

Estimación de la anomalía del rendimiento de maíz a partir de componentes principales de índices espectrales en la región agrícola de secano de Córdoba, Argentina

de la Casa, A.; Ovando, G.; Díaz, G.; Díaz, P. y Soler, F.

RESUMEN

Distintos indicadores espectrales obtenidos durante el ciclo de cultivo de maíz (*Zea mays* L.) se transformaron a partir del Análisis de Componentes Principales (ACP) para estimar la anomalía del rendimiento (ARMz) en Córdoba, Argentina, entre 2000 y 2018. Luego de corroborar la condición de multicolinealidad de los registros espectrales, se estimó ARMz aplicando el Análisis de Regresión Múltiple (AnReMu) convencional en sus tres modos característicos: i) Empleando todas las variables; ii) Con selección hacia adelante y iii) Con selección hacia atrás, para obtener modelos cuyos R^2 alcanzaron valores de 0,658, 0,609 y 0,596, respectivamente. Realizado el ACP se reiteró el AnReMu al conjunto de los primeros 6 CP para estimar ARMz y se estableció que todos los coeficientes contribuyen de manera significativa para explicar la variabilidad, si bien el modelo alcanza un R^2 de sólo 0,53. La menor performance del modelo de CP se explica porque otros factores que contribuyen en menor proporción a la variabilidad total presentan correlaciones también elevadas con ARMz. Aplicando AnReMu con selección hacia adelante al conjunto de CP, se obtuvo un modelo de 11 términos significativos con un R^2 de 0,628, similar al ajuste de los modelos que usan datos espectrales.

Palabras clave: NDVI; LST; TVDI

de la Casa, A.; Ovando, G.; Díaz, G.; Díaz, P. and Soler, F., 2022. Corn yield anomaly estimation from principal components of spectral indices in the rainfed agricultural region of Córdoba, Argentina RADA XIII: 1-14

SUMMARY

Different spectral indicators obtained during the corn (*Zea mays* L.) crop cycle were transformed from the Principal Component Analysis (PCA) to estimate the yield anomaly (ARMz) in Córdoba, Argentina, between 2000 and 2018. After corroborate the multicollinearity condition of the spectral records, ARMz was estimated by applying the conventional Multiple Regression Analysis (AnReMu) in its three characteristic modes: i) Using all the variables; ii) With forward selection and iii) With backward selection, to obtain models whose R^2 reached values of 0.658, 0.609 and 0.596, respectively. Once the PCA was

carried out, the AnReMu was reiterated to the set of the first 6 PCs to estimate ARMz and it was established that all the coefficients contribute significantly to explain the variability, although the model reaches an R^2 of only 0.53. The lower performance of the CP model is explained by the fact that other factors that contribute to a lesser extent to the total variability present also high correlations with ARMz. Applying AnReMu with forward variable selection to the CP set, a model of 11 significant terms with an R^2 of 0.628 was obtained, similar to the fit of models using spectral data.

Key words: NDVI; LST; TVDI

de la Casa, A.; Ovando, G.; Díaz, G.; Díaz, P. y Soler, F.: Facultad de Ciencias Agropecuarias, Universidad Nacional de Córdoba. Ing. Agr. Félix Aldo Marrone 746, Ciudad Universitaria. (5000) Córdoba, Argentina. Correspondencia a: delacasa@agro.unc.edu.ar

INTRODUCCIÓN

En razón de la influencia determinante de las condiciones climáticas y su variabilidad tanto anual como interanual sobre la productividad agrícola (Lobell *et al.*, 2007), es usual que las herramientas empleadas para pronosticar el rendimiento utilicen información meteorológica/climática a fin de expresar el grado de satisfacción de los requerimientos de energía y agua de un cultivo (Cai *et al.*, 2013; Wang *et al.*, 2016; Dreccer *et al.*, 2018). No obstante, también es factible para tal propósito recurrir a datos radiométricos que exponen tanto el estado y vigor de la vegetación (Seo *et al.*, 2019), como de las condiciones térmicas e hídricas prevalentes (Doraiswamy *et al.*, 2005; Lobell, 2013; Johnson, 2016; Liu *et al.*, 2020). En contraposición al carácter puntual de los datos meteorológicos, la información remota ofrece la ventaja tanto del carácter espacial de los datos como de la visión sinóptica de cada escena. Con el apoyo de procedimientos multivariados y de inteligencia artificial, algunos estudios también combinan ambas fuentes de información a los efectos de estimar la variabilidad interanual del rendimiento (Cai *et al.*, 2019; Zhu *et al.*, 2021).

A los efectos de realizar pronósticos estacionales del rendimiento de los cultivos han sido propuestos procedimientos con distinto nivel de complejidad (Basso and Liu, 2019). Una alternativa cada vez más generalizada es recurrir directa e indirectamente al uso de indicadores espectrales (IVe) para representar el estado y condición de los cultivos. El análisis de regresión que emplea los registros de rendimiento como información dependiente y los IVe como variables independientes constituye un método habitual,

utilizando a tal efecto el Índice de Vegetación de la Diferencia Normalizada (NDVI) (Mkhabela *et al.*, 2011; Nagy *et al.*, 2018), el Índice de Vegetación Mejorado de dos bandas (EVI2) (Bolton and Friedl, 2013; Liu *et al.*, 2020), el Índice de Agua de la Diferencia Normalizada (NDWI) (Bolton and Friedl, 2013) o el Índice de Vegetación de Rango Dinámico Amplio (WDRVI) (Sakamoto, 2020). Por su parte, Johnson (2014) estableció que los valores diurnos de la temperatura superficial de la tierra (LST), además de presentar una señal de respuesta especular a la del NDVI durante la temporada de cultivo, se correlacionaron negativamente con los rendimientos de maíz y de soja. Asimismo, Holzman and Rivas (2016) realizaron un pronóstico temprano del rendimiento de maíz a partir del Índice de Sequía de Temperatura de la Vegetación (TDVI), que se calcula empleando el espacio aproximadamente triangular establecido por la relación entre NDVI y LST.

El análisis de componentes principales (ACP) es una técnica multivariada que ha sido utilizada con múltiples propósitos (Jolliffe, 2002): estimar y pronosticar la productividad agrícola, tanto con información meteorológica (Cai *et al.*, 2013; Verma *et al.*, 2016) como empleando datos multiespectrales y multitemporales de reflectancia (Chang *et al.*, 2003); determinar la distribución territorial de la sequía (Mathbout *et al.*, 2018) o para diferenciar las distintas zonas de manejo en un lote (Peralta *et al.*, 2015). Dos argumentos que justifican el uso de ACP son, por una parte, la posibilidad de restringir el número de variables predictoras y, por la otra, evitar la multicolinealidad entre ellas, es decir la fuerte correlación que puede existir entre el conjunto de variables explicativas de un modelo. Tanto la cantidad de

variables sometidas a análisis como la correlación entre ellas es un problema recurrente cuando se analiza información meteorológica (Verma *et al.*, 2016). La Regresión sobre Componentes Principales (RCP) es un método apropiado para superar ambas limitaciones, ya que las variables originales se transforman en un nuevo conjunto de factores no correlacionados entre sí denominados componentes principales (CP). Además, esta transformación organiza las variables ortogonales obtenidas por orden de importancia de acuerdo a la contribución que ofrecen en el modelo, y el procedimiento implica eliminar algunas de dichas componentes para lograr una reducción de la varianza.

Meyer *et al.* (1991) utilizaron el ACP para evaluar la relación entre indicadores de sequía de Palmer (PDSI y CMI) y el rendimiento de maíz en las Grandes Planicies y el Medio Oeste de los Estados Unidos. Por su parte, Cai *et al.* (2013) desarrollaron indicadores climáticos a partir del ACP basados en tres componentes que aplican posteriormente para estimar el rendimiento de los cultivos de maíz y soja sometidos a escenarios climáticos futuros. Identificaron la heterogeneidad espacial de las respuestas del rendimiento de los cultivos al cambio climático en varios estados del Norte y Sur de EE. UU.

Utilizando ACP Schillerberg *et al.* (2019) establecieron que los primeros 5 componentes principales explican 79% y 72% de la variabilidad de las anomalías de rendimiento de los cultivos de maíz y trigo de invierno, respectivamente, y que el primer CP de la variabilidad del rendimiento de los cultivos está fuertemente asociado con la Oscilación Multidecadal Atlántica (AMO). Por su parte, El Niño Oscilación Sur (ENSO) es el fenómeno de interacción entre el Océano Pacífico ecuatorial y la atmósfera que controla las condiciones meteorológicas en gran parte de las principales regiones agrícolas del mundo (Iizumi *et al.*, 2014; Anderson *et al.*, 2017). En la provincia de Córdoba esta oscilación climática influye sobre el régimen de lluvias (de la Casa *et al.*, 2019b) y, por su condición de persistencia, es factible anticipar su impacto sobre el rendimiento de los cultivos de secano desde el mes de agosto, inmediatamente antes del comienzo de la siembra de maíz y soja en la región (de la Casa *et al.*, 2021).

El objetivo de este trabajo fue estimar la anomalía del rendimiento del cultivo de maíz en la región de secano de la provincia de Córdoba, Argentina, empleando un conjunto de datos e indicadores espectrales de MODIS mediante el análisis de componentes principales.

MATERIALES Y MÉTODOS

1. Región en estudio

La región en estudio comprende el territorio Central, Sur y Sudeste de la provincia de Córdoba, cuya ubicación geográfica muestra la Figura 1. La Figura presenta la división política provincial y señala la distribución espacial de los 11 principales departamentos productores de maíz de secano en la región. Las condiciones edafoclimáticas del territorio permiten el desarrollo de la producción agrícola de secano. Los principales suelos corresponden a Haplustoles y Arguiduoles que, en general, son profundos y bien drenados. El clima de la región se clasifica como templado, con temperaturas promedio en verano de aproximadamente 23,5°C en tanto que la temperatura promedio en invierno ronda los 8°C. La precipitación se concentra en primavera y verano, con un valor promedio anual de alrededor de 800 mm (Jarsún *et al.*, 2003; Meade *et al.*, 2016; Aliaga *et al.*, 2017). Los principales cultivos en esta área, que en su mayoría se realizan bajo sistema de siembra directa, corresponden a soja, maíz y, en menor medida, trigo. El cultivo de maíz en la provincia de Córdoba ocupa actualmente alrededor de 3 millones de hectáreas (BCCBA, 2022).

2. Datos de rendimiento de maíz

Los datos de rendimiento de maíz, entre 2000 y 2018, para los 11 principales departamentos de producción de secano de la provincia de Córdoba fueron proporcionados por el Ministerio de Agricultura, Ganadería y Pesca de Argentina (MAGyP, 2020). Estos datos de rendimiento se expresaron en términos de la anomalía (ARMz) que se obtuvo, como muestra la Figura 2 para el departamento Marcos Juárez, haciendo la diferencia entre el rendimiento de cada departamento y año (RMz_{di}) y un valor de índole tecnológico (T_{di}). En este caso, el aporte tecnológico se consideró a partir de la recta de regresión lineal entre los datos de rendimiento y el tiempo (años). Tanto en Marcos Juárez como para el resto de los departamentos, las pendientes lineales no presentan un incremento o decrecimiento significativo, de modo que la línea de tendencia se aproxima al valor medio. A partir de este comportamiento se interpreta que la base tecnológica del cultivo de maíz se ha mantenido relativamente constante en la región a lo largo de los primeros años del siglo XXI.

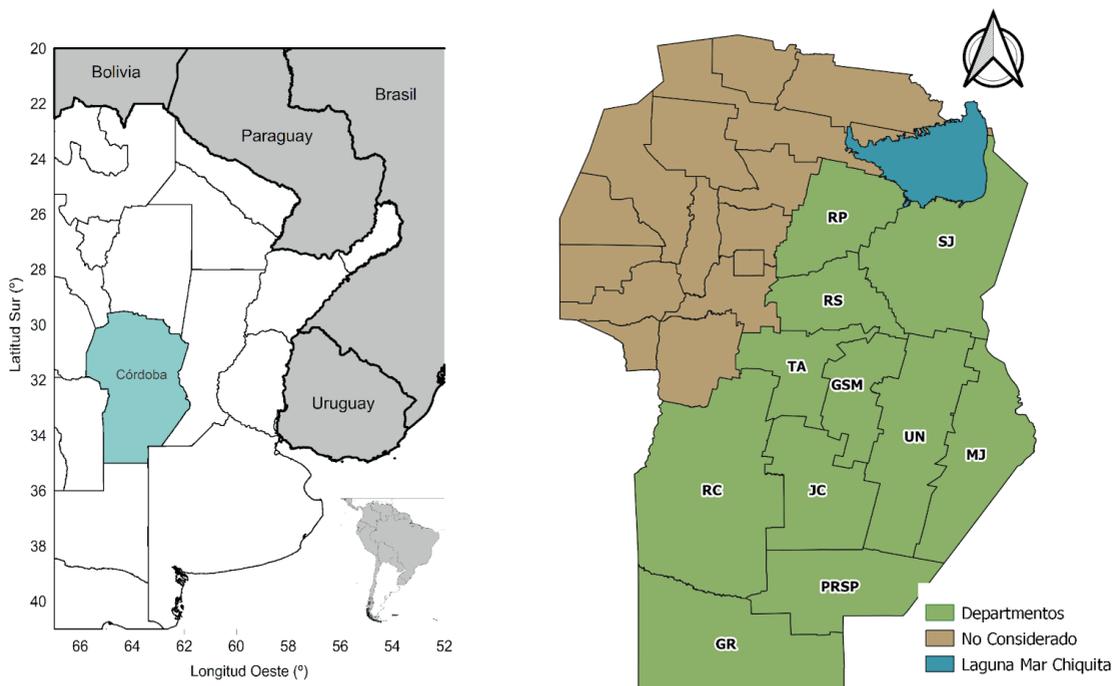


Figura 1. Departamentos de la provincia de Córdoba que integran la región de producción de maíz de secano. Departamentos: RP=Río Primero, SJ=San Justo, RS=Río Segundo, TA=Tercero Arriba, GSM= General San Martín, UN= Unión, MJ= Marcos Juárez, RC= Río Cuarto, JC= Juárez Célman, PRSP= Presidente Roque Sáenz Peña, GR= General Roca.

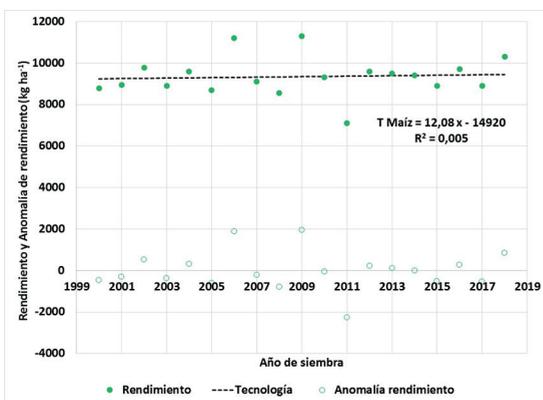


Figura 2. Rendimientos de maíz, valores de la tendencia calculada a partir de una regresión lineal para representar la influencia del aporte tecnológico de largo plazo y la anomalía del rendimiento de maíz para el departamento de Marcos Juárez entre 2000 y 2018.

3. Datos radiométricos

3.1 Índice de Vegetación de la Diferencia Normalizada (NDVI) y temperatura de superficie de la tierra (LST).

En este estudio se utilizaron datos de NDVI y registros diurnos de LST correspondientes a períodos mensuales. La fuente de estos datos

son los productos MOD13C2 y MOD11C3, respectivamente, derivados del sensor MODIS a bordo del satélite TERRA. Para cubrir la extensión completa del ciclo de cultivo en la región, el análisis comprende el periodo desde octubre de un año hasta abril del siguiente.

3.2 Índice de Sequía de la Temperatura de la Vegetación (TVDI)

A partir del espacio triangular conformado por los datos de NDVI y LST también se obtuvo, de acuerdo al esquema de cálculo propuesto por Sandholt *et al.* (2002), el Índice de sequía de temperatura de la vegetación (TVDI), que fue utilizado para representar la disponibilidad de agua y estimar el rendimiento de maíz (Holzman and Rivas, 2016).

4 Datos del ENSO

Dos conjuntos de datos se utilizaron como proxy del ENSO: i) el Índice de Oscilación Sur (SOI), una señal atmosférica relacionada con la variabilidad de las precipitaciones y el NDVI en la provincia de Córdoba (de la Casa y Ovando, 2006; de la Casa *et al.*, 2019b) y ii) la anomalía de temperatura

superficial del mar (ATSM) en la región El Niño 3.4 (de la Casa *et al.*, 2021).

4.1. Datos SOI

El SOI representa la anomalía de la variación de la presión atmosférica en Tahití y Darwin, dos sectores opuestos del Océano Pacífico tropical (Chowdhury and Beecham, 2010). La serie de tiempo SOI se obtuvo de la Oficina de Meteorología del Gobierno de Australia (Bureau of Meteorology, 2019). De acuerdo a la Oficina Meteorológica de Australia, mientras los valores de SOI negativos que se sostienen por debajo de -8 indican episodios de El Niño, los valores de SOI positivos por encima de +8 son típicos de los episodios La Niña. Los valores de SOI entre ambos límites se consideran casos neutrales.

4.2 Datos de Anomalía de la Temperatura de la Superficie del Mar (ATSM)

Debido a que el término El Niño (La Niña) se refiere al calentamiento (enfriamiento) extenso que experimenta el Océano Pacífico tropical central y oriental, otra forma de describir la oscilación entre las fases El Niño y La Niña es utilizando la temperatura de la superficie del mar y, de manera más específica, su anomalía respecto a un valor medio de referencia (Barnston *et al.*, 1997). Diferentes ubicaciones geográficas se han propuesto como regiones del origen de la señal. En este caso, se utilizan datos de la región de El Niño 3.4 (5° N – 5° S, 120-170° W), en tanto la fuente de datos es la misma que para SOI. Valores persistentes inferiores a -0,8 °C son típicos de La Niña, mientras valores persistentes superiores a +0,8 °C corresponden a los episodios El Niño.

5. Procedimientos de análisis

El análisis de componentes principales (ACP) se aplicó para integrar la información radiométrica durante toda la extensión del ciclo de cultivo y evaluar su contribución particular sobre la variabilidad interanual de la anomalía del rendimiento de maíz en la región. A tal efecto, se obtuvieron y compararon modelos de estimación obtenidos del AnReMu que utilizan alternativamente los datos radiométricos originales y los factores que produce el ACP. Además, el ACP se aprovechó también en su capacidad de clasificación para evaluar la dependencia de la información espectral con respecto a la señal de teleconexión que el ENSO origina en la región de estudio.

En primer término se realizó el AnReMu al conjunto completo de datos e información espectral y los resultados se enmarcaron en una evaluación regional. A los efectos de obtener modelos lineales para estimar la anomalía de rendimiento de maíz, el procedimiento se aplicó haciendo uso de sus 3 alternativas: i. Incorporando todas las variables (21); ii. Haciendo una selección de variables hacia adelante (en cada paso el modelo incorpora una variable al conjunto de predictores que satisface ciertas restricciones estadísticas); y iii. Haciendo una selección de variables hacia atrás (en cada paso el modelo elimina una variable del conjunto de predictores que no satisface ciertas restricciones estadísticas).

Posteriormente, se aplicó el análisis de componentes principales (ACP) a la base de datos integrada por el conjunto de indicadores (NDVI, TDVI y LST), donde los 7 meses del ciclo de cultivo dieron lugar a las columnas (7x3) y los años analizados (19) en los 11 departamentos que integran la región a las filas de la matriz. La estructura de variabilidad se exploró a partir de los autovalores o elementos de la matriz de correlación y el conjunto de variables analizadas y suplementarias (no interviene en la determinación) se describieron a partir del plano factorial integrado por el primer y segundo factor (componente). El método de "scree" (resto) se utilizó para retener los factores de interés que se emplearon luego en el análisis de regresión múltiple (ARM). Asimismo, los modelos obtenidos del ARM se constituyeron empleando factores sólo de carácter significativo.

Finalmente, a partir de los CP obtenidos se procedió a obtener modelos de regresión múltiple para estimar ARMz aplicando el AnReMu. En primer término se emplearon sólo los CP que surgen del método "scree" y, por último, apelando al procedimiento de selección de factores hacia delante.

RESULTADOS Y DISCUSIÓN

1. Multicolinealidad en los datos e indicadores espectrales.

La Tabla 1 contiene los coeficientes de correlación entre los datos e indicadores espectrales evaluados en el estudio a escala mensual, clasificados siguiendo un criterio colorimétrico para facilitar su evaluación. Los valores analizados se extienden entre los meses de octubre y abril del año siguiente, periodo que abarca en su totalidad el ciclo de cultivo de maíz

en la región, desde la etapa que precede a la siembra hasta la posterior a su final. Mientras la relación del NDVI, tanto con LST como con TVDI, se presenta inversa en términos generales (Johnson, 2014; Johnson, 2016), ya que la acumulación de biomasa de acuerdo a la señal del NDVI se reduce en respuesta a la intensidad del estrés hídrico, la que se suscita entre ambos indicadores de estrés, en cambio, resulta de carácter positiva. Este resultado es congruente porque la interpretación física de ambas expresiones es análoga. El incremento de LST expresa una condición de estrés asociada a la falta de agua en la medida que, para una situación particular del balance de energía, el aumento térmico se interpreta que ocurre como consecuencia de haber disminuido la capacidad refrigerante que promueve el proceso de evapotranspiración del cultivo. Por su parte, la influencia de la falta de agua sobre la temperatura

del cultivo en el caso de TVDI es ponderada de acuerdo a la condición de cobertura del suelo que presenta el cultivo, en relación directa con el valor de NDVI (Moran *et al.*, 1994; de la Casa *et al.*, 2013).

Dentro de cada mes LST está más correlacionada con TDVI que con NDVI (con valores de r superiores a 0,72). La relación NDVI - TDVI presenta la correlación más elevada ($r = -0,887$) en enero, siendo los valores de r más bajos tanto al comienzo de la estación de cultivo (octubre), como al final (marzo - abril). Estos resultados concuerdan con los obtenidos por Sun and Kafatos (2007) en Estados Unidos, que determinaron el valor de r más negativo (-0.89) en el mes de julio. En tal sentido, Karnieli *et al.* (2010) al analizar el espacio triangular/trapezoidal entre LST-NDVI, a partir de datos de bimestrales encontraron dos grandes grupos de puntos: uno con la típica pendiente

Tabla 1. Mapa de color del coeficiente de correlación (r) entre los valores mensuales de los datos e indicadores espectrales (NDVI, LST y TVDI) durante el ciclo de maíz en Córdoba, Argentina.

	NDVI						LST						TVDI										
	oct	nov	dic	ene	feb	mar	abr	oct	nov	dic	ene	feb	mar	abr	oct	nov	dic	ene	feb	mar	abr		
NDVI	1,00																						
nov	0,84	1,00																					
dic	0,14	0,35	1,00																				
ene	0,03	0,09	0,57	1,00																			
feb	-0,36	-0,45	-0,06	0,58	1,00																		
mar	-0,33	-0,42	-0,42	0,09	0,70	1,00																	
abr	0,07	0,02	-0,45	-0,31	0,05	0,60	1,00																
LST	-0,65	-0,64	-0,11	-0,08	0,34	0,38	0,16	1,00															
nov	-0,58	-0,79	-0,26	-0,28	0,17	0,15	-0,20	0,54	1,00														
dic	-0,21	-0,27	-0,70	-0,45	0,06	0,31	0,19	0,14	0,29	1,00													
ene	-0,11	-0,21	-0,41	-0,89	-0,55	-0,20	0,10	0,14	0,43	0,42	1,00												
feb	0,35	0,40	0,04	-0,42	-0,75	-0,57	-0,01	-0,19	-0,21	0,00	0,43	1,00											
mar	0,15	0,03	0,27	-0,08	-0,38	-0,64	-0,52	-0,03	0,26	-0,21	0,31	0,46	1,00										
abr	-0,14	-0,24	0,09	-0,10	-0,08	-0,30	-0,51	0,22	0,54	0,15	0,21	0,28	0,53	1,00									
TVDI	-0,25	-0,32	-0,12	-0,01	0,23	0,29	0,29	0,77	0,26	0,10	0,08	0,01	-0,01	0,05	1,00								
nov	-0,29	-0,58	-0,21	-0,21	0,09	0,13	-0,11	0,36	0,85	0,16	0,37	-0,12	0,34	0,38	0,30	1,00							
dic	-0,25	-0,26	-0,52	-0,33	0,08	0,30	0,25	0,26	0,22	0,88	0,32	0,11	-0,21	0,13	0,30	0,16	1,00						
ene	0,00	-0,11	-0,35	-0,77	-0,52	-0,14	0,18	0,18	0,38	0,40	0,87	0,55	0,32	0,33	0,19	0,40	0,39	1,00					
feb	0,25	0,20	-0,10	-0,43	-0,58	-0,43	-0,03	-0,11	0,09	0,23	0,55	0,79	0,51	0,27	0,04	0,17	0,22	0,64	1,00				
mar	0,09	-0,03	0,24	0,11	-0,12	-0,36	-0,44	0,12	0,25	-0,11	0,13	0,22	0,79	0,35	0,09	0,37	-0,10	0,21	0,41	1,00			
abr	-0,16	-0,21	0,11	0,06	0,13	-0,04	-0,15	0,37	0,31	0,13	0,04	0,17	0,27	0,73	0,31	0,23	0,25	0,19	0,17	0,26	1,00		

Referencias: $r \geq$ -1 -0,80 -0,60 -0,40 -0,20 0,00 0,20 0,40 0,60 0,80 1

negativa, indicando condiciones de crecimiento vegetal limitado por el contenido de humedad del suelo, y una segunda clase con una pequeña pendiente positiva que muestra poca variabilidad de LST en todo el rango de NDVI, por lo que el valor de correlación general estaría influenciado por las proporciones de estos dos grupos presentes en el área de estudio.

Otro aspecto para destacar de la Tabla 1 es el predominio de los valores de correlación de carácter significativo, particularmente cuando las variables se contrastan entre sí. El análisis entre los distintos meses del ciclo para el mismo indicador, en cambio, tiende a producir correlaciones más elevadas sólo con respecto al mes subsecuente. De esta manera, se manifiesta con claridad la condición de multicolinealidad que presenta este conjunto de variables espectrales, especialmente cuando su propósito es servir de información independiente en un modelo de estimación o predicción del rendimiento.

2. Estimación de la productividad de maíz para la región de secano a partir de los datos e indicadores espectrales.

Los datos e indicadores espectrales mensuales (LST, NDVI y TVDI) en una primera etapa se emplean directamente como variables independientes en un análisis clásico de regresión múltiple. A tal efecto, el procedimiento se aplicó primero considerando la influencia de todas las variables independientes y, luego, realizando una selección estadística de variables hacia adelante (incorporando) y hacia atrás (descartando). Los resultados obtenidos a partir del conjunto completo de datos e indicadores espectrales muestran en la Tabla 2 que la sumatoria de términos lineales explica alrededor de 65,6% de la variabilidad de la anomalía del rendimiento de maíz, aunque sólo 7 de ellas, además de la ordenada al origen, alcanzan un carácter significativo ($p < 0,05$). La inclusión de todas las variables modifica los grados de libertad del Análisis de Varianza (ANAVA) y reduce el valor del ajuste, como lo señala el R^2 aj ligeramente más bajo (0,617).

La interpretación causal de los términos significativos del modelo lineal se presenta confusa. Asociado a la estimación del volumen de biomasa presente, mientras el NDVI en noviembre tiene un coeficiente negativo incongruente con respecto a la anomalía de rendimiento, el de diciembre, en cambio, resulta positivo y es más razonable para explicar las variaciones de la productividad del

maíz. Por su parte, la información de LST en los meses de enero, febrero y marzo corresponde a coeficientes de signo negativo, de modo que el aumento de la temperatura durante este lapso tiende a producir anomalías negativas de rendimiento en respuesta a una situación de estrés hídrico en las etapas reproductivas del cultivo de maíz. El TVDI en febrero y marzo, por el contrario, es otro indicador de estrés hídrico que muestra una inesperada contribución positiva sobre el rendimiento.

Tabla 2. Intercepción y coeficientes de regresión (b) con su error estándar de estimación y los valores de t de Student con su valor de probabilidad (p) del modelo de regresión múltiple para estimar la anomalía de rendimiento de maíz en la región de secano de Córdoba.

	<i>b</i>	<i>Std.Err.</i>	<i>t(187)</i>	<i>Valor de p</i>
Intercepción	225548,8	54911,01	4,10753	0,000060
NDVI_oct	1989,4	1855,37	1,07226	0,284985
NDVI_nov	-6430,7	2937,00	-2,18954	0,029796
NDVI_dic	5568,9	1625,37	3,42623	0,000752
NDVI_ene	-4372,7	2351,40	-1,85962	0,064511
NDVI_feb	-4095,1	2568,46	-1,59438	0,112541
NDVI_mar	2035,4	2754,42	0,73894	0,460868
NDVI_abr	4125,1	2149,33	1,91924	0,056476
LST_oct	-60,0	55,91	-1,07396	0,284225
LST_nov	3,0	99,97	0,02954	0,976465
LST_dic	83,9	76,02	1,10374	0,271122
LST_ene	-299,8	78,40	-3,82425	0,000179
LST_feb	-230,8	95,66	-2,41262	0,016804
LST_mar	-213,4	85,25	-2,50268	0,013183
LST_abr	-35,7	84,55	-0,42212	0,673424
TVDI_oct	1868,1	1006,07	1,85684	0,064907
TVDI_nov	494,1	1708,10	0,28925	0,772708
TVDI_dic	-2468,1	1622,82	-1,52087	0,129982
TVDI_ene	-1347,3	1250,47	-1,07747	0,282659
TVDI_feb	2991,5	1354,61	2,20843	0,028430
TVDI_mar	3937,8	1378,78	2,85599	0,004776
TVDI_abr	538,1	1088,67	0,49429	0,621680

Por su parte, el AnReMu que realiza la selección de variables hacia adelante (con un valor del estadístico F de Fisher para entrar de 4 y un F para sacar de 1), de acuerdo a los resultados de la Tabla 3, excluye por completo las variables que no presentan una contribución significativa en la variabilidad de la anomalía productiva. Esta reducción de la base de información tiene el costo de disminuir ligeramente el R^2 a 0,608. No obstante, la extracción de información poco explicativa de la variabilidad no modifica sustancialmente el R^2 ajustado del modelo completo, que alcanza en este caso un valor de 0,596.

Tabla 3. Intercepción y coeficientes de regresión (b) con su error estándar de estimación y los valores de t de Student con su valor de probabilidad (p) del modelo de regresión múltiple que selecciona las variables hacia adelante para estimar la anomalía de rendimiento de maíz en la región de secano de Córdoba.

	b	Std.Err.	t(201)	Valor de p
<i>Intercepción</i>	133890,4	19110,00	7,00630	0,000000
<i>LST_ene</i>	-242,1	27,72	-8,73368	0,000000
<i>LST_abr</i>	-69,2	34,14	-2,02677	0,044007
<i>LST_nov</i>	79,0	34,19	2,31075	0,021861
<i>NDVI_dic</i>	2995,8	804,47	3,72393	0,000255
<i>NDVI_abr</i>	5189,0	1007,09	5,15247	0,000001
<i>LST_feb</i>	-229,5	62,26	-3,68563	0,000293
<i>TVDI_feb</i>	2888,4	947,92	3,04713	0,002621

Finalmente, el AnReMu con el método de selección hacia atrás produce un modelo de estimación más parsimonioso que incluye, además de la constante, a otros 5 términos lineales (Tabla 4). Mientras el NDVI en diciembre y abril presenta una contribución positiva sobre la productividad, los valores de temperatura de superficie (LST) de enero y febrero exponen una correlación negativa que, asociada a la condición de estrés hídrico durante periodos críticos del cultivo, explica la ocurrencia de mermas en el rendimiento. Más difícil de justificar resulta la relación directa de TVDI con la anomalía del rendimiento ya que se trata, al igual que LST, de un indicador de estrés hídrico. Es interesante destacar que la extracción de 2 variables no modifica sustancialmente el valor de R^2 ni de R^2 aj (0,5964 y 0,5864, respectivamente) que produce el modelo con selección hacia adelante, poniendo en evidencia la menor importancia predictiva de LST en los meses de noviembre y abril.

Tabla 4. Intercepción y coeficientes de regresión (b) con su error estándar de estimación y los valores de t de Student con su valor de probabilidad (p) del modelo de regresión múltiple que selecciona las variables hacia atrás para estimar la anomalía de rendimiento de maíz en la región de secano de Córdoba.

	b	Std.Err.	t(203)	Valor de p
<i>Intercepción</i>	157723,3	14485,13	10,88863	0,000000
<i>NDVI_dic</i>	2941,8	803,17	3,66281	0,000318
<i>NDVI_abr</i>	5662,1	853,93	6,63067	0,000000
<i>LST_ene</i>	-209,0	23,36	-8,94710	0,000000
<i>LST_feb</i>	-331,5	45,66	-7,25938	0,000000
<i>TVDI_feb</i>	3596,3	904,57	3,97573	0,000098

La incorporación preferencial de variables relacionadas a la condición de estrés hídrico es consistente con la propuesta de Meyer *et al.* (1991), que utilizaron como variables independientes de sus modelos predictivos a indicadores de sequía (Índice de Severidad de Sequía de Palmer (PDSI) e Índice de Humedad del Cultivo (CMI)) para

analizar la variación del rendimiento de maíz en regiones de secano de USA. Al igual que en el área en estudio, la disponibilidad de agua constituye la principal limitante de la productividad agrícola (Bodner *et al.*, 2015; Rattalino Edreira *et al.*, 2018; de la Casa *et al.*, 2019a).

3. Estimación de la productividad de maíz para el conjunto de la región de secano a partir de los componentes principales

Visto el alcance del AnReMu para estimar la anomalía de rendimiento de maíz empleando directamente información de origen satelital, se analiza ahora el procedimiento análogo pero utilizando las nuevas variables ortogonales que suscita el ACP. Aplicada la transformación de CP al conjunto de 21 variables objeto del análisis se obtiene la información de la Tabla 5, que resume y ordena la proporción de variabilidad explicada por cada uno de los autovalores. Considerando que la variabilidad total corresponde al conjunto de 21 variables transformadas (la suma del porcentaje de cada una totaliza 100% de la variabilidad), mientras los primeros factores que extrae el análisis muestran una contribución notablemente más importante, los últimos, en cambio, explican una proporción de la variabilidad sólo residual. Para la región de producción de maíz de secano de Córdoba los primeros 7 factores explican aproximadamente 90% de la variabilidad y, de esta forma, el procedimiento lograría en principio reducir a un tercio el conjunto de variables candidatas originales.

Como muestra la Tabla 5, el número de CP o factores seleccionados que fueron utilizados posteriormente para el AnReMu de acuerdo a la prueba "scree" (Cattell, 1966) corresponde a 6, que comprende 85,6% de la varianza total. Precisamente, el criterio que se aplica en este caso es retener para el análisis posterior sólo los autovalores mayores a 1.

Tabla 5. Autovalores y variabilidad total y acumulada para las variables (3 x 7) del análisis regional.

	Autovalores	% Variabilidad total	Autovalores acumulados	% Variabilidad total acumulada
1	5,487	26,128	5,487	26,128
2	4,988	23,752	10,475	49,880
3	3,533	16,826	14,008	66,706
4	1,564	7,449	15,573	74,155
5	1,388	6,611	16,961	80,767
6	1,012	4,817	17,973	85,584
7	0,751	3,577	18,724	89,161

Como muestra la Figura 3a, la mayor correlación del primer factor se presenta en el mes de enero, tanto para la variable LST (-0,805) como para TVDI (-0,824), señalando en ambos casos que el primer CP se encuentra ligado a factores de riesgo por estrés hídrico en un momento del ciclo que resulta particularmente sensible para el maíz. Por su parte, el segundo CP presenta la correlación más alta para los valores de NDVI en los meses de febrero (0,799) y marzo (0,848). De esta forma, de acuerdo tanto a LST como a TVDI se interpreta que un eventual episodio de estrés hídrico durante etapas sensibles a la falta de agua como el comienzo de las fases reproductivas en maíz (panojamiento, polinización y fecundación), repercute de manera negativa no sólo sobre el rendimiento, sino que estaría asociado también a una merma en la acumulación de biomasa.

Por su parte, la introducción de la anomalía de rendimiento (ARMz) a la representación gráfica como una variable suplementaria (no participa de la transformación), de acuerdo a la Figura 3b muestra una vinculación consistente con la estructura de variabilidad de los datos en el espacio factorial determinado por los dos primeros factores. En un sentido explicativo, presenta una aproximación positiva tanto con respecto a los valores de NDVI (asociada a la producción de biomasa) en enero (más ligado al primer factor) y en febrero y marzo, más vinculado con el segundo. Por el contrario, las variables relacionadas al estrés (LST y TVDI) durante el mes de enero se interpreta que estarían asociadas de manera negativa con la anomalía de rendimiento (ya que un mayor estrés traería aparejado una reducción del rendimiento).

Por otra parte, la inclusión de la variable SOLas al espacio factorial muestra asimismo su vinculación inversa tanto con CP1 como CP2, y confirma la influencia de los episodios ENSO sobre la productividad agrícola en la región agrícola de secano de Córdoba (de la Casa *et al.*, 2021). La ATSM de diciembre, en cambio, presenta valores de correlación de igual naturaleza y muy similares a los de ARMz, expresando en el mismo sentido que la fase caliente (fría) de los episodios ENSO se vinculan con las anomalías positivas (negativas) de rendimiento. A partir de un ACP rotado, Schillerberg *et al.* (2019) reportaron que los primeros cinco componentes principales explican el 79% (maíz) y el 72% (trigo de invierno) de la variabilidad espacial y temporal de las anomalías de rendimiento de estos cultivos en numerosas regiones de los Estados Unidos de América; en tanto el primer componente principal de la variabilidad del rendimiento de los cultivos

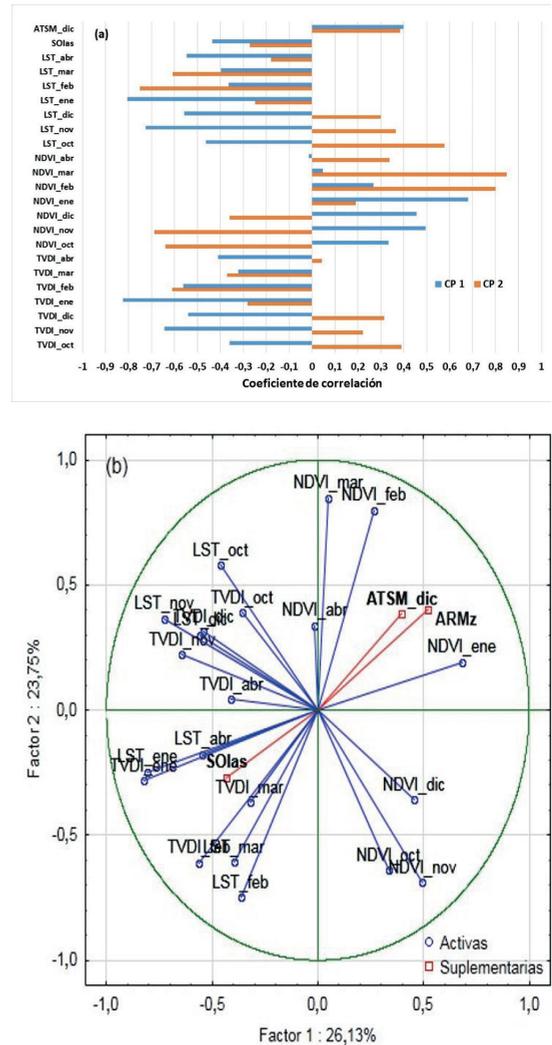


Figura 3.(a) Correlación entre las variables radiométricas mensuales (LST, NDVI y TVDI) y los 2 primeros factores del Análisis de Componentes Principales. (b) Anomalía de rendimiento de maíz (ARMz), Índice de Oscilación Sur de agosto y setiembre (SOLas), Anomalía de la Temperatura de la Superficie del Mar de diciembre (ATSM) (variables suplementarias) y el conjunto de índices radiométricos (variables activas) en el espacio factorial 1 X 2.

se mostró fuertemente asociado con la Oscilación Multidecadal Atlántica (AMO).

Como muestra la Figura 4, la introducción de los valores mensuales tanto de SOI como de ATSM al espacio factorial que conforman los 2 primeros CP, más allá de su carácter inverso, permite reconocer de manera anticipada la capacidad predictiva que presentan las señales oceánica y atmosférica acerca del potencial productivo de cada ciclo agrícola. Además, la persistencia de la

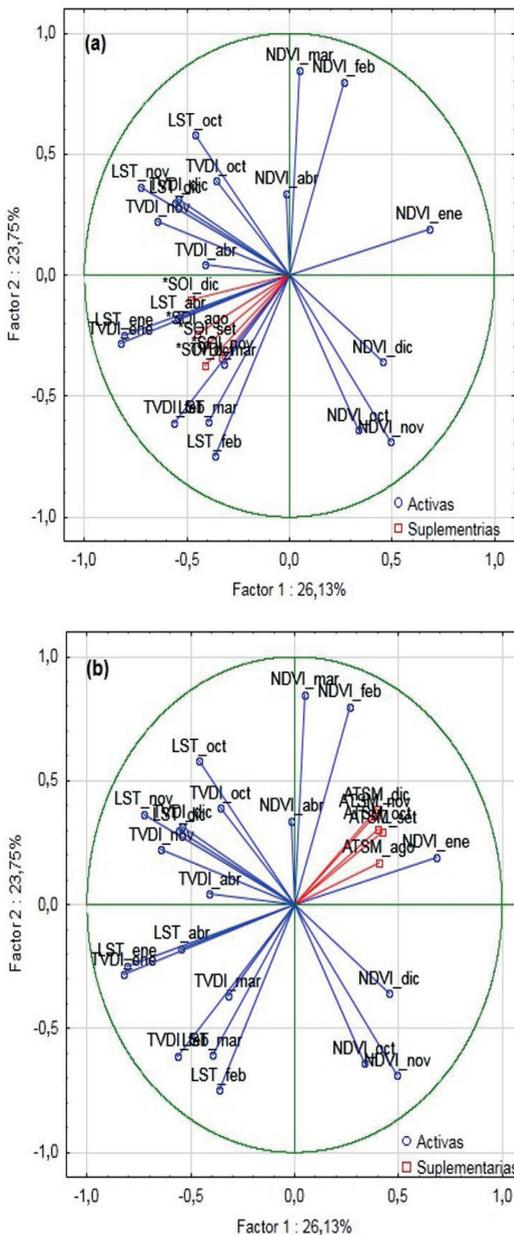


Figura 4. (a) Proyección del Índice de Oscilación Sur (SOI) y (b) de la Anomalia de la Temperatura de la Superficie del Mar (ATSM) desde agosto hasta diciembre (variables suplementarias) en el espacio factorial 1 X 2.

señal se verifica porque las correlaciones de los indicadores del ENSO con respecto a ambos CP son relativamente similares entre agosto (antes de la siembra de maíz) y diciembre (cuando el cultivo está completando las etapas vegetativas).

A partir de los 6 primeros factores ortogonales identificados y aplicado el análisis de regresión

lineal múltiple convencional para estimar ARMz, se obtienen los coeficientes de correlación y regresión que muestra la Tabla 6. Para una ordenada al origen que tiende a cero en correspondencia a un valor de anomalía, todos los factores presentan el carácter significativo ($p < 0,05$). Por su parte, el coeficiente de determinación (R^2) presenta un valor de 0,53, en tanto el R^2 ajustado por el número de términos considerados se reduce escasamente a 0,52, lo que avala la interpretación de que todos los factores considerados aportan de manera efectiva para explicar la variabilidad.

Tabla 6. Intercepción y coeficientes de regresión (b) con su error estándar de estimación y los valores de t de Student con su valor de probabilidad (p) del modelo de regresión múltiple que estima la anomalía del rendimiento de maíz a partir de los primeros 6 componentes principales (CP) derivados de la matriz de datos e indicadores radiométricos.

	<i>b</i>	Error típico	Valor de t	Valor de p
Intercepción	-2,0912E-11	54,4445086	-3,8409E-13	1
CP 1	251,898	23,2986463	10,8116855	8,619E-22
CP 2	203,066	24,4362824	8,31000034	1,384E-14
CP 3	-89,635	29,0336363	-3,08727474	0,00230371
CP 4	-130,661	43,6344683	-2,99443979	0,00309306
CP 5	121,23	46,3167011	2,62373414	0,00936116
CP 6	238,973	54,2607897	4,40415725	1,721E-05

No obstante, el modelo conformado con los 6 CP que capturan el 86% de la variabilidad de los datos originales sólo alcanza a explicar aproximadamente la mitad de la variabilidad de ARMz. Este comportamiento muestra, por una parte, que la información radiométrica utilizada tiene un alcance limitado en su capacidad de estimar la productividad agrícola y, por el otro, que la región tiene un comportamiento productivo heterogéneo, tanto por sus diferentes condiciones edáficas (tipo de suelo y capacidad de retención de agua) como por las técnicas y manejo particular (fechas de siembra). Esta diversidad justificaría un análisis pormenorizado por departamento.

La menor performance predictiva del modelo obtenido a partir de las primeras 6 CP (0,53) comparado al modelo lineal que utiliza todas las variables o que se restringe sólo a emplear las significativas, se explica porque otros factores que contribuyen en menor proporción a la variabilidad total ("scree"), presentan correlaciones también elevadas con ARMz. Esta conjetura se sostiene por medio de un AnReMu que realiza una selección hacia adelante del conjunto de CP. En este caso, como muestra la Tabla 7, se obtuvo un modelo

de 11 términos (factores) todos significativos que produce un R^2 de 0,628 (R^2 ajustado de 0,608), similar a los coeficientes de ajuste de los modelos que usan los datos espectrales.

Tabla 7. Intercepción y coeficientes de regresión (b) con su error estándar de estimación y los valores de t de Student con su valor de probabilidad (p) del modelo de regresión múltiple que selecciona hacia adelante los componentes principales (CP) para estimar la anomalía de rendimiento de maíz en la región de secano de Córdoba.

	b	Std.Err.	t(187)	Valor de p
Intercepción	0,000	49,1563	0,00000	0,999997
CP 1	251,898	21,0356	11,97480	0,000000
CP 2	203,066	22,0628	9,20399	0,000000
CP 6	238,973	48,9904	4,7795	0,000002
CP 13	-493,489	117,8522	-4,18735	0,000043
CP 3	-89,635	26,2136	-3,41940	0,000763
CP 4	-130,661	39,3962	-3,31658	0,001085
CP 12	381,996	116,1747	3,28812	0,001194
CP 9	-224,390	76,6964	-2,92569	0,003840
CP 18	729,149	250,8477	2,90674	0,004071
CP 5	121,523	41,8180	2,90599	0,004080
CP 20	-827,194	354,4839	-2,33352	0,020630

Los resultados de la Tabla 7 muestran los coeficientes del modelo lineal, como así también el valor de t cuya magnitud se reduce desde arriba hacia abajo, a medida que crece la probabilidad de error. Este ordenamiento de los términos permite advertir que el CP 13 se incorpora al modelo primero que CP 3 y CP 4, y que el CP 12 lo hace antes que CP 9 y CP 5. De esta forma, si bien el ACP transforma la matriz original de datos radiométricos e introduce un conjunto de variables ortogonales (no correlacionadas entre sí) que están relacionadas estrechamente con la productividad del maíz, principalmente los dos primeros CP, se observa que existen factores que influyen en menor proporción sobre la varianza pero tienen una estrecha correlación con la variable respuesta. Esta particularidad fue señalada antes por Hadi and Ling (1998) y justifica el uso de procedimientos destinados a la selección de variables (Cai *et al.*, 2013).

Por último, la Figura 5 presenta el análisis de correlación y regresión entre los valores observados y estimados de ARMz a partir de los modelos que utilizan, por una parte, el conjunto completo de la información espectral (de acuerdo a los coeficientes de regresión de la Tabla 2) y, por la otra, los CP derivados de la información espectral (según los coeficientes de la Tabla 7). No

sólo los coeficientes de determinación presentan un valor moderado en ambos casos, que en términos del R^2 ajustado resultan muy similares (0,617 en el primer caso y 0,608 para el segundo), sino que la recta de ajuste en uno y otro se aparta de la función identidad y muestra la tendencia a subestimar tanto las anomalías de rendimiento positivas como negativas. De esta forma, más allá de utilizar directamente las variables espectrales o sus valores transformados de carácter ortogonal, la capacidad predictiva resultante no difiere de manera sustancial.

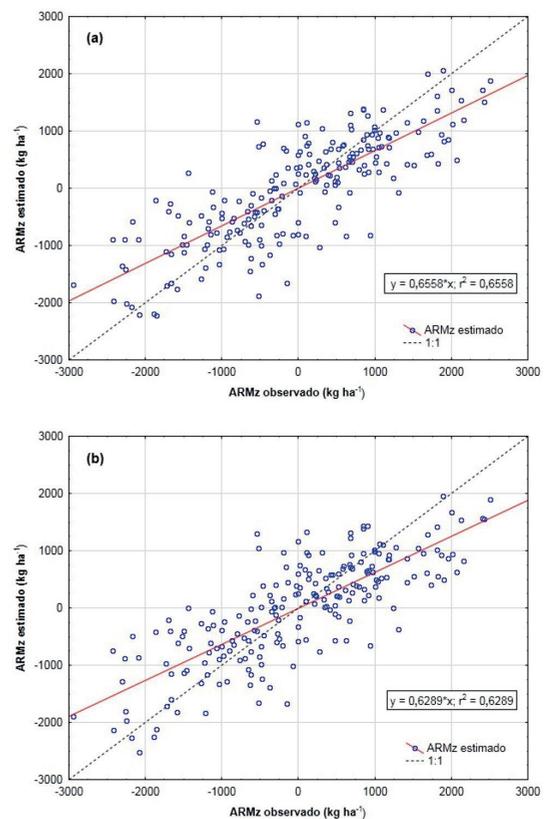


Figura 5. Relación entre la anomalía de rendimiento de maíz (ARMz) observada y estimada a partir de los modelos de regresión múltiple determinados a partir de (a) el conjunto de variables espectrales y (b) la selección hacia adelante de componentes principales en la región de secano de Córdoba, Argentina. Incorporadas se presentan la función de ajuste y la función de identidad (1:1).

La Tabla 8 presenta con propósitos comparativos las medidas de ajuste y error de los modelos desarrollados. Además de la heterogénea aptitud productiva de la región en estudio, donde algunos departamentos presentan condiciones edafoclimáticas más propicias que otros para la

producción de maíz, los episodios ENSO que se pueden valorar con anticipación al comienzo del ciclo de producción agrícola, constituyen otro factor relacionado con la productividad agrícola que se debe considerar especialmente a fin de desarrollar herramientas predictivas más precisas. Estos eventos alcanzan su punto máximo en el invierno boreal, cuando las anomalías de la circulación atmosférica se intensifican e impactan sobre los cultivos de maíz y la soja en el sureste de América del Sur (Anderson *et al.*, 2017; de la Casa *et al.*, 2021).

Tabla 8. Coeficiente de determinación (R^2) y su valor ajustado por los grados de libertad (R^2_{aj}), F de Fisher y su valor de probabilidad (p) y Raíz cuadrada del error medio (RMSE) de los modelos de regresión múltiple desarrollados con todas las variables y mediante selección hacia adelante y hacia atrás, a partir de índices espectrales (IVE) y de su transformación en componentes principales (CP).

	R^2	R^2_{aj}	F	RMSE (kg ha ⁻¹)
IVE				
Todas	0,6558	0,6171 (21;187)=	16,97	666,05
Hacia adelante	0,6087	0,5951 (7;201)=	44,67	710,15
Hacia atrás	0,5964	0,5864 (5;203)=	59,99	721,25
CP				
Todas	0,6558	0,6171 (21;187)=	16,97	666,05
Hacia adelante	0,6289	0,6082 (11;197)=	30,35	691,60
Hacia atrás	0,5076	0,4979 (4;204)=	52,57	796,66

CONCLUSIONES

La regresión múltiple a partir del ACP constituye un procedimiento apropiado para desarrollar modelos destinados a estimar la anomalía del rendimiento de maíz en la región de producción de secano de Córdoba, Argentina, a partir de indicadores radiométricos derivados de MODIS. No obstante, la performance predictiva a escala regional resultó sólo moderada, con coeficientes de determinación (R^2 y R^2_{aj}) que presentan un rango entre 0,5 y 0,63, dependiendo de la cantidad y naturaleza de los componentes utilizados. De todos modos, la capacidad predictiva de estos modelos no difiere ostensiblemente de la que presentan los modelos desarrollados directamente a partir de la información de origen satelital.

El ACP resultó una técnica relativamente efectiva para tratar problemas de multicolinealidad de datos y registros radiométricos, en la medida que la información utilizada se encuentra fuertemente correlacionada entre sí (en particular TVDI porque deriva simultáneamente de NDVI y de LST), como así también a fin de reducir la dimensionalidad

de la base de datos predictores. Por otra parte, el proceso de rotación y transformación logra introducir variables al análisis que no sólo son subrogantes de las originales (datos satelitales en este caso), sino que también constituyen composiciones integrales de las mismas durante la extensión completa del ciclo de cultivo. No obstante, la implementación apropiada de la técnica demanda emplear procedimientos de selección de variables en la medida que algunos CP que contribuyen en menor medida a la varianza y en términos generales tienden a ser excluidos del análisis, mantienen sin embargo correlaciones elevadas con la variable respuesta.

De acuerdo a su inserción en el espacio factorial que se configura a partir de los dos primeros CP de los indicadores espectrales, se estableció que la información espectral influye directamente sobre la variabilidad interanual de la ARMz. Asimismo, se verificó que el ENSO, utilizando tanto la temperatura de la superficie del mar como SOI a modo de proxy, constituye una señal no sólo relacionada con ARMz sino que también está vinculada a la información espectral. En ambos casos, se denota un comportamiento que, siendo anticipado desde agosto (previo a la siembra de maíz), muestra también un carácter de persistencia.

BIBLIOGRAFÍA

- Aliaga, V.S.; F. Ferrelli and M.C. Piccolo, 2017. Regionalization of climate over the Argentine Pampas. *International Journal of Climatology* 37: 1237–1247. <https://doi.org/10.1002/joc.5079>
- Anderson, W.B.; R. Seager, W. Baethgen and M. Cane, 2017. Crop production variability in North and South America forced by life-cycles of the El Niño Southern Oscillation. *Agric. For. Meteorol.* 239: 151–165. <https://doi.org/10.1016/j.agrformet.2017.03.008>
- Anderson, W.B.; R. Seager, W. Baethgen, M. Cane and L. You, 2019. Synchronous crop failures and climate-forced production variability. *Science Advances* 5(7): eaaw1976. doi: 10.1126/sciadv.aaw1976
- Barnston, A.G.; M. Chelliah and S.B. Goldenberg, 1997. Documentation of a highly related ENSO-related SST region in the equatorial Pacific. *Ocean-Atmosphere* 35: 367–383. doi:10.1080/07055900.1997.9649597
- Basso, B.; and L. Liu, 2019. Seasonal crop yield forecast: Methods, applications, and accuracies. *Advances in Agronomy* 154: 201–255. <https://doi.org/10.1016/bs.agron.2018.11.002>
- BCCBA, 2021. Bolsa de Cereales de Córdoba. Cultivos estivales 2020/21 en Córdoba. La superficie sembrada de maíz estableció un nuevo récord Jul 14, 2021. <https://www.bccba.org.ar/informes/cultivos-estivales->

- 2020-21-en-cordoba-la-superficie-sembrada-de-maiz-establecio-un-nuevo-record/
- Bodner, G.; A. Nakhforoosh and H-P Kaul, 2015. Management of crop water under drought: a review. *Agron. Sustain. Dev.* 35(2): 401–442. doi: 10.1007/s13593-015-0283-4
- Bolton, D.K.; and M.A. Friedl, 2013. Forecasting crop yield using remotely sensed vegetation indices and crop phenology metrics. *Agric. For. Meteorol.* 173: 74–84. doi: 10.1016/j.agrformet.2013.01.007
- Bureau of Meteorology — Australian Government, 2019. Information from <http://www.bom.gov.au/climate/current/soihtm1.shtml>
- Cai, R.; J. Mullen, J. Bergstrom, W.D. Shurley and M.E. Wetzstein, 2013. Using a climate index to measure crop yield response. *Journal of Agricultural and Applied Economics* 45(4): 1-18. doi: 10.22004/ag.econ.157314
- Cai, Y.; K. Guan, D. Lobell, A.B. Potgieter, S. Wang, J. Peng, T. Xu, S. Asseng, Y. Zhang, L. You, L. and B. Peng, 2019. Integrating satellite and climate data to predict wheat yield in Australia using machine learning approaches. *Agric. For. Meteorol.* 274: 144–159. <https://doi.org/10.1016/j.agrformet.2019.03.010>
- Chowdhury, R.K.; and S. Beecham, 2010. Australian rainfall trends and their relation to the Southern Oscillation Index. *Hydrol. Process.* 24(4): 504–514.
- de la Casa, A.; y G. Ovando, 2006. Influencia de episodios El Niño-Oscilación Sur (ENOS) sobre la precipitación y el rendimiento de maíz en la provincia de Córdoba, Argentina. *Agricultura Técnica (Chile)* 66(1): 80–89.
- de la Casa, A.C.; G.G. Ovando, A.C. Ravelo, E.G. Abril and H. Bergamaschi, 2013. Estimating maize ground cover using spectral data from Aqua-Modis in Córdoba, Argentina. *International Journal of Remote Sensing* 35(4): 1295–1308.
- de la Casa, A.; G. Ovando, L. Bressanini, G. Díaz, P. Díaz y C. Miranda, 2019a. Evaluación de la brecha de rendimiento para maíz tardío con distintas densidades de siembra en la región central de Córdoba, Argentina. *Agriscientia* 36 (2): 1–17.
- de la Casa, A.C.; G.G. Ovando and G.J. Díaz, 2019b. Interannual variability of seasonal rainfall in Córdoba, Argentina, evaluated from ENSO and ENSO Modoki signals and verified with MODIS NDVI data. *SN Applied Sciences* 1(12): 1-21. doi:10.1007/s42452-019-1650-6.
- de la Casa, A.C.; G.G. Ovando and G.J. Díaz, 2021. ENSO influence on corn and soybean yields as a base of an early warning system for agriculture in Córdoba, Argentina. *European Journal of Agronomy* 129: 126340. <https://doi.org/10.1016/j.eja.2021.126340>
- Doraiswamy, P.C.; T.R. Sinclair, S. Hollinger, B. Akhmedov, A. Stern and J. Prueger, 2005. Application of MODIS derived parameters for regional crop yield assessment. *Remote Sens. Environ.* 97(2): 192–202. doi: 10.1016/j.rse.2005.03.015
- Dreccer, M.F.; J. Fainges, J. Wish, F.C. Ogbonnaya and V.O. Sadras, 2018. Comparison of sensitive stages of wheat, barley, canola, chickpea and field pea to temperature and water stress across Australia. *Agric. For. Meteorol.* 248: 275–294. doi: 10.1016/j.agrformet.2017.10.006
- Hadi, A.S.; and R.F. Ling, 1998. Some cautionary notes on the use of Principal Components Regression. *The American Statistician* 52(1): 15–19.
- Holzman M.E.; and R.E. Rivas, 2016. Early maize yield forecasting from remotely sensed Temperature/Vegetation Index measurements. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing* 9(1): 507–519.
- Jarsún, B.; J.A. Gorgas, E. Zamora, E. Bosnero, E. Lovera, A. Ravelo y J. L. Tassile, 2003. Caracterización general de la provincia. pp. 23-60. In: J. A. Gorjas and J. L. Tassile. Recursos naturales de la Provincia de Córdoba. Los Suelos. Córdoba, Argentina Agencia Córdoba Ambiente e INTA. Córdoba, Argentina.
- Johnson, D.M., 2014. An assessment of pre- and within-season remotely sensed variables for forecasting corn and soybean yields in the United States. *Remote Sens. Environ.* 141: 116–128. <https://doi.org/10.1016/j.rse.2013.10.027>
- Johnson, D.M., 2016. A comprehensive assessment of the correlations between field crop yields and commonly used MODIS products. *Int. J. Appl. Earth Obs. Geoinformation* 52: 65–81. doi:10.1016/j.jag.2016.05.010
- Jolliffe, I.T., 2002. *Principal Component Analysis*. 2nd Ed. New York, NY: Springer. 487 pp.
- Karnieli, A.; N. Agam, R.T. Pinker, M. Anderson, M.L. Imhoff, G.G. Gutman, ... and A. Goldberg, 2010. Use of NDVI and land surface temperature for drought assessment: Merits and limitations. *Journal of Climate* 23(3): 618–633.
- Liu, J.; T. Huffman, B. Qian, J. Shang, Q. Li, T. Dong, A. Davidson and Q. Jing, 2020. Crop yield estimation in the Canadian Prairies using Terra/MODIS-derived crop metrics. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing* 13: 2685–2697. doi: 10.1109/JSTARS.2020.2984158
- Lobell, D.B.; K.N. Cahill and C.B. Field, 2007. Historical effects of temperature and precipitation on California crop yields. *Climatic Change* 81(2): 187–203. doi: 10.1007/s10584-006-9141-3
- Lobell, D.B., 2013. The use of satellite data for crop yield gap analysis. *Field Crops Research* 143: 56–64. <https://doi.org/10.1016/j.fcr.2012.08.008>
- Mathbout, S.; J.A. Lopez-Bustins, J. Martin-Vide, J. Bech and F.S. Rodrigo, 2018. Spatial and temporal analysis of drought variability at several time scales in Syria during 1961–2012. *Atmospheric Research* 200: 153–168. doi: 10.1016/j.atmosres.2017.09.016

- Meade, B.; E. Puricelli, W.D. McBride, C. Valdés, L. Hoffman, L. Foreman and E. Dohlman, 2016. Corn and soybean production costs and export competitiveness in Argentina, Brazil, and the United States. USDA Economic Information Bulletin, 154.
- Meyer, S.J.; K.G. Hubbard and D.A. Wilhite, 1991. The relationship of climatic indices and variables to corn (maize) yields: A principal components analysis. *Agric. For. Meteorol.* 55(1–2): 59-84.
- MAGyP, 2020. Ministerio de Agricultura, Ganadería y Pesca de la República Argentina. Estimaciones Agrícolas. <https://datosestimaciones.magyp.gob.ar/reportes.php?reporte=Estimaciones>. (Accessed 15 October 2020).
- Mkhabela, M.S.; P. Bullock, S. Raj, S. Wang and Y. Yang, 2011. Crop yield forecasting on the Canadian Prairies using MODIS NDVI data. *Agric. For. Meteorol.* 151(3): 385–393.
- Moran, M.S.; T.R. Clarke, Y. Inoue and A. Vidal, 1994. Estimating crop water deficit using the relation between surface-air temperature and spectral vegetation index. *Remote Sens. Environ.* 49(3): 246–263. [https://doi.org/10.1016/0034-4257\(94\)90020-5](https://doi.org/10.1016/0034-4257(94)90020-5)
- Nagy, A.; J. Fehér and J. Tamás, 2018. Wheat and maize yield forecasting for the Tisza river catchment using MODIS NDVI time series and reported crop statistics. *Computers and Electronics in Agriculture* 151: 41–49. <https://doi.org/10.1016/j.compag.2018.05.035>
- Peralta, N.R.; J.L. Costa, M. Balzarini, M. Castro Franco, M. Córdoba and D. Bullock, 2015. Delineation of management zones to improve nitrogen management of wheat. *Computers and Electronics in Agriculture* 110: 103–113. doi: 10.1016/j.compag.2014.10.017
- Rattalino Edreira, J.I.; N. Guilpart, V. Sadras, K.G. Cassman, M.K. van Ittersum, R.L.M. Schils and P. Grassini, 2018. Water productivity of rainfed maize and wheat: A local to global perspective. *Agric. For. Meteorol.* 259: 364–373. <https://doi.org/10.1016/j.agrformet.2018.05.019>
- Sandholt, I.; K. Rasmussen and J. Andersen, 2002. A simple interpretation of the surface temperature/vegetation index space for assessment of surface moisture status. *Remote Sensing of Environment* 79(2–3): 213–224.
- Schillerberg, T.A.; D. Tian and R. Miao, 2019. Spatiotemporal patterns of maize and winter wheat yields in the United States: Predictability and impact from climate oscillations. *Agric. For. Meteorol.* 275: 208–222. <https://doi.org/10.1016/j.agrformet.2019.05.019>
- Seo, B.; J. Lee, K. Lee, S. Hong and S. Kang, 2019. Improving remotely-sensed crop monitoring by NDVI-based crop phenology estimators for corn and soybeans in Iowa and Illinois, USA. *Field Crops Research* 238: 113–128. doi:10.1016/j.fcr.2019.03.015
- Sun, D.; and M. Kafatos, 2007. Note on the NDVI-LST relationship and the use of temperature-related drought indices over North America. *Geophysical Research Letters* 34: L24406, doi:10.1029/2007GL031485
- Verma, U.; H.P. Piepho, A. Goyal, J.O. Ogutu and M.H. Kalubarme, 2016. Role of climatic variables and crop condition term for mustard yield prediction in Haryana. *Int. J. Agricult. Stat. Sci.* 12(1): 45–51.
- Wang, R.; L.C. Bowling and K.A. Cherkauer, 2016. Estimation of the effects of climate variability on crop yield in the Midwest USA. *Agric. For. Meteorol.* 216(1): 141–156.
- Zhu, B.; S. Chen, Y. Cao, Z. Xu, Y. Yu and C. Han, 2021. A regional maize yield hierarchical linear model combining Landsat 8 vegetative indices and meteorological data: Case study in Jilin province. *Remote Sensing* 13(3): 356.