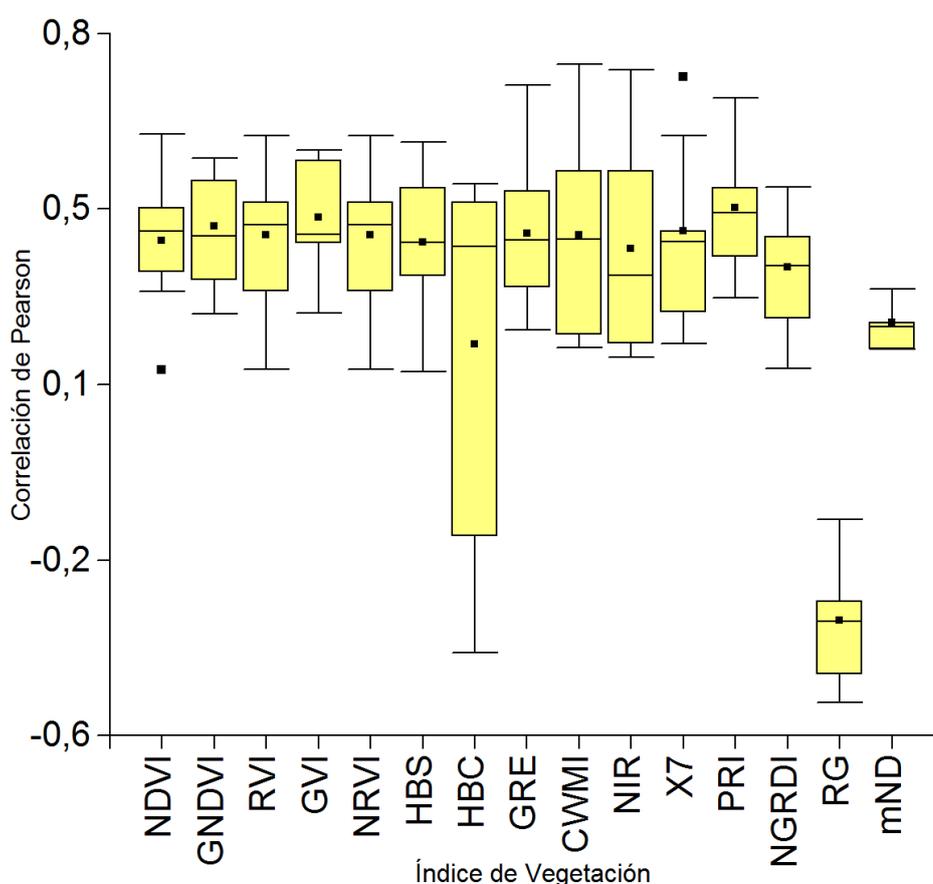


Fig. 1. Gráfico de Box Plot de los IV y su correlación con el rendimiento.

En la Tabla 4, se muestra la correlación de los índices espectrales con el rendimiento en los 11 ensayos. Se observa que los valores de los ensayos 1 y 3 no son estadísticamente significativos. Mientras que, en los ensayos restantes, se destacan ciertos índices por su alto valor de correlación y nivel de significancia (NDVI, PRI, RVI y GRE, entre otros).

Elwadie et al. (2005) concluyeron los IV que utilizan la banda verde (GVI y GNDVI) en lugar de la roja (RVI y NDVI) producen mejores resultados para estimar el rendimiento. A diferencia de lo encontrado en este trabajo, los índices que utilizan la banda roja fueron los que tuvieron mayor correlación. Asimismo, NDVI, RVI, GVI y GNDVI presentaron valores similares para la estimación del rendimiento.

Tabla 4. Coeficientes de Correlación Lineal de Pearson entre índices de vegetación (IV) y rendimiento de maíz en 11 ensayos comparativos de rendimiento.

IV	Ensayo										
	E1	E2	E3	E4	E5	E6	E7	E8	E9	E10	E11
NDVI	-0,01	0,48 **	0,12	0,35 *	0,15 *	0,53 **	0,63 **	0,43 **	0,44 **	0,31 **	0,39 **
GNDVI	-0,06	0,58 **	0,05	0,33 *	0,11	0,53 **	0,57 **	0,40 **	0,42 **	0,26 **	0,42 **
RVI	0,00	0,49 **	0,11	0,31	0,15 *	0,53 **	0,62 **	0,43 **	0,45 **	0,31 **	0,39 **
GVI	-0,06	0,59 **	0,05	0,31	0,12	0,53 **	0,57 **	0,41 **	0,41 **	0,27 **	0,42 **
NGRDI	0,08	0,08	0,19	0,32 *	0,15 *	0,47 **	0,52 **	0,42 **	0,40 **	0,32 **	0,25 **
RG	0,00	-0,08	-0,19	-0,33 *	-0,15 *	-0,47 **	-0,52 **	-0,42 **	-0,39 **	-0,32 **	-0,26 **
NRVI	-0,08	0,49 **	0,11	0,31	0,15 *	0,53 **	0,62 **	0,43 **	0,45 **	0,31 **	0,39 **
HBS	-0,04	0,52 **	0,11	0,34 **	0,15 *	0,52 **	0,61 **	0,41 **	0,44 **	0,29 **	0,39 **
HBC	-0,09	-0,42 *	0,16	0,14	-0,19 **	0,19	0,53 **	0,49 **	0,43 **	0,37 **	0,15
mND	-0,19	0,27	0,09	0,15	-0,06	0,15	0,24 *	0,15	0,31 **	0,23 *	0,19 *
GRE	-0,02	0,73 **	0,02	0,32 *	0,27 **	0,57 **	0,51 **	0,37 **	0,42 **	0,23 *	0,41 **
CWMI	-0,11	0,77 **	-0,01	0,29	0,20 **	0,55 **	0,44 **	0,22 **	0,36 **	0,11 **	0,41 **
NIR	-0,06	0,76 **	-0,05	0,27	0,18 **	0,55 **	0,34 **	0,20 *	0,33 **	0,05	0,40 **
X7	-0,01	0,74 **	-0,03	0,31	0,27 **	0,62 **	0,43 **	0,36 **	0,39 **	0,20 *	0,42 **
PRI	0,07	0,70 **	0,10	0,41 **	0,42 **	0,58 **	0,52 **	0,30 **	0,51 **	0,16	0,38 **

**p-valor <0,01 y *p-valor <0,05.

En la Tabla 5, se compara los diferentes modelos de regresión, contemplando la correlación espacial y suponiendo datos independientes (sin correlación espacial). En todos los modelos con correlación espacial ajustados, el modelo exponencial fue el que tuvo mejor ajuste (menor AIC). El índice PRI en ambos modelos presenta el menor RMSE (%) 19,73% y la mayor correlación (0,61) con el rendimiento, aunque las diferencias entre los mismos no son importantes; siendo bueno el ajuste del modelo cuando, $RMSE(\%) \leq 20\%$ (Pereira, 2004; Stockle et al., 2004; Cai et al., 2007).

Shanahan et al. (2001) estimaron el rendimiento de maíz, y compararon el desempeño de dos IV: NDVI, y GNDVI (Gitelson et al., 1996). Este último, que en la expresión del NDVI reemplaza la información del canal rojo por la del canal verde, mostró el mejor comportamiento. En este trabajo los índices NDVI y GNDVI tuvieron un desempeño similar.

Tabla 5. Comparación de los diferentes modelos de regresión lineal.

MLMix	MSE_media	RMSE	RMSE(%)	Correlación	P-valor
NDVI	0,55	0,74 Tn	20,49%	0,57	<0,0001
GNDVI	0,55	0,74 Tn	20,49%	0,57	<0,0001
GVI	0,55	0,74 Tn	20,49%	0,57	<0,0001
GRE	0,53	0,73 Tn	20,11%	0,59	<0,0001
PRI	0,51	0,71 Tn	19,73%	0,61	<0,0001
CP	0,56	0,75 Tn	20,67%	0,55	<0,0001
CS	0,62	0,79 Tn	21,75%	0,49	<0,0001
NDVI_Corr Exp	0,54	0,73 Tn	20,30%	0,57	<0,0001
GNDVI_Corr Exp	0,55	0,74 Tn	20,49%	0,57	<0,0001
GVI_Corr Exp	0,54	0,73 Tn	20,30%	0,57	<0,0001
GRE_Corr Exp	0,53	0,73 Tn	20,11%	0,59	<0,0001
PRI_Corr Exp	0,51	0,71 Tn	19,73%	0,61	<0,0001
CP_Corr Exp	0,56	0,75 Tn	20,67%	0,55	<0,0001
CS_Corr Exp	0,61	0,78 Tn	21,58%	0,49	<0,0001

En la Fig. 2, se muestra la relación entre el rendimiento del cultivo de maíz y el índice de vegetación, PRI; y la recta del modelo de regresión ajustado. Los parámetros del modelo ajustado se presentan en la siguiente ecuación:

- $Y = 11,21 + 49,14 * PRI$

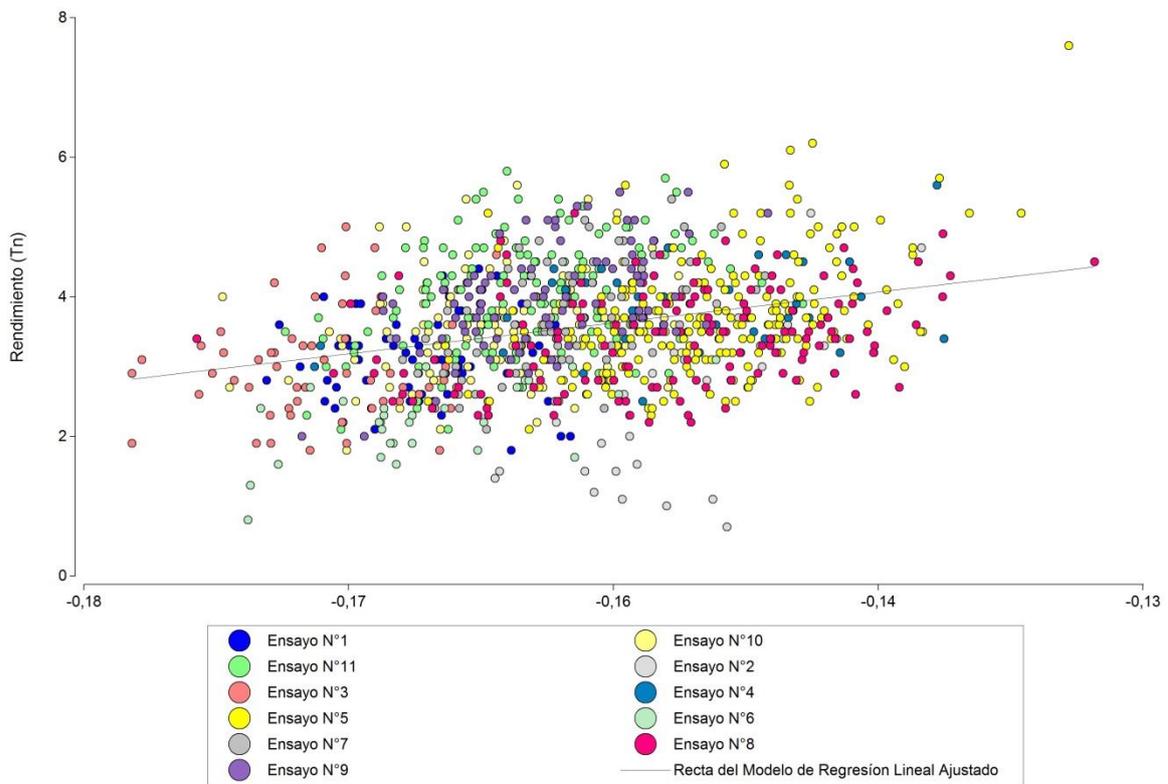


Fig.2. Gráfico de dispersión en función del rendimiento y PRI, junto a la recta del modelo de regresión lineal ajustado.

CONCLUSIÓN

Las correlaciones de los índices de vegetación con el rendimiento, en general, fueron positivas pero bajas ($<0,5$), y si bien eran similares entre sí, PRI y GRE se destacan levemente del resto. Los modelos de regresión lineal, sin y con correlación espacial exponencial, bajo el marco teórico de modelos lineales mixtos (MLM), no mostraron diferencias importantes en su capacidad predictiva, por lo que se decidió elegir una estrategia para datos independientes, es decir, sin ajustar una estructura espacial. En este contexto, el modelo en base a PRI resultó ser el que mejor capacidad predictiva presentó y el que tuvo el mayor valor de correlación con respecto al rendimiento. La estrategia que contempla el cálculo de los índices de vegetación tuvo un mejor desempeño respecto a método que se basa en la combinación de todas las bandas del espectro a partir de un análisis de componentes principales (con o sin restricción espacial).

CONSIDERACIONES FINALES

El uso combinado de la teledetección y los sistemas de información geográfica representan una valiosa herramienta para el uso sostenible de los recursos naturales. En donde los diferentes actores involucrados e interesados en la misma son: productores, técnicos, comunidad cercana, municipio, ingenieros agrónomos, proveedores de insumos de la tecnología y los nuevos usuarios.

Es de fundamental importancia, alinear los Indicadores Ethos de Responsabilidad Social a la utilización de estas herramientas para que incorporen en su gestión los conceptos y sus compromisos con el desarrollo sostenible.

BIBLIOGRAFÍA

Balzarini M.G., Gonzalez L., Tablada M., Casanoves F., Di Rienzo J.A., Robledo C.W. (2008). Infostat. Manual del Usuario, Editorial Brujas, Córdoba, Argentina

Abaurrea Pereda M. 2013. Comparación de índices de vegetación en zona semiárida de Navarra. 40 pp.

Díaz García-Cervigón JJ. 2015. Estudio de Índices de vegetación a partir de imágenes aéreas tomadas desde UAS/RPAS y aplicaciones de estos a la agricultura de precisión. 78 pp. Argentina.

Arinci A., Clemente J., Faraoni D., Nolasco M., Sayago S., Selva G., Violini S., Willington E. y Bocco M. 2014. Estimación del Rendimiento de Soja y Maíz basado en el Índice de Vegetación de Diferencia Normalizada (NDVI). 7 pp.

Balzarini M., Di Rienzo J., Tablada M., Gonzalez L., Bruno C., Córdoba M., Robledo W. y Casanoves F. 2012. Estadística y Biometría. Ilustraciones del uso de InfoStat en problemas de Agronomía. Ed. Brujas. 402 pp.

Baret F. 1995. Use of spectral reflectance variation to retrieve canopy biophysical character en Danson, F. M. and Plummer, S. E. (eds) *Advances in Environmental Remote Sensing*. John Wiley & Sons. Ltd. Ch.3

CONAE. 2016. Índices Espectrales derivados de imágenes satelitales Landsat 8 Sensor OLI. 15 pp.

Córdoba M. 2014. Herramientas Estadísticas Para El Monitoreo Y Uso De La Variabilidad Espacial Del Rendimiento Y Propiedades De Suelo Intralote. 201 pp.

Di Rienzo J.A., Casanoves F., Balzarini M.G., Gonzalez L., Tablada M., Robledo C.W. InfoStat versión 2016. Grupo InfoStat, FCA, Universidad Nacional de Córdoba, Argentina. URL <http://www.infostat.com.ar>

GRAS, INIA. La Teledetección y los Sistemas de Información Geográfica, algunas aplicaciones en

el Uruguay. Recuperado de <http://www.inia.uy/Publicaciones/Paginas/publicacion-685.aspx>

Hoyos-Villegas V. y Fritschi F. 2013. Relationships Among Vegetation Indices Derived from Aerial Photographs and Soybean Growth and Yield. 12 pp.

Instituto Ethos. 2011. Indicadores Ethos de Responsabilidad Social Empresarial. 78 pp.

Rivas R., Ocampo D., y Carmona F. 2011. Modelo de predicción de rendimiento de trigo a partir de NDVI: aplicación en el contexto de la agricultura de precisión. 7 pp.

Stockle C., Kjelgaard J., Bellocchi G. 2004. Evaluation of estimated weather data for calculating Penman-Monteith reference evapotranspiration. *Irrigation Science*, 23:39-46.

Pereira A. 2004. The Priestley-Taylor parameter and the decoupling factor for reference evapotranspiration. *Agricultural and Forest Meteorology*, 125:305-313.

Taylor S., Raun W.R.; Solie J., Johnson G., Stone M., Whitney R. 1998. Use of spectral radiance for collecting nitrogen deficiencies and estimating soil variability in an established Bermuda grass pasture. *J. Plant Nutr.* 21 (11): 2287–2302.

Martínez-Casasnovas J., Xavier Bordes A. 2005. Viticultura de precisión: Predicción de cosecha a partir de variables del cultivo e índices de vegetación. En: *Teledetección avances en la observación de la Tierra*. Editores Arbelo M., Gonzalez A., Perez J., 33-36

De la Casa, A.; Ovando, G. 2007. Integración del Índice de Vegetación de la Diferencia Normalizada (NDVI) y del Ciclo Fenológico de Maíz para Estimar el Rendimiento a Escala Departamental en Córdoba, Argentina. *Agricultura Técnica (Chile)* 67(4): 362-371.

Stanhill, G., V. Kalkofi, M. Fuchs, and Y. Kagan. 1972. The effects of fertilizer applications on solar reflectance from a wheat crop. *Agron. J.* 69:799-802

Sridhar TS, Liberman MC, Brown MC, Sewell WF (1995) A novel cholinergic “slow effect” of efferent stimulation on cochlear potentials in the guinea pig. *J Neurosci* 15:3667–3678

Reynolds, C. A., M. Yitayew, D.C. Slack, C.F. Hutchinson, A. Huete, and M.S. Petersen, 2000.

Estimating crop yields and production by integrating the FAO Crop Specific Water Balance model with real-time satellite data and ground-based ancillary data. *Int.J. Rem. Sens.* 21:3487-3508.

Oberthür, S. and Tänzler, D. (2007). 'Climate Policy in the EU: International Regimes and Policy Diffusion', Harris, P.G. (ed.), *Europe and Global Climate Change*. Cheltenham: Edward Elgar. pp.255-278.

Massey RE, Myers DB, Kitchen NR, Sudduth KA. 2008. Profitability maps as an input for site-specific management decision making. *Agron. J.* 100: 52–59.

Wang J, Li X, Lu L, Fang F. 2013. Estimating near future regional corn yields by integrating multi-source observations into a crop growth model. *Eur. J. Agron.* 49: 126–140.

Bocco M, Sayago S, Willington E. 2014. Neural network and crop residue index multiband models for estimating crop residue cover from Landsat TM and ETM+ images. *Int. J. Remote Sens.* 35(10): 3651–3663.

Casanova, D., G.F. Epema, and J. Goudriaan, 1998. Monitoring rice reflectance at field level for estimating biomass and LAI. *Field Crops Research* 55:83-92.

Elwadie, M.E., F.J. Pierce, and J. Qi, 2005. Remote sensing of canopy dynamics and biophysical variables estimation of corn in Michigan. *Agron. J.* 97:99-105.

Gitelson, A.A., Y.J. Kaufman, and M.N. Merzlyak, 1996. Use of green channel in remote sensing of global vegetation from EOS-MODIS. *Remote Sens. Environ.* 58:289-298.

Groten, S.M.E., 1993. NDVI-crop monitoring and early yield assessment of Burkina Faso. *Int. J. Rem. Sens.* 14:1495-1515.

Mika, J., J. Kerényi, A. Rimóczi-Paál, Á. Merza, C. Szinell, and I. Csiszár, 2002. On correlation of maize and wheat yield with NDVI: Example of Hungary (1985-1998). *Adv. Space Res.* 30:2399-2404.

Mkhabela, Ma.S., Mi.S. Mkhabela, and N.N. Mashinini, 2005. Early maize yield forecasting in four agro-ecological regions of Swaziland using NDVI data derived from NOAA's-AVHRR. *Agric. For. Meteorol.* 129:1-9.

Serrano, L., I. Filella, and J. Peñuelas, 2000. Remote sensing of biomass and yield of winter wheat under different nitrogen supplies. *Crop Sci.* 40:723-731.

Shanahan, J.F., J.S. Schepers, D.D. Francis, G.E. Varvel, W.W. Wilhelm, J. M. Tringe, M.R. Schlemmer, and D.J. Mayor, 2001. Use of remote-sensing imagery to estimate corn grain yield. *Agron. J.* 93:583-589.

Smith, R.C.G., J. Adams, D.J. Stephens, and P.T. Hick, 1995. Forecasting wheat yield in a mediterranean-type environment from the NOAA satellite. *Aust. J. Agric. Research* 46:113-125.

Unganai, L., and F. Kogan, 1998. Drought monitoring and corn yield estimation in Southern Africa from AVHRR data. *Remote Sens. Environ.* 63: 219-232.

Akaike H. 1973. Information theory and an extension of the maximum likelihood principle, in 2nd International Symposium on Information Theory and Control, Petrov, E.B.N. and Csaki, F., (ed.), pp. 267

Schabenberger O. and Pierce F. 2002. *Contemporary Statistical Models for the Plant and Soil Sciences.* Taylor and Francis. CRC Press, 738 pp.

Dray S., Saïd S. and Débias F. 2008. Spatial ordination of vegetation data using a generalization of Wartenberg's multivariate spatial correlation. *J. Veg. Sci.* 19:45-56.

Gbur E.E., Stroup W.W., McCarter K.S., Durham S., Young L.J., Christman M., West M. and Kramer M. 2012. *Analysis of Generalized Linear Mixed Models in the Agricultural and Natural Resources Sciences,* ASA, CSSA, SSSA, Madison, WI.

Pearson K. 1901. On lines and planes of closest fit to systems of points in space. *Philos. Mag.* 2: 559–572.

Muñoz, J., Martínez, J. y R. Giraldo. 2006. The spatial variability of some soil properties and

their relationship with varying production in potato crop (*Solanum tuberosum* L.). *Agronomía Colombiana*, 24(2):355-366. ISSN:0120-9965.

Cai J., Liu Y., Lei T., Pereira L. 2007. Estimating reference evapotranspiration with the FAO Penman-Monteith equation using daily weather forecast messages. *Agricultural and Forest Meteorology*, 145:22-35.