

Tesis de Maestría

Comparación de índices climáticos y espectrales en la estimación de rendimiento de maíz y soja a nivel departamental en Entre Ríos

Vaiman, Nicolás

2018-06-19

Este documento forma parte de la colección de tesis doctorales y de maestría de la Biblioteca Central Dr. Luis Federico Leloir, disponible en digital.bl.fcen.uba.ar. Su utilización debe ser acompañada por la cita bibliográfica con reconocimiento de la fuente.

This document is part of the doctoral theses collection of the Central Library Dr. Luis Federico Leloir, available in digital.bl.fcen.uba.ar. It should be used accompanied by the corresponding citation acknowledging the source.

Cita tipo APA:

Vaiman, Nicolás. (2018-06-19). Comparación de índices climáticos y espectrales en la estimación de rendimiento de maíz y soja a nivel departamental en Entre Ríos. Facultad de Ciencias Exactas y Naturales. Universidad de Buenos Aires.

Cita tipo Chicago:

Vaiman, Nicolás. "Comparación de índices climáticos y espectrales en la estimación de rendimiento de maíz y soja a nivel departamental en Entre Ríos". Facultad de Ciencias Exactas y Naturales. Universidad de Buenos Aires. 2018-06-19.

EXACTAS UBA

Facultad de Ciencias Exactas y Naturales



UBA

Universidad de Buenos Aires



UNIVERSIDAD DE BUENOS AIRES
Facultad de Ciencias Exactas y Naturales
Facultad de Agronomía

Maestría en Meteorología Agrícola

**Comparación de índices climáticos y espectrales en la
estimación de rendimiento de maíz y soja a nivel
departamental en Entre Ríos**

Tesis presentada para optar al título de Magíster de la Universidad de
Buenos Aires en Meteorología Agrícola

Maestrando: Ing. Agr. Nicolás Vaiman
Director de Tesis: M. Sc. Roberto De Ruyver
Co-Director: Dr. Martín Durante

Buenos Aires, 2018
Fecha de defensa:

Comparación de índices climáticos y espectrales en la estimación de rendimiento de maíz y soja a nivel departamental en Entre Ríos

Resumen

Las estimaciones de rendimientos agrícolas son de gran importancia debido a que la producción de alimentos juega un papel fundamental en la seguridad alimentaria y en la economía de los países. En el pasado, las estimaciones de rendimiento se debían realizar a campo, con operaciones trabajosas y lentas, y se obtenían resultados poco precisos. Por este motivo, cada vez más trabajos apuntan a estimar el rendimiento mediante técnicas geo-informáticas. Considerando la disponibilidad de datos de libre acceso existen dos posibilidades para estimar los rendimientos: por un lado, se pueden utilizar datos de precipitaciones, y, por otro lado, se pueden utilizar datos provenientes de sensores remotos. El objetivo del trabajo fue determinar y comparar la capacidad de distintos índices (climáticos y espectrales) de estimar los rendimientos agrícolas a escala departamental en la provincia de Entre Ríos. En primera instancia se determinó la capacidad de las precipitaciones y el SPI (*Standardized Precipitation Index*) de 3 meses, ambos en distintos períodos de acumulación en el semestre cálido (octubre a marzo). Los modelos que mejor explicaron el rendimiento en maíz fueron los que incluyeron información de diciembre (tanto con precipitaciones como con SPI), con un menor error de predicción y un mayor coeficiente de determinación. En cambio, en soja, fueron aquellos que se basaron en la precipitación previa al período crítico y el SPI centrado en dicho período. Luego, en segunda instancia, se evaluó la capacidad de TRMM (*Tropical Rainfall Measurement Mission*) para estimar la precipitación en Entre Ríos. En un primer análisis a escala mensual, se comparó la estimación derivada de TRMM y de dos métodos de interpolación a partir de los datos de nueve estaciones meteorológicas convencionales (EMC) (cinco dentro y cuatro fuera de la provincia). En un segundo análisis para distintos períodos de acumulación inferiores al mes se utilizaron tres EMC dentro de la provincia. A escala mensual, la capacidad de estimar las precipitaciones resultó mejor con TRMM que con cualquiera de los dos métodos de interpolación. La estimación de precipitaciones

mensuales mediante la ecuación con todos los datos agrupados de TRMM no resultó diferente de la estimación particular de cada EMC, lo que permite utilizar la ecuación de forma generalizada para toda la provincia. A escala menor a la mensual se observó que el ajuste aumenta con los días acumulados. Se estableció al período de acumulación de 15 días como el mínimo que no disminuye la precisión con respecto a períodos más largos. Por esto, los datos de TRMM acumulados cada 16 días (frecuencia de los productos MODIS) fueron utilizados en conjunto con otros índices espectrales en la instancia siguiente. En ésta tercera instancia, se determinó la capacidad de un conjunto de índices espectrales para estimar los rendimientos. Para esto, se utilizaron valores de reflectancia de distintas bandas del producto MOD09A1 y la temperatura de superficie del producto MOD11A2, ambos provenientes de MODIS. Los índices obtenidos (básicos y escalados cada 8 días, y combinados cada 16 días), fueron promediados en 8 períodos de tiempo ubicados en distintos estadios fenológicos del ciclo de los cultivos. Los modelos más exactos para estimar rendimientos en soja y en maíz fueron aquellos cuyos índices habían sido escalados. En maíz, los mejores índices se obtuvieron al considerar sólo el período crítico. En cambio, para soja, los mejores modelos incluyeron al período crítico del cultivo y al ciclo completo. En general, los mejores resultados se obtuvieron al utilizar el NDWI y NDDI (derivado del NDWI). En última instancia, se compararon los índices climáticos y los derivados de sensores remotos en la estimación de rendimientos. En maíz, la mejor estimación con índices climáticos se obtuvo con el SPI de enero y febrero en el departamento Federal, con un RMSE de $820 \text{ kg}\cdot\text{ha}^{-1}$ (error relativo del 22%). En cambio, la mejor estimación con índices espectrales se produjo con el Sc_NDWI_7 en el período crítico en el departamento Villaguay, con un RMSE de $363 \text{ kg}\cdot\text{ha}^{-1}$ (error relativo del 8%). En soja, la mejor estimación con índices climáticos se obtuvo con el SPI de enero a marzo en Federación, con un RMSE de $245 \text{ kg}\cdot\text{ha}^{-1}$ (error relativo del 8%). En cambio, la mejor estimación con índices espectrales se produjo con el Sc_NDWI_7 en el período comprendido entre el 17 de enero y el 18 de febrero en Nogoyá, con un RMSE de $132 \text{ kg}\cdot\text{ha}^{-1}$ (error relativo del 5%). Los resultados del trabajo indican que las precipitaciones estimadas con TRMM podrían utilizarse para la mayoría de los posibles usos agronómicos. Además, se lograron estimaciones de rendimientos departamentales muy buenas

mediante modelos provenientes de regresiones lineales simples. Tanto en maíz como en soja, las mejores estimaciones de rendimiento se lograron dos meses previos a la cosecha. Los modelos lineales obtenidos en este trabajo podrían ampliarse con más datos en años futuros o implementarse operativamente en su forma original. Estos modelos aportarían: 1) objetividad en las estimaciones, 2) adecuada anticipación en la estimación y 3) datos a nivel departamental.

Palabras claves: estimación de rendimiento, soja, maíz, precipitaciones, sensores remotos

Climatic and spectral indices comparison in the assessment of maize and soybean yields at departmental scale in Entre Ríos

Abstract

The estimates of agricultural yields are of great importance because food production plays a fundamental role in food security and the economy of the countries. In the past, yield estimates had to be made in the field, with laborious and slow operations, and imprecise results were obtained. For this reason, more and more studies aim to estimate yields through geo-informatics. Considering the availability of free access data there are two possibilities to estimate the yields: on the one hand, precipitation data, and, on the other hand, data from remote sensing can be used. The objective of this work was to determine and compare the capacity of different indices (climatic and spectral ones) to estimate agricultural yields at departmental scale in the province of Entre Ríos. In the first instance, the capacity of the precipitations and the SPI (Standardized Precipitation Index) of 3 months were determined, both in different periods of accumulation in the warm semester (October to March). The models that best explained the maize yields were those that included December information (both with precipitation and with SPI), with a lower prediction error and a higher coefficient of determination. In contrast, for soybeans the best models were those that were based on precipitation and SPI prior to the critical period. Then, in the second instance, the capacity of TRMM (Tropical Rainfall Measurement Mission) to estimate precipitation in Entre Ríos was evaluated. In a first monthly analysis, the estimate derived from TRMM and two interpolation methods were compared to nine conventional meteorological stations (CME) data (five inside and four outside the province). In a second analysis for different accumulation periods less than a month, three CME within the province were used. On a monthly basis, the ability to estimate precipitation was better with TRMM than with either of the two interpolation methods. The estimation of monthly precipitation with the equation with all grouped data of TRMM was not different from the particular estimation of each CME. That allows us to use the equation in a generalized manner for the

whole province. On a scale smaller to the month, it was observed that the adjustment increases with the accumulated days. The 15-day accumulation period was established as the minimum that does not affect the accuracy with respect to longer periods. Therefore, the TRMM data accumulated every 16 days (frequency of MODIS products) were used in conjunction with other spectral indices in the following instance. In this third instance, the capacity of a set of spectral indices to estimate yields was determined. For this, reflectance values of different MOD09A1 product bands and the surface temperature of the MOD11A2 product were used, both belonging to MODIS. The resulting indices (basic and scaled every 8 days, and combined every 16 days), were averaged over 8 time periods in different phenological stages of the crop cycle. The most accurate models to estimate soybean and maize yields were those whose indices had been scaled. In maize, the best indices were obtained when considering only the critical period. In contrast, for soybeans, the best models included the critical period of the crop and the full cycle. In general, the best results were obtained when using the NDWI and NDDI (derived from the NDWI). Ultimately, climatic and remote sensing indices were compared in the yield estimation. In maize, the best estimate with climatic indices was obtained with the SPI of January and February in Federal, with an RMSE of 820 kg.ha⁻¹ (relative error of 22%). On the other hand, the best estimate with spectral indices was obtained with the Sc_NDWI_7 in the critical period in Villaguay, with an RMSE of 363 kg.ha⁻¹ (relative error of 8%). In soybean, the best estimate with climatic indices was obtained with the SPI from January to March in the Federación, with an RMSE of 245 kg.ha⁻¹ (relative error of 8%). In contrast, the best estimate with spectral indices was obtained with the Sc_NDWI_7 in the period between January 17 and February 18 in Nogoyá, with an RMSE of 132 kg.ha⁻¹ (relative error of 5%). The results of this work indicate that the estimated precipitations with TRMM could be used for agronomic uses. In addition, good estimates of departmental yields were obtained through models from simple linear regressions. In both maize and soybeans, the best yield estimates were achieved two months before harvest. The linear models obtained in this work could be expanded with more data in future years or could be operationally implemented in its original form. These models would provide: 1) objectivity in the estimates, 2) adequate anticipation in the estimates and 3) data at the departmental level.

Keywords: yield estimate, soybean, maize, precipitations, remote sensing.

Índice

Capítulo 1: Introducción general y objetivos	1
1.1 Introducción general	2
1.2 Objetivo general	6
1.3 Objetivos específicos	6
Capítulo 2: Estimación de rendimientos a través de precipitaciones	8
2.1 Introducción.....	9
2.2 Metodología.....	11
2.2.1 Datos climáticos	11
2.2.2 Construcción de las variables predictoras o independientes	14
2.2.3 Generación de modelos lineales de predicción de rendimiento	14
2.2.4 Datos de rendimientos departamentales.....	15
2.3 Resultados	17
2.3.1 Modelos lineales.....	17
2.3.2 Evaluación de la capacidad de predicción de los modelos lineales.....	19
2.4 Discusión	21

Capítulo 3: Comparación entre interpolación y datos satelitales en la estimación de las precipitaciones en Entre Ríos	24
3.1 Introducción.....	25
3.2 Metodología.....	27
3.2.1 Análisis mensual.....	27
3.2.2 Análisis para distintos períodos de acumulación	29
3.3 Resultados	30
3.3.1 Análisis mensual.....	30
3.3.2 Análisis para distintos períodos de acumulación	35
3.4 Discusión	36
Capítulo 4: Estimación de rendimientos a través de sensores remotos	38
4.1 Introducción.....	39
4.2 Metodología.....	42
4.2.1 Datos de sensores remotos	42
4.2.2 Construcción de las variables predictoras o independientes	46
4.2.3 Generación de modelos lineales de predicción de rendimiento	47
4.2.4 Datos de rendimientos departamentales.....	47
4.3 Resultados	47

4.3.1 Modelos lineales de predicción de rendimiento	47
4.3.2 Comparación de índices combinados.....	50
4.4 Discusión	51
Capítulo 5: Discusión general	54
5.1 Resumen de los principales resultados.....	55
5.2 Comparación entre índices climáticos y espectrales	57
5.3 Aportes y posibles aplicaciones	59
Capítulo 6: Bibliografía.....	62

Índice de figuras

FIGURA 2.1. LOCALIZACIÓN DE LAS EMC UTILIZADAS PARA GENERAR PRECIPITACIONES INTERPOLADAS DEPARTAMENTALES Y SPI.	12
FIGURA 2.2. PERÍODOS ANALIZADOS CON DATOS DE PRECIPITACIONES Y SPI DE 3 MESES EN MAÍZ Y SOJA PARA CORRELACIONAR CON EL RENDIMIENTO FINAL DEL CULTIVO.	13
FIGURA 2.3. TENDENCIA DEL RENDIMIENTO PROMEDIO PROVINCIAL DE A) MAÍZ (N=45) Y B) SOJA (N=41).	15
FIGURA 2.4. COEFICIENTE DE DETERMINACIÓN PARA CADA CULTIVO Y VARIABLE PREDICTORA. A) PRECIPITACIONES EN MAÍZ; B) SPI EN MAÍZ; C) PRECIPITACIONES EN SOJA; D) SPI EN SOJA. ACLARACIÓN: LA LEYENDA INDICA EL ÚLTIMO MES CONSIDERADO EN CADA PERÍODO DE TIEMPO ANALIZADO (EJEMPLO: EL PRIMER PUNTO DE LA LÍNEA CELESTE -DE IZQUIERDA A DERECHA- CORRESPONDE AL PERÍODO OCTUBRE-NOVIEMBRE-DICIEMBRE-ENERO, EL SEGUNDO CORRESPONDE AL PERÍODO NOVIEMBRE-DICIEMBRE-ENERO; EL TERCERO CORRESPONDE AL PERÍODO DICIEMBRE-ENERO Y EL CUARTO CORRESPONDE AL MES DE ENERO).	17
FIGURA 2.5. DIAGRAMAS DE CAJA Y BIGOTE MOSTRANDO EL RMSE DE LOS DISTINTOS MODELOS LINEALES PARA LA PREDICCIÓN DEL RENDIMIENTO DE MAÍZ, UTILIZANDO COMO VARIABLE PREDICTORA A A) PRECIPITACIONES; B) SPI. EL COLOR DE LA CAJA SE ASOCIA CON EL ÚLTIMO MES (O MES INDIVIDUAL) DE CADA PERÍODO ANALIZADO.	20
FIGURA 2.6. DIAGRAMAS DE CAJA Y BIGOTE MOSTRANDO EL RMSE DE LOS DISTINTOS MODELOS LINEALES PARA LA PREDICCIÓN DEL RENDIMIENTO DE SOJA, UTILIZANDO COMO VARIABLE PREDICTORA A A) PRECIPITACIONES; B) SPI. EL COLOR DE LA CAJA SE ASOCIA CON EL ÚLTIMO MES (O MES INDIVIDUAL) DE CADA PERÍODO ANALIZADO.	20
FIGURA 3.1. MAPA CON LA UBICACIÓN DE LAS EMC UTILIZADAS PARA EVALUAR LA CAPACIDAD DE TRMM DE ESTIMAR PRECIPITACIONES MENSUALES Y DE DISTINTOS PERÍODOS DE ACUMULACIÓN EN ENTRE RÍOS.	28
FIGURA 3.2. COEFICIENTE DE DETERMINACIÓN (R^2) PARA LA CORRELACIÓN ENTRE LAS PRECIPITACIONES OBSERVADAS EN CADA EMC Y LAS PRECIPITACIONES ESTIMADAS POR CADA MÉTODO.	31
FIGURA 3.3. CORRELACIÓN ENTRE PRECIPITACIONES ESTIMADAS Y PRECIPITACIONES OBSERVADAS PARA LOS TRES MÉTODOS (POND1, POND2 Y TRMM) CON TODOS LOS DATOS AGRUPADOS.	32
FIGURA 3.4. VALORES DE ERROR PARA TRMM SIN CORREGIR (TRMM) Y CORREGIDO A TRAVÉS DE LA ECUACIÓN DE CADA ESTACIÓN (TRMMCOR) Y A TRAVÉS DE LA ECUACIÓN CON TODOS LOS DATOS AGRUPADOS (TRMMCOR2).	35
FIGURA 3.5. COEFICIENTE DE DETERMINACIÓN (R^2) EN LA CORRELACIÓN ENTRE DATOS DE LAS EMC Y TRMM Y ERROR RELATIVO PARA DISTINTA CANTIDAD DE DÍAS ACUMULADOS PARA A) C. DEL URUGUAY, B) CONCORDIA Y C) GUALEGUAYCHÚ.	35

FIGURA 3.6. VALORES (ADIMENSIONALES) DE POD, FAR Y CSI PARA A) C. DE URUGUAY, B) CONCORDIA, Y C) GUALEGUAYCHÚ.	36
FIGURA 4.1. PERÍODOS (BLOQUES AZULES) EN LOS QUE SE PROMEDIÓ CADA ÍNDICE COMBINADO PARA CORRELACIONAR CON EL RENDIMIENTO FINAL DEL CULTIVO Y ESTADÍOS FENOLÓGICOS APROXIMADOS. REFERENCIAS: CC = CICLO COMPLETO, PC = PERÍODO CRÍTICO (FECHA MARCADA EN COLOR ANARANJADO), PC-N O PC+N = N INDICA EL NÚMERO DE FECHAS PREVIAS CONSIDERADAS (EN PERÍODOS DE 16 DÍAS) ANTES (-) O DESPUÉS (+) DEL PC.	45
FIGURA 4.2. PERÍODOS (BLOQUES AZULES) EN LOS QUE SE PROMEDIÓ CADA ÍNDICE ESCALADO Y VHI PARA CORRELACIONAR CON EL RENDIMIENTO FINAL DEL CULTIVO Y ESTADÍOS FENOLÓGICOS APROXIMADOS. REFERENCIAS: CC = CICLO COMPLETO, PC = PERÍODO CRÍTICO (FECHA MARCADA EN COLOR ANARANJADO), PC-N O PC+N = N INDICA EL NÚMERO DE FECHAS PREVIAS CONSIDERADAS (EN PERÍODOS DE 8 DÍAS) ANTES (-) O DESPUÉS (+) DEL PC.	46
FIGURA 4.3. RMSE DE LOS MODELOS CUYOS ÍNDICES FUERON MÁS FRECUENTES AL CONSIDERAR TODOS LOS DEPARTAMENTOS: A) Sc_NDDI_5 EN MAÍZ Y B) Sc_NDWI_7 EN SOJA. LOS DISTINTOS COLORES HACEN REFERENCIA A LOS OCHO PERÍODOS ANALIZADOS EN CADA CULTIVO. LETRAS DISTINTAS INDICAN DIFERENCIAS ESTADÍSTICAMENTE SIGNIFICATIVAS (P<0,05).	48
FIGURA 4.4. REGRESIONES LINEALES ENTRE LAS VARIABLES A) Sc_NDWI_7-353-1 EN MAÍZ EN EL DEPARTAMENTO VILLAGUAY Y B) Sc_NDWI_7-17-49 EN SOJA EN EL DEPARTAMENTO NOGOYÁ, Y EL RENDIMIENTO DE CADA CULTIVO.	50
FIGURA 4.5. DIAGRAMAS DE CAJA Y BIGOTE MOSTRANDO EL RMSE DE LAS DISTINTAS FORMAS DE CÁLCULO DE LOS ÍNDICES COMBINADOS: A) NDDI_5 PARA EL PERÍODO CRÍTICO EN MAÍZ Y B) NDWI_7 PARA EL CICLO COMPLETO EN SOJA.	51
FIGURA 5.1. FRECUENCIA RELATIVA ACUMULADA (F _i) EN FUNCIÓN DEL RMSE PARA LA TOTALIDAD DE LOS MODELOS EN MAÍZ SEPARADOS POR TIPO DE ÍNDICES (CLIMÁTICOS Y ESPECTRALES).	57
FIGURA 5.2. FRECUENCIA RELATIVA ACUMULADA (F _i) EN FUNCIÓN DEL RMSE PARA LA TOTALIDAD DE LOS MODELOS EN SOJA SEPARADOS POR TIPO DE ÍNDICES (CLIMÁTICOS Y ESPECTRALES).	58
FIGURA 5.3. MENOR RMSE OBTENIDO CON CADA TIPO DE ÍNDICE (CLIMÁTICO O ESPECTRAL) EN A) MAÍZ Y B) SOJA. EN A) SE MUESTRA AL SPI-ENE-FEB EN FEDERAL Y AL Sc_NDWI_7-353-1 EN VILLAGUAY. EN B) SE MUESTRA AL SPI-ENE-MAR EN FEDERACIÓN Y AL Sc_NDWI_7-17-49 EN NOGOYÁ. ENTRE PARÉNTESIS SE MUESTRA EL R ² DE PREDICCIÓN.	59

Índice de tablas

TABLA 2.1. ORDENADA AL ORIGEN (EN T. HA ⁻¹) Y PENDIENTE (EN T. HA ⁻¹ . AÑO ⁻¹) DE LA SERIE DE DATOS DE RENDIMIENTOS DEPARTAMENTALES (N=45 PARA MAÍZ Y N=41 PARA SOJA).....	16
TABLA 2.2. MEDIANA DE LA ORDENADA AL ORIGEN (EN T. HA ⁻¹), PENDIENTE (EN T. HA ⁻¹ . MM ⁻¹ EN EL CASO DE PP Y EN T. HA ⁻¹ EN EL CASO DE SPI) Y COEFICIENTE DE DETERMINACIÓN (R ²) PARA CADA VARIABLE PREDICTORA DEL RENDIMIENTO EN MAÍZ.	18
TABLA 2.3. MEDIANA DE LA ORDENADA AL ORIGEN, PENDIENTE Y COEFICIENTE DE DETERMINACIÓN (R ²) PARA CADA VARIABLE PREDICTORA DEL RENDIMIENTO EN SOJA.....	19
TABLA 3.1. EMC UTILIZADAS PARA EL ANÁLISIS DE LA CAPACIDAD DE TRMM DE ESTIMAR PRECIPITACIÓN MENSUAL...	27
TABLA 4.1. ESPECIFICACIONES DE LAS BANDAS DEL PRODUCTO MOD09 UTILIZADAS PARA EL CÁLCULO DE ÍNDICES DE VEGETACIÓN.....	42
TABLA 4.2. ÍNDICES BÁSICOS, ESCALADOS (PREFIJO “Sc”) Y COMBINADOS (PREFIJO “Cl”). P HACE REFERENCIA A LA REFLECTANCIA DE LA BANDA EN CUESTIÓN. LOS PREFIJOS “MIN” Y “MAX” INDICAN QUE SE UTILIZÓ EL VALOR MÍNIMO Y MÁXIMO, RESPECTIVAMENTE, DE CADA PÍXEL EN EL PERÍODO DE 15 AÑOS COMPLETO Y EN CADA FECHA. “VI” HACE REFERENCIA A CUALQUIERA DE LOS ÍNDICES DE VEGETACIÓN BÁSICOS (NDVI, NMDI, NDWI O NDDI).	44
TABLA 4.3. MÍNIMO RMSE HALLADO PARA CADA VARIABLE EN CADA DEPARTAMENTO. SE MUESTRA ADEMÁS EL ERROR RELATIVO Y EL R ² DE PREDICCIÓN DE DICHAS VARIABLES.	49

Capítulo 1: **Introducción general y objetivos**

1.1 Introducción general

Las estimaciones de rendimientos agrícolas son de gran importancia para el desarrollo de políticas y para tomadores de decisiones debido a que la producción de alimentos juega un papel fundamental en la seguridad alimentaria y en la economía de los países. A su vez contar con una estimación previa (i.e. modelos de predicción) de los rendimientos es un factor importante relacionado tanto a la economía agrícola y políticas de importación-exportación, como a las cadenas agroindustriales que dependen de la producción agropecuaria. Por lo tanto, las estimaciones de rendimiento final de los cultivos y su predicción tienen un impacto directo cada año en las economías nacionales e internacionales, jugando un papel importante en el manejo de los alimentos (Hayes y Decker, 1996).

Los rendimientos en la agricultura de secano son altamente dependientes del agua. La deficiencia de la misma, de acuerdo con Blum (2005), afecta a un 26% de las tierras cultivables del mundo y las limitantes al consumo de agua son el principal factor responsable de las pérdidas de rendimiento de los cultivos de secano (Boyer, 1982). A su vez, Hall *et al.* (1992) identifican al agua como el factor limitante más importante de la producción en muchas áreas de Argentina, siendo la principal responsable de la variación de rendimientos entre sitios y años.

Aún en ambientes propicios para la producción agrícola, los cultivos pueden estar sometidos durante un período a algún tipo de estrés por falta de agua. Hay tres características de la sequía que determinan sus efectos sobre los cultivos: intensidad, duración y momento de ocurrencia en relación al estado de desarrollo del cultivo. Las áreas agrícolas pampeanas se ven frecuentemente afectadas por sequías estivales de duración e intensidad variables. Cuando las deficiencias hídricas son pronunciadas y/o duraderas, se genera en la planta una situación de estrés hídrico que afecta su normal funcionamiento. Los efectos del estrés en las plantas por falta de agua varían de acuerdo al estado de crecimiento y desarrollo de las mismas (Salter y Goode, 1967). De persistir el estrés, sobre todo durante estados críticos, el rendimiento se reduce (Andrade y Sadras, 2002).

En el pasado, las estimaciones de rendimiento se debían realizar a campo y se obtenían resultados poco precisos ya que resultaba difícil localizar las muestras y tomar un número de muestras suficiente (Zang, 1998). Las observaciones *in situ* no sólo son trabajosas, si no también lentas. Por este motivo, cada vez más trabajos apuntan a

estimar el rendimiento mediante técnicas geo-informáticas. Considerando la disponibilidad de datos de fácil y libre acceso, y que a su vez estén relacionados con la disponibilidad de agua y estado de los cultivos, existen dos posibilidades diferentes para estimar los rendimientos. Por un lado, se pueden utilizar los datos de precipitación, ya sea de forma directa (Bettolli *et al.*, 2002, 2004) o en forma indirecta a través cálculos de índices o en modelos más complejos (Llano y Vargas, 2015). Por otro lado, se pueden utilizar los datos provenientes de sensores remotos. Más precisamente, los índices espectrales pueden utilizarse para monitorear la vegetación y para la predicción de los rendimientos de los cultivos (Prasad *et al.*, 2006; de la Casa y Ovando, 2007).

Los datos de precipitación en determinados momentos se relacionan con los rendimientos. Llano y Vargas (2015) encontraron que la precipitación acumulada durante el período de floración afecta el rendimiento final de soja y maíz en la Pampa Húmeda. En la zona centro-oriental de la misma región, Bettolli *et al.* (2002) determinaron que el rendimiento de la soja presenta una asociación significativa con la precipitación acumulada en el ciclo del cultivo y, en un trabajo posterior (Bettolli *et al.*, 2004), que el resultado es similar si se comparan distintos subperíodos dentro de la estación de crecimiento o si se toma el período completo.

La utilización de datos de precipitación para la agricultura está limitada por la distribución espacial de las estaciones meteorológicas. Ante la insuficiente densidad de estaciones meteorológicas en determinada área surge la necesidad de estimar las precipitaciones. Una de las técnicas más frecuentes para estimar precipitaciones es la de utilizar distintos métodos de interpolación de datos obtenidos en estaciones cercanas. Sin embargo, otra alternativa es utilizar estimaciones satelitales de precipitaciones. Las técnicas de estimación de la precipitación a partir de sensores remotos pueden ofrecer una mejor cobertura espacial de dicha variable. Una fuente de datos de precipitación a partir de sensores remotos son los productos derivados de TRMM (*Tropical Rainfall Measuring Mission*). Éstos han sido validados con datos de superficie para distintos lugares del planeta (Karaseva *et al.*, 2012; Duan y Bastiaanssen, 2013).

La capacidad de los sensores remotos para estimar los rendimientos de los cultivos se basa en la forma en que la vegetación interactúa con la radiación. La vegetación sana presenta una distintiva interacción con la energía en las regiones del espectro electromagnético del visible y del infrarrojo cercano. En la región del visible, los pigmentos vegetales (principalmente clorofila) absorben una gran cantidad de energía solar para la

fotosíntesis, originándose dos picos de absorción bien marcados, uno en la región del rojo y otro en la del azul. En la región del infrarrojo cercano, en cambio, la energía es reflejada fuertemente por las hojas, principalmente por los efectos de la pared celular y de la interface agua-aire de los espacios intercelulares (Rencz, 1999). Este contraste, principalmente basado en la diferencia de energía reflejada en las regiones del rojo y del infrarrojo cercano del espectro electromagnético, ha sido el centro de atención para el desarrollo de índices cuantitativos con el objetivo de estimar la condición de la vegetación a través de imágenes de sensores remotos (Thiam y Eastman, 2006).

Las estimaciones de producción basadas en sensores remotos presentan la ventaja de tener un bajo (o nulo) costo de material requerido, son oportunas porque pueden obtenerse previo a la cosecha (Gitonga, 1995) y han demostrado ser una tecnología efectiva y prometedora por la precisión con la que han estimado rendimientos previamente (Hayes y Decker, 1996; Dadhwal y Sridhar, 1997; Mika *et al.*, 2002; Prasad *et al.*, 2006). Las condiciones de la vegetación y la predicción de rendimientos han sido extensivamente analizadas en varios países a través del tradicional *Normalized Difference Vegetation Index* o NDVI (Boken y Shaykewich, 2002; Doraiswamy y Cook, 1995; Mkhabela *et al.*, 2005, 2011; Moriondo *et al.*, 2007; Quarmby *et al.*, 1993) y la mayoría de los trabajos ha reportado correlaciones lineales entre este índice y el rendimiento.

Un aspecto a tener en cuenta es la anticipación con la cual se pueden realizar las predicciones de rendimiento mediante estas técnicas. Aunque su procesamiento sea relativamente sencillo, los datos de precipitaciones tienen la desventaja de que suelen tener un tiempo de demora desde que se los solicita hasta que se puede contar con los mismos para su procesamiento. Por este motivo, pueden resultar inadecuados para estimar rendimientos cuando no se dispone de bases de datos actualizadas y de fácil acceso. En cambio, los productos derivados de sensores remotos están disponibles prácticamente en tiempo real, o con demoras de pocos días. De esta forma, muchos trabajos han logrado predecir rendimientos utilizando índices de vegetación provenientes de sensores remotos hasta con dos meses de anticipación a la cosecha (Unganai y Kogan, 1998; Labus *et al.*, 2002; Mkhabela *et al.* 2005).

Un ejemplo claro de las relaciones entre distintos índices y los rendimientos de soja y maíz se puede hallar en el trabajo de Rhee *et al.* (2010). Estos autores propusieron, tanto para regiones húmedas y sub-húmedas como para regiones áridas, un conjunto de índices provenientes del sensor MODIS (*Moderate Resolution Imaging Spectroradiometer*)

solos y en combinación con datos de lluvia de TRMM. En este trabajo, Rhee *et al.* (2010) utilizaron distintas combinaciones de índices y encontraron que durante los períodos de activo crecimiento de los cultivos estos índices tuvieron altas correlaciones con el rendimiento final de los mismos. También hallaron diferencias en el ajuste logrado con las distintas combinaciones de índices y entre las regiones evaluadas.

En Argentina existen pocos trabajos que aprovechen las ventajas en cuanto a cobertura espacial que proveen los sensores remotos para estas estimaciones. A su vez, ninguno de ellos utiliza datos estimados de lluvia proveniente de satélite, ya que éstos se basan solamente en índices de vegetación y en temperatura de superficie (Seiler *et al.*, 1998; de la Casa y Ovando, 2007; Holzman *et al.*, 2014). Por su parte, el Instituto Nacional de Tecnología Agropecuaria publica regularmente a través de su herramienta SEPA (Seguimiento de la Producción Agropecuaria) información agrometeorológica y distintos índices espectrales basados en imágenes del sensor MODIS. Sin embargo, esta herramienta no cuenta con modelos que utilicen dicha información para predecir rendimientos agrícolas. Si se correlacionara este tipo de información y surgieran modelos que sirvan para predecir rendimientos, sin duda esta información sería de gran utilidad para el sector agropecuario.

Entre Ríos es una provincia con una actividad agrícola muy importante. Según el Portal de Datos Abiertos del Ministerio de Agroindustria, en los últimos 15 años Entre Ríos sembró en promedio el 8% de la superficie total sembrada con soja a nivel nacional, y un 5% de la superficie total de maíz. La producción en el mismo período correspondió, también en promedio, a un 7% del total de soja y a un 6% del total de maíz. A nivel provincial, del total de superficie con cultivos agrícolas, la soja ocupa el primer lugar (60% del área agrícola), seguida por el trigo (14%) y el maíz (10%) (Ministerio de Agroindustria, 2017).

Actualmente, Entre Ríos cuenta con el Sistema Integrado de la Bolsa de Cereales de Entre Ríos (SIBER) que, entre otras variables, informa el rendimiento promedio departamental de los cultivos más importantes de la provincia. Este se estima a través de una red de más de 200 colaboradores que incluye a profesionales, productores, cooperativas y acopios del sector agropecuario. Sin embargo, las estimaciones se realizan una vez cosechado el cultivo.

Hasta el momento existen escasas referencias (Brizuela *et al.*, 2015) sobre la utilización de los productos TRMM para estimar precipitaciones y no se ha intentado

relacionar la información proveniente de productos MODIS con rendimientos agrícolas en Entre Ríos. Considerando la importancia previamente mencionada de poder contar con estimaciones de rendimientos antes de la cosecha de los cultivos, el valor del presente trabajo radica en dos cuestiones principales. Primero, se realizará una evaluación de distintos índices, tanto de precipitaciones como de sensores remotos, para determinar cuál estima mejor el rendimiento. Así, este sería el primer intento de estimar rendimientos departamentales en la provincia con técnicas de geo-informática. Segundo, se intentará determinar con cuánta anticipación a la cosecha se podrían realizar dichas estimaciones, generando predicciones de rendimiento que podrían ser reportadas en los momentos más oportunos para el sector agrícola.

1.2 Objetivo general

El objetivo general del presente trabajo es determinar y comparar la capacidad de distintos índices (climáticos y espectrales) de estimar los rendimientos agrícolas a escala departamental en la provincia de Entre Ríos.

1.3 Objetivos específicos

- I) Determinar la capacidad de las precipitaciones y del SPI (índice derivado de las mismas) para estimar el rendimiento de maíz y de soja a nivel departamental en Entre Ríos.

Hipótesis. Debido a que los rendimientos agrícolas dependen de las precipitaciones, éstos datos o algún índice relacionado (como el SPI) en algún mes o período dentro del ciclo de los cultivos podrían estimar rendimientos de maíz y soja.

- II) Evaluar la capacidad de TRMM para estimar la precipitación en Entre Ríos.

Hipótesis. Dado que las estaciones meteorológicas convencionales se encuentran dispersas en la provincia de Entre Ríos, los datos de precipitación de TRMM, que poseen una adecuada resolución espacial, podrían estimar mejor las precipitaciones en comparación con métodos de interpolación.

- III) Determinar la capacidad de un conjunto de modelos basados en índices espectrales y en datos de TRMM para estimar el rendimiento de maíz y de soja a nivel departamental en Entre Ríos.

Hipótesis. Existen índices espectrales y períodos dentro del ciclo de cada cultivo que optimizan la estimación de rendimientos a través de sensores remotos. Debido a las diferencias ambientales a nivel departamental en la provincia de Entre Ríos y en los momentos en los que se produce el período crítico en maíz y soja, se espera que varíen los índices y períodos óptimos para estimar rendimiento entre departamentos y cultivos.

La tesis continúa con tres capítulos de resultados (capítulos 2 a 4 correspondientes a los objetivos I a III) y uno de discusión general (capítulo 5).

Parte de los resultados presentados en este trabajo de tesis fueron publicados:

- Vaiman, N.; Durante, M. 2016. Estimación de las precipitaciones mediante interpolación vs. datos satelitales para Entre Ríos (Argentina). XVI Reunión Argentina y VIII Latinoamericana de Agrometeorología, Puerto Madryn. 20-23 de septiembre de 2016.
- Vaiman, N.; Durante, M. 2016. Evaluación de la precisión de la precipitación estimada a partir de satélite para distintos períodos de acumulación. XVI Reunión Argentina y VIII Latinoamericana de Agrometeorología, Puerto Madryn. 20-23 de septiembre de 2016.

Capítulo 2: **Estimación de rendimientos a través de precipitaciones**

2.1 Introducción

Globalmente, los impactos de las sequías y del cambio climático sobre el rendimiento de los cultivos y la producción de alimentos se encuentran bien documentados (Rötter y van de Geijn, 1999; Sivakumar *et al.*, 2005; Li *et al.*, 2009). No obstante, la variabilidad en los rendimientos de los cultivos se debe principalmente al tiempo y clima local y regional más que a las dinámicas climáticas de gran escala (Thomson *et al.*, 2005), sugiriendo la importancia de análisis locales y regionales.

En Sudamérica, la variabilidad climática puede asociarse parcialmente a anomalías en las temperaturas del océano Pacífico ecuatorial, fenómeno conocido como *El Niño-Southern Oscillation* (ENSO) (Penalba *et al.*, 2005). En el fenómeno ENSO se distinguen tres fases según las temperaturas de la superficie del Océano Pacífico ecuatorial: eventos cálidos (El Niño), eventos fríos (La Niña) y los años que no se encuentran dentro de estas categorías se denominan Neutros, los cuales presentan valores normales de temperatura superficial del agua en la región ecuatorial del Océano Pacífico. En la región pampeana de Argentina, la señal más pronunciada del ENSO se manifiesta en el período octubre-diciembre. Durante los eventos El Niño, las precipitaciones tienden, en términos estadísticos, a ser superiores al promedio histórico, mientras que en los años La Niña tienden a ser inferiores. En los años Neutros (que constituyen alrededor del 50 % del total de la serie histórica) las precipitaciones medias generalmente son similares al promedio histórico (Podestá *et al.*, 2002).

Esta variación cíclica en las precipitaciones es uno de los factores que determinan, a su vez, cambios en los rendimientos de los principales cultivos de la zona pampeana, entre ellos, maíz y soja. Los resultados de estimaciones del cambio en rendimientos muestran que en el caso del maíz existen probabilidades de incrementos de rendimientos en años El Niño y disminuciones en años La Niña, mientras que en soja la asociación negativa es muy fuerte con la fase de La Niña (Magrín, 1998). Los años secos suelen ser muy perjudiciales para los rendimientos de los cultivos, debido a que un déficit de agua puede llegar a inhibir la división, crecimiento y diferenciación celular, produciendo plantas de menor tamaño y con menor rendimiento (Kramer, 1983).

Debido a los efectos de las sequías en las economías basadas en la producción agrícola, se han realizado intentos de seguimientos para determinar su duración e intensidad, dar alarmas, proveer ayuda y estimar sus impactos (Wilhite, 1993; OMM, 1994). Si bien no existe una definición única de sequía, los medios tradicionales utilizados

para identificarla, caracterizarla o evaluarla, se fundamentan en la aplicación de información meteorológica, expresando el desequilibrio hídrico a partir de indicadores elaborados con variables atmosféricas u obtenidos por medio de procedimientos de balance hidrológico. Dentro de los primeros se puede citar al Índice Estandarizado de Precipitación (IPE o SPI, por sus siglas en inglés) (Mckee *et al.*, 1993, 1995), que cuantifica el déficit de precipitación para escalas temporales múltiples.

El SPI ha sido ampliamente utilizado para escalas de tiempo de 3, 6 o 12 meses, ya que solo requiere datos de precipitaciones para su aplicación. Además, es efectivo para analizar los períodos y ciclos tanto húmedos como secos. El cálculo de este índice requiere de una serie histórica entre 20 y 30 años de valores mensuales de precipitación, pero lo óptimo y preferible sería contar con entre 50 y 60 años (o más) (Guttman, 1994). La función de distribución de probabilidad se determina ajustando una distribución Gamma a los datos (Mood y Graybill, 1963), y luego la distribución acumulada es transformada usando igual probabilidad que una distribución normal con media igual a cero y desvío estándar igual a uno (Edwards y McKee, 1997).

Las distintas escalas de tiempo del SPI se relacionan con distintos procesos. La humedad del suelo responde a anomalías de precipitación en escalas temporales relativamente cortas, por ejemplo, de entre 1 y 6 meses, mientras que los caudales fluviales, el almacenamiento en reservorios y las aguas subterráneas responden a anomalías de precipitación a más largo plazo, del orden de 6 meses y hasta 24 meses o más. El SPI de 3 meses de un mes en particular ofrece una comparación de la precipitación a lo largo de un período específico de 3 meses que terminan en el mencionado mes con el promedio de precipitación del mismo período de todos los años incluidos en el registro histórico. En otras palabras, un SPI de 3 meses al final de febrero compara el total de la precipitación de los meses de diciembre, enero y febrero de ese año concreto con el promedio de precipitación entre diciembre y febrero de todos los años contemplados en el registro para esa localidad. El SPI de 3 meses refleja las condiciones de humedad a corto y medio plazo, y proporciona una estimación estacional de la precipitación. En las principales regiones agrícolas, y para los momentos en que se producen los períodos críticos de definición de rendimiento de los cultivos, un SPI de 3 meses podría ser más eficaz para poner de relieve la existencia de condiciones de humedad que el índice de Palmer (Palmer, 1965), de respuesta más lenta. En India, por ejemplo, se lo ha correlacionado significativamente con la producción de granos para

alimentación (Chaudhari y Dadhwal, 2004; Patel *et al.*, 2007). Un SPI de 3 meses al final de agosto en el cinturón maicero en Estados Unidos refleja tendencias de precipitación durante las importantes etapas de reproducción y llenado del grano para el maíz y la soja (OMM, 2012) y se han encontrado correlaciones significativas entre el SPI y el rendimiento de estos cultivos (Yamoha *et al.*, 2000; Mishra y Cherkauer, 2010).

El objetivo de este capítulo es determinar la capacidad de las precipitaciones y del SPI para estimar el rendimiento de maíz y de soja a nivel departamental en Entre Ríos. La hipótesis es que los rendimientos agrícolas dependen de las precipitaciones por lo que éstas o algún índice derivado de las mismas (como el SPI) en algún mes o período dentro del ciclo de los cultivos podrían estimar rendimientos de maíz y soja.

2.2 Metodología

2.2.1 Datos climáticos

2.2.1.1 Datos de precipitación

Los datos de precipitaciones mensuales utilizados tanto para las predicciones de rendimientos como para el cálculo de SPI de 3 meses (ver punto 2.2.1.2) corresponden a cuatro estaciones meteorológicas convencionales (EMC) de la provincia de Entre Ríos (figura 2.1): Concordia (Servicio Meteorológico Nacional, SMN), Concepción del Uruguay (INTA), Gualeguaychú (SMN) y Paraná (INTA). Los datos de estas estaciones tienen un control de calidad realizado en origen para disminuir datos erróneos o dudosos y completar datos faltantes. El período analizado corresponde al período 1963-2012 ($n = 50$ años), y para la correlación con los rendimientos se utilizaron los meses correspondientes al semestre cálido (octubre-marzo).

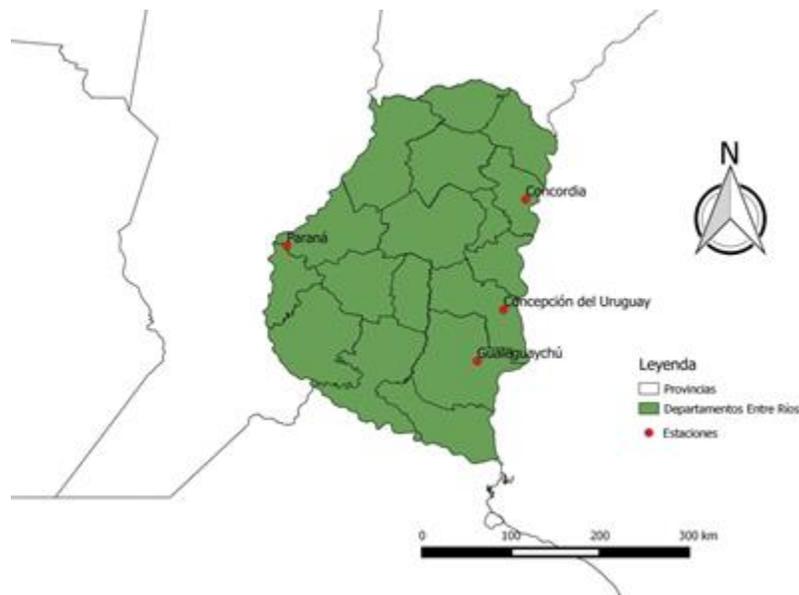


Figura 2.1. Localización de las EMC utilizadas para generar precipitaciones interpoladas departamentales y SPI.

Dado que se dispone de datos departamentales de rendimiento, los datos de precipitación fueron interpolados espacialmente para lograr un dato de precipitación mensual por cada punto central de cada departamento. El método empleado para la interpolación fue el de la inversa de la distancia al cuadrado, ya que en Entre Ríos mostró un mejor ajuste con la precipitación real que la inversa de la distancia (Vaiman y Durante, 2016). Para cada departamento y mes, se realizó un análisis de la serie temporal encontrando que no existe tendencia significativa al 5%. El mismo análisis se realizó para el SPI (punto 2.2.1.2) y se obtuvo el mismo resultado.

Tanto para las precipitaciones como para el SPI de 3 meses se seleccionaron los valores promedio de distintos períodos de tiempo (meses por separado -en el caso del SPI, el mes indica el mes final del período- y períodos de duración creciente; 15 períodos para maíz y 21 períodos para soja) dentro del ciclo de los cultivos de maíz y soja (figura 2.2).

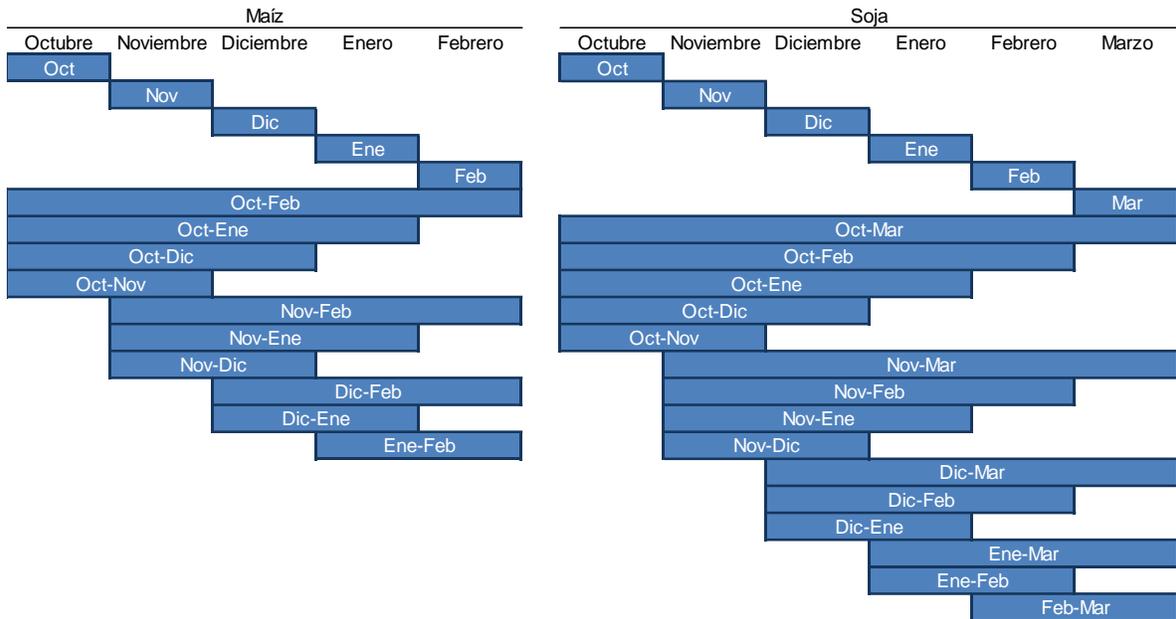


Figura 2.2. Períodos analizados con datos de precipitaciones y SPI de 3 meses en maíz y soja para correlacionar con el rendimiento final del cultivo.

2.2.1.2 Datos de SPI de 3 meses

Con los datos mensuales de precipitaciones de las EMC previamente mencionados, se calcularon los valores de SPI de 3 meses para cada punto central de cada departamento. El SPI de 3 meses de un mes en particular se calcula con datos de dicho mes y los dos meses anteriores. El cálculo de SPI requiere ajustar la función de distribución Gamma de dos parámetros (alfa $-\alpha-$ y beta $-\beta-$) a la distribución de frecuencia de los datos de precipitación para cada estación (McKee *et al.*, 1993). Luego, se calculan la probabilidad acumulada de un determinado valor de precipitación y la función normal (Gaussiana) inversa se aplica a la probabilidad. El resultado es el valor del SPI.

Thom (1966) encontró que la distribución Gamma se ajustaba adecuadamente a series climatológicas de precipitación. La distribución Gamma está definida por su función de frecuencia:

$$g(x) = \frac{1}{\beta^\alpha \Gamma(\alpha)} x^{\alpha-1} e^{-x/\beta}$$

donde

$$\alpha > 0$$

α es el parámetro de forma

$\beta > 0$	β es el parámetro de escala
$x > 0$	x es la precipitación mensual
$\Gamma(\alpha) = \int_0^{\infty} y^{\alpha-1} e^{-y} dy$	$\Gamma(\alpha)$ es la función Gamma

Los parámetros alfa y beta de la función Gamma se estimaron para cada punto central de los departamentos y para cada mes del año. Para el cálculo se utilizó el software propuesto en la guía del usuario del SPI (OMM, 2012), disponible en la página web del Centro Nacional de Mitigación de Sequías de la Universidad de Nebraska Lincoln de Estados Unidos (<http://drought.unl.edu/MonitoringTools/DownloadableSPIProgram.aspx>). Los datos utilizados para las correlaciones corresponden a los datos de SPI de los meses de octubre a marzo de la serie 1963-2012, ya sea como mes simple (que también incluye a los dos meses anteriores) o como promedio de distintos períodos (figurar 2.2).

2.2.2 Construcción de las variables predictoras o independientes

Para la predicción de rendimientos se realizaron correlaciones lineales entre los datos de precipitación y SPI en los distintos períodos (variables X o independientes) y los de rendimiento equivalente (variable Y o dependiente; ver punto 2.2.4). Para nombrar las variables predictoras se utilizó el nombre de la variable climática (precipitación -PP- o SPI) y el mes o período correspondiente. Así, por ejemplo, la variable predictora PP-Nov-Ene corresponde a la precipitación media del período comprendido entre noviembre y enero del año siguiente de cada año en particular, y SPI-Feb corresponde al Índice Estandarizado de Precipitaciones de febrero (que incluye información de diciembre, enero y febrero) de cada año en particular. Si bien todas las variables se trataron de la misma manera, a los fines de facilitar la comprensión, los resultados pueden estar diferenciados entre precipitaciones y SPI en algunos casos.

2.2.3 Generación de modelos lineales de predicción de rendimiento

El conjunto de datos completo (con $n = 45$ en maíz y $n=41$ en soja, ver punto 2.2.4) fue dividido en subconjuntos de calibración y validación. Para evaluar la capacidad de predicción de los modelos, se extrajo de manera aleatoria el 70% de los datos para calibración, y el 30% se usó para la validación en 100 iteraciones. En cada iteración, un

modelo de regresión lineal generado con el subconjunto de datos de calibración se usó para predecir el rendimiento de maíz y soja del subconjunto de validación y se estimaron algunos descriptores de la capacidad de predicción de los modelos. Como descriptores de la capacidad de predicción se usaron: la raíz cuadrada del cuadrado medio del error (RCME o *RMSE*, por sus siglas en inglés), el coeficiente de determinación (R^2), que proveen una medida de la bondad de ajuste, y los valores de la pendiente y la ordenada al origen de la ecuación de ajuste lineal entre los valores observados y predichos. El procesamiento se realizó mediante el software libre RStudio (R Core Team, 2016).

2.2.4 Datos de rendimientos departamentales

Los datos de rendimiento de los departamentos de la provincia de Entre Ríos fueron adquiridos del Portal de Datos Abiertos del Ministerio de Agroindustria (Ministerio de Agroindustria, 2017). Los datos correspondientes a maíz pertenecen a un período de 45 años (campañas 1969/70 a 2014/15) y los correspondientes a soja pertenecen a un período de 41 años (campañas 1973/74 a 2014/15).

Los datos de rendimientos de maíz y de soja a nivel provincial (promediando todos los departamentos) presentaron tendencia significativa ($p < 0,01$). Las pendientes indican incrementos anuales de aproximadamente $130 \text{ kg. ha.}^{-1} \text{ año}^{-1}$ en maíz y de $30 \text{ kg. ha.}^{-1} \text{ año}^{-1}$ en soja (figura 2.3).

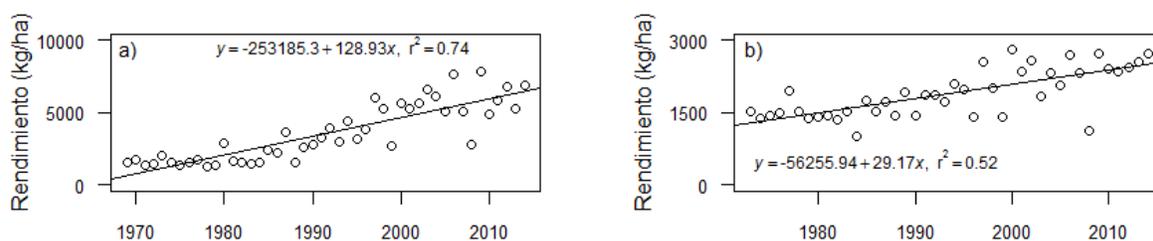


Figura 2.3. Tendencia del rendimiento promedio provincial de a) maíz (n=45) y b) soja (n=41).

Por lo tanto, para cada cultivo y cada departamento, se realizó un análisis de tendencia en la serie de datos. En aquellos departamentos en los que la pendiente resultó estadísticamente significativa ($p < 0,01$), se procedió a ajustar un modelo de regresión lineal para luego calcular los rendimientos equivalentes para cada año y evitar el sesgo

que produciría trabajar con datos con tendencia. El rendimiento equivalente se calculó de la siguiente manera:

$$Rto_{eq} = \frac{Rto_{real}}{Rto_{est}} Rto_{prom}$$

donde

Rto_{eq}	=	rendimiento equivalente
Rto_{real}	=	rendimiento real
Rto_{est}	=	rendimiento estimado mediante regresión lineal
Rto_{prom}	=	rendimiento promedio de la serie histórica

El análisis de tendencia en los datos de rendimiento departamentales, también indicó que en todos los departamentos, excepto San Salvador, la tendencia resultó estadísticamente significativa (tabla 2.1).

Tabla 2.1. Ordenada al origen (en t. ha⁻¹) y pendiente (en t. ha⁻¹. año⁻¹) de la serie de datos de rendimientos departamentales (n=45 para maíz y n=41 para soja).

Departamento	Maíz		Soja	
	Pendiente	Ordenada	Pendiente	Ordenada
Colón	0,110**	-217	0,023**	-45
Concordia	0,129**	-255	0,032**	-62
Diamante	0,157**	-309	0,034**	-65
Federación	0,121**	-238	0,027**	-51
Federal	0,151**	-297	0,036**	-70
Feliciano	0,128**	-252	0,041**	-79
Galeguay	0,136**	-268	0,029**	-55
Galeguaychú	0,118**	-232	0,029**	-55
La Paz	0,149**	-293	0,035**	-69
Nogoyá	0,127**	-249	0,026**	-49
Paraná	0,151**	-297	0,035**	-69
San Salvador	0,068	-129	0,05	-98
Tala	0,109**	-215	0,027**	-53
Uruguay	0,115**	-226	0,031**	-60
Victoria	0,152**	-298	0,031**	-60
Villaguay	0,113**	-223	0,025**	-48

**Pendientes significativas (p<0,01).

2.3 Resultados

2.3.1 Modelos lineales

La capacidad de las precipitaciones y el SPI de explicar los rendimientos resultó variable en los distintos períodos analizados, tanto para maíz como para soja, al considerar los rendimientos promedio para todos los departamentos (figura 2.4). El coeficiente de determinación de las correlaciones entre las variables climáticas y el rendimiento mostró un ajuste variable, pero en general bajo.

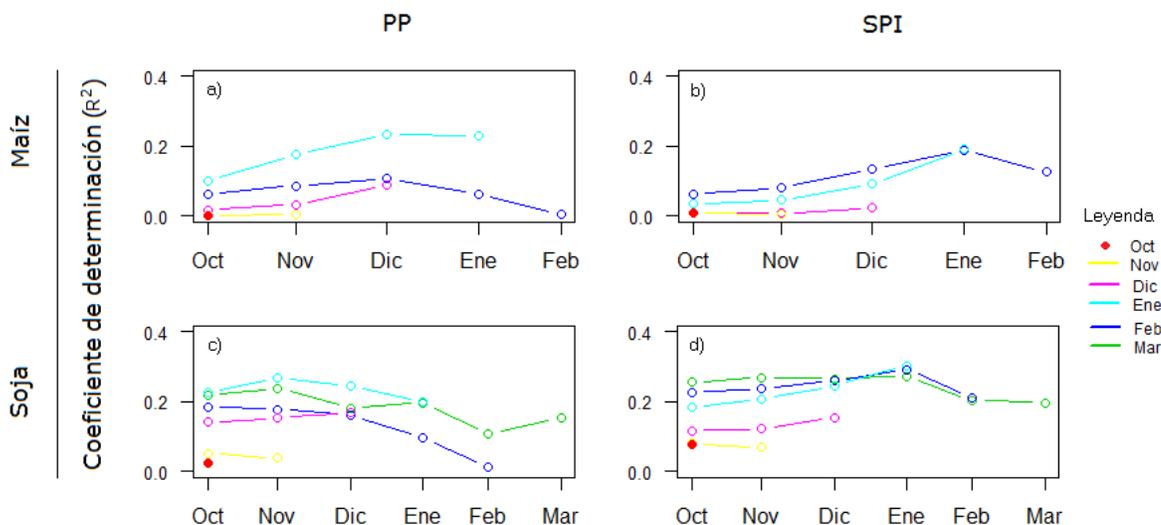


Figura 2.4. Coeficiente de determinación para cada cultivo y variable predictora. a) precipitaciones en maíz; b) SPI en maíz; c) precipitaciones en soja; d) SPI en soja. Aclaración: la leyenda indica el último mes considerado en cada período de tiempo analizado (ejemplo: el primer punto de la línea celeste -de izquierda a derecha- corresponde al período octubre-noviembre-diciembre-enero, el segundo corresponde al período noviembre-diciembre-enero; el tercero corresponde al período diciembre-enero y el cuarto corresponde al mes de enero).

El rendimiento de maíz se correlacionó mejor con la precipitación en el mes de enero (PP-Ene) y el período diciembre-enero (PP-Dic-Ene) ($R^2=0,23$; $p<0,01$). Los menores coeficientes de determinación se observaron en las precipitaciones de los meses de octubre (PP-Oct), noviembre (PP-Nov), febrero (PP-Feb) y del período octubre-noviembre (PP-Oct-Nov). Con respecto al SPI, el mejor ajuste se observó en enero (SPI-Ene) y en el período enero-febrero (SPI-Ene-Feb) ($R^2=0,19$; $p<0,01$) y el menor ajuste se observó en los meses de octubre (SPI-Oct) y noviembre (SPI-Nov) y en los períodos

octubre-noviembre (SPI-Oct-Nov), octubre-diciembre (SPI-Oct-Dic) y noviembre-diciembre (SPI-Nov-Dic) (tabla 2.2).

Tabla 2.2. Mediana de la ordenada al origen (en t. ha⁻¹), pendiente (en t. ha⁻¹. mm⁻¹ en el caso de PP y en t. ha⁻¹ en el caso de SPI) y coeficiente de determinación (R²) para cada variable predictora del rendimiento en maíz.

Maíz							
PP				SPI			
Variable	Ordenada	Pendiente	R ²	Variable	Ordenada	Pendiente	R ²
PP-Oct-Feb	2,8	0,0079	0,06	SPI-Oct-Feb	3,7	0,4448	0,06
PP-Oct-Ene	2,5	0,0096	0,10*	SPI-Oct-Ene	3,7	0,3113	0,03
PP-Oct-Dic	3,2	0,0034	0,02	SPI-Oct-Dic	3,8	0,1221	0,00
PP-Oct-Nov	3,7	-0,0005	0,00	SPI-Oct-Nov	3,8	0,0209	0,00
PP-Oct	3,7	0,0005	0,00	SPI-Oct	3,8	0,0328	0,00
PP-Nov-Feb	2,7	0,0087	0,09•	SPI-Nov-Feb	3,7	0,5149	0,08•
PP-Nov-Ene	2,3	0,0127	0,18**	SPI-Nov-Ene	3,7	0,3664	0,05
PP-Nov-Dic	3,2	0,0047	0,03	SPI-Nov-Dic	3,8	0,1521	0,00
PP-Nov	3,9	-0,0013	0,00	SPI-Nov	3,8	0,0162	0,00
PP-Dic-Feb	2,7	0,0082	0,11*	SPI-Dic-Feb	3,7	0,5764	0,13*
PP-Dic-Ene	2,4	0,0112	0,23**	SPI-Dic-Ene	3,7	0,4608	0,09*
PP-Dic	3,1	0,0053	0,09•	SPI-Dic	3,8	0,2348	0,02
PP-Ene-Feb	3,0	0,0055	0,06	SPI-Ene-Feb	3,7	0,7089	0,19**
PP-Ene	2,4	0,0096	0,23**	SPI-Ene	3,7	0,6275	0,19**
PP-Feb	3,8	-0,0004	0,00	SPI-Feb	3,7	0,5521	0,13*

Referencias: • significativo al 10%; * significativo al 5%; ** significativo al 1%.

El rendimiento de soja se correlacionó mejor con la precipitación en el período noviembre-enero (PP-Nov-Ene) (R²=0,27; p<0,01). El menor coeficiente de determinación se observó con las precipitaciones del mes de febrero (PP-Feb) (tabla 2.3). Con respecto al SPI, el mejor ajuste se observó en enero (SPI-Ene) (R²=0,30; p<0,01) y el menor ajuste se observó en el mes de noviembre (SPI-Nov).

Tabla 2.3. Mediana de la ordenada al origen, pendiente y coeficiente de determinación (R^2) para cada variable predictora del rendimiento en soja.

Soja							
PP				SPI			
Variable	Ordenada	Pendiente	R^2	Variable	Ordenada	Pendiente	R^2
PP-Oct-Mar	1,4	0,0041	0,22**	SPI-Oct-Mar	1,9	0,2633	0,25**
PP-Oct-Feb	1,4	0,0039	0,18*	SPI-Oct-Feb	1,9	0,2472	0,23**
PP-Oct-Ene	1,4	0,0038	0,23**	SPI-Oct-Ene	1,9	0,2059	0,18**
PP-Oct-Dic	1,6	0,0028	0,14*	SPI-Oct-Dic	1,9	0,1580	0,12•
PP-Oct-Nov	1,7	0,0016	0,05	SPI-Oct-Nov	1,9	0,1274	0,08•
PP-Oct	1,8	0,0008	0,02	SPI-Oct	1,9	0,1197	0,08
PP-Nov-Mar	1,4	0,0043	0,24**	SPI-Nov-Mar	1,9	0,2638	0,27**
PP-Nov-Feb	1,4	0,0038	0,18**	SPI-Nov-Feb	1,9	0,2432	0,24**
PP-Nov-Ene	1,4	0,0040	0,27**	SPI-Nov-Ene	1,9	0,1962	0,21**
PP-Nov-Dic	1,6	0,0027	0,15*	SPI-Nov-Dic	1,9	0,1452	0,12*
PP-Nov	1,8	0,0011	0,04	SPI-Nov	1,9	0,1143	0,07
PP-Dic-Mar	1,4	0,0034	0,18**	SPI-Dic-Mar	1,9	0,2508	0,26**
PP-Dic-Feb	1,5	0,0031	0,16*	SPI-Dic-Feb	1,9	0,2375	0,26**
PP-Dic-Ene	1,5	0,0030	0,25**	SPI-Dic-Ene	1,9	0,1974	0,24**
PP-Dic	1,7	0,0022	0,17*	SPI-Dic	1,9	0,1555	0,15*
PP-Ene-Mar	1,4	0,0033	0,20**	SPI-Ene-Mar	1,9	0,2593	0,27**
PP-Ene-Feb	1,6	0,0021	0,10•	SPI-Ene-Feb	1,9	0,2594	0,29**
PP-Ene	1,6	0,0026	0,20**	SPI-Ene	1,9	0,2385	0,30**
PP-Feb-Mar	1,6	0,0019	0,11•	SPI-Feb-Mar	1,9	0,2092	0,20**
PP-Feb	1,8	0,0005	0,01	SPI-Feb	1,9	0,2046	0,21**
PP-Mar	1,7	0,0019	0,15*	SPI-Mar	1,9	0,1781	0,20**

Referencias: • significativo al 10%; * significativo al 5%; ** significativo al 1%.

2.3.2 Evaluación de la capacidad de predicción de los modelos lineales

Considerando todos los departamentos y el cultivo de maíz, al evaluar la capacidad de predicción de los modelos a través de remuestreos (iteraciones) no se encontraron diferencias entre aquellos que usaron PP y SPI (figura 2.5).

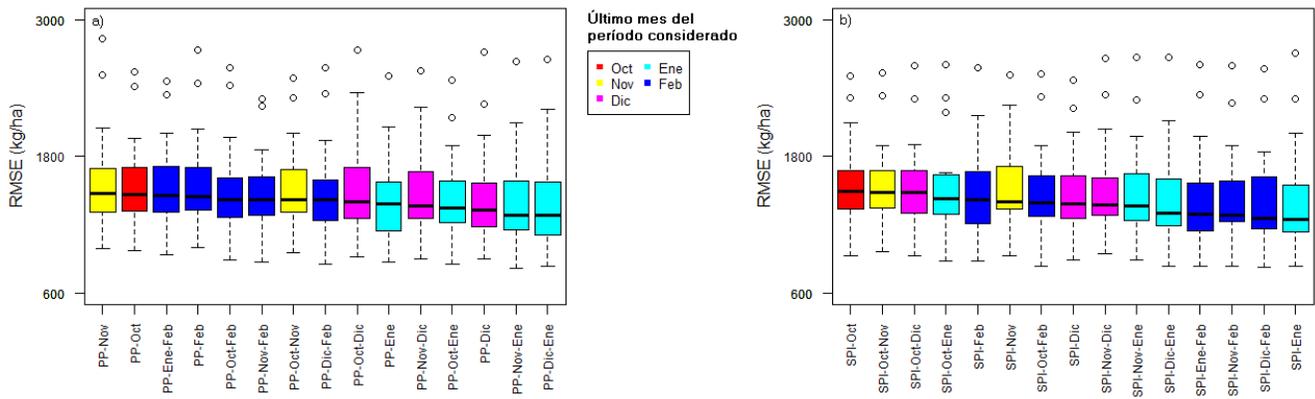


Figura 2.5. Diagramas de caja y bigote mostrando el RMSE de los distintos modelos lineales para la predicción del rendimiento de maíz, utilizando como variable predictora a a) precipitaciones; b) SPI. El color de la caja se asocia con el último mes (o mes individual) de cada período analizado.

En soja, de los modelos que utilizaron PP, sólo presentaron diferencias PP-Dic-Ene y PP-Nov-Ene, los cuales produjeron RMSE menores que los de PP-Oct, PP-Nov y PP-Feb. El resto no presentó diferencias entre sí (figura 2.6). Los modelos que utilizaron SPI presentaron diferencias entre SPI-Dic-Mar, SPI-Ene, SPI-Ene-Feb, SPI-Ene-Mar (RMSE menores) con respecto a SPI-Oct (RMSE mayor). El resto no presentó diferencias entre sí.

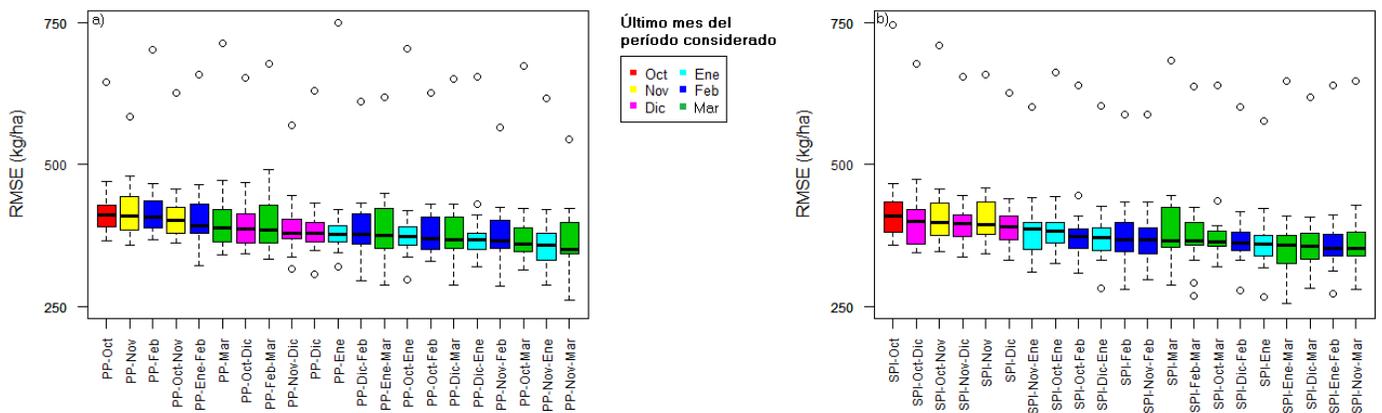


Figura 2.6. Diagramas de caja y bigote mostrando el RMSE de los distintos modelos lineales para la predicción del rendimiento de soja, utilizando como variable predictora a a) precipitaciones; b) SPI. El color de la caja se asocia con el último mes (o mes individual) de cada período analizado.

A nivel departamental y en ambos cultivos, resultaron variables tanto los periodos como los índices óptimos. El ajuste alcanzado también resultó variable. En maíz, los coeficientes de determinación de los modelos que utilizaron a PP presentaron un máximo en la variable PP-Nov-Dic con un $R^2=0,87$ (San Salvador) y un mínimo de $R^2=0,02$ (PP-Oct en Federación). Los coeficientes de determinación de los modelos que utilizaron a SPI presentaron un máximo en la variable SPI-Dic con un $R^2=0,76$ (San Salvador) y un mínimo de $R^2=0,04$ (SPI-Oct-Nov en Federación).

En soja, los coeficientes de determinación de los modelos que utilizaron a PP como variable predictora presentaron un máximo en la variable PP-Oct-Nov con un $R^2=0,70$ (San Salvador) y un mínimo de $R^2=0,05$ (PP-Feb en Paraná). Los coeficientes de determinación de los modelos que utilizaron a SPI presentaron un máximo en la variable SPI-Oct-Ene con un $R^2=0,65$ (San Salvador) y un mínimo de $R^2=0,05$ (SPI-Oct en La Paz).

2.4 Discusión

El SPI presentó valores máximos de correlación más altos que los encontrados en la correlación con las precipitaciones. Si bien en maíz no se observaron diferencias, en soja los valores de la mediana de los coeficientes de determinación resultaron más elevados para SPI que para precipitaciones. Esto puede deberse a que la precipitación no se distribuye de forma normal, y por lo tanto, los valores absolutos de la misma se correlacionan más pobremente con los rendimientos si se los compara con los valores de precipitaciones estandarizados (Teigen y Thomas, 1995).

Tanto el máximo coeficiente de determinación entre precipitaciones y el rendimiento de maíz (PP-Dic: $R^2=0,87$, dato no mostrado), como el mayor valor medio (PP-Dic-Ene: $R^2=0,24$) incluyen al mes de diciembre, considerado como mes en el que ocurre el período crítico de definición de rendimiento del cultivo. De los modelos que utilizaron PP, la mediana del error relativo de las variables predictoras que incluyen a diciembre es de 23% siendo el error relativo más bajo, mientras que el error relativo más alto se encuentra en PP-Feb con un 29% (datos no mostrados). Con respecto al SPI se da una situación similar. El máximo coeficiente de determinación entre este índice y el rendimiento de maíz (SPI-Dic: $R^2=0,76$, dato no mostrado), y el mayor valor medio (SPI-Ene-Feb: $R^2=0,19$) incluyen información del mes de diciembre (el SPI de enero incluye información de noviembre, diciembre y enero y el SPI de febrero incluye información de diciembre, enero

y febrero). Este valor medio es inferior al reportado por Mishra y Cherkauer (2010) para etapas reproductivas de maíz en el oeste de Estados Unidos ($R^2=0,37$). El error relativo más bajo encontrado corresponde a SPI-Ene con un 21% (que incluye información de diciembre), mientras que el valor más alto se encontró en SPI-Oct con un 29% (datos no mostrados).

En cuanto a soja, el máximo coeficiente de determinación entre precipitaciones y el rendimiento del cultivo (PP-Ene-Mar: $R^2=0,70$ –variable que a su vez presenta el menor error relativo = 11%-, datos no mostrado) incluye al período crítico del cultivo (producido en el mes de febrero). En cambio, el mayor valor medio (PP-Nov-Ene: $R^2=0,27$) corresponde a un momento previo al período crítico dentro del ciclo completo del cultivo. Estos resultados son similares a los hallados por Bettolli *et al.* (2002) en la región pampeana. Con respecto al SPI, tanto el máximo coeficiente de determinación entre éste índice y el rendimiento de soja (SPI-Ene-Mar: $R^2=0,66$) como el mayor valor medio (SPI-Ene-Feb: $R^2=0,30$) incluyen al mes considerado como crítico para la definición de rendimientos. Este valor medio es inferior al citado por Mishra y Cherkauer (2010) para la etapa de llenado de grano del cultivo de soja en el oeste de Estados Unidos ($R^2=0,57$). Ambas variables (SPI-Ene-Mar y SPI-Ene-Feb) presentan un error relativo del 12%.

Los modelos lineales en maíz no presentaron diferencias en la capacidad de estimar rendimientos considerando el RMSE. Sin embargo, existe una tendencia a que los meses que incluyen información de diciembre (tanto utilizando PP como SPI) presenten un menor error de predicción (aunque en todos los casos con $RMSE > 1200 \text{ kg}\cdot\text{ha}^{-1}$) y un mayor coeficiente de determinación. En cambio, los modelos lineales en soja presentaron diferencias a favor de aquellos que utilizaron información de la precipitación previa al período crítico y del SPI centrado en dicho período (aunque en todos los casos con $RMSE > 350 \text{ kg}\cdot\text{ha}^{-1}$). En este caso, sería ventajoso utilizar aquellas variables que ofrezcan mayor anticipación sin aumentar el error de la estimación (por ejemplo, SPI de enero o PP de diciembre en maíz y PP de noviembre-enero o SPI de enero-febrero en soja). La facilidad para calcular SPI mediante software libre no dificultaría la obtención de dicho índice si este fuera necesario en algún caso particular.

Estos resultados indican que la información próxima al período crítico de cada cultivo es importante en la estimación de rendimientos. Esto se podría explicar por la influencia que tiene la disponibilidad hídrica en distintos factores que afectan el rendimiento de los cultivos. Por un lado, un déficit hídrico afecta la expansión foliar y la

intercepción de radiación (Cox y Joliff, 1986; Eck, 1986) y por otra parte también se reduce la eficiencia de conversión de la radiación en biomasa (Andriani *et al.*, 1991; Otegui, 1992). A su vez, cualquier estrés producido alrededor del período crítico, reduce el rendimiento en mayor proporción que el mismo estrés en otros períodos, ya sean previos o posteriores (Andrade y Sadras, 2002).

El análisis de estos datos sugiere que, para estimar rendimientos con información climática mensual, es necesario incluir el mes en el que se produce el período crítico de determinación de rendimientos en ambos cultivos. Para maíz, esto significa que se debe incluir información de precipitaciones de diciembre, ya sea como precipitación en sí misma o como SPI de dicho mes o hasta dos meses posteriores. Sin embargo, en este caso, las precipitaciones de diciembre proveerían una estimación más anticipada que el SPI de meses posteriores. Esto es, aproximadamente, dos meses previos a la cosecha del cultivo. En cuanto a soja, se debería incluir información del mes de febrero, que al igual que en maíz, puede realizarse con la precipitación en sí misma o con el SPI de dicho mes o hasta dos posteriores. Sin embargo, considerando el SPI, existieron diferencias favoreciendo a aquellos modelos que utilizaron información hasta el mes de marzo. Esto retrasaría el momento de estimación (hasta un mes antes de la cosecha), pero con mayores coeficientes de determinación y menores RMSE. También cabe destacar el SPI medio del período enero-febrero que podría estimar el rendimiento con datos que incluyen sólo hasta febrero (dos meses antes de la cosecha).

Capítulo 3: **Comparación entre interpolación y datos satelitales en la estimación de las precipitaciones en Entre Ríos**

3.1 Introducción

Muchos procesos bióticos y abióticos son influenciados por las características climáticas del ambiente. Por lo tanto, las ciencias como la biología, agronomía, climatología y ecología, entre otras, utilizan información climática con distintos propósitos. Sin embargo, ésta puede presentar dos tipos de inconvenientes. El primero surge de la calidad de la información, problema que puede ser subsanado con controles de calidad y métodos de homogeneización (Rhoades y Salinger 1993; Easterling y Peterson 1995; Alexandersson y Moberg, 1997). Además, si bien existen muchas estaciones meteorológicas automáticas, éstas carecen de un mantenimiento adecuado y poseen registros históricos cortos. El segundo inconveniente es la disponibilidad de la información climática. Esto es debido a que los datos se registran en estaciones meteorológicas convencionales (EMC) que suelen estar dispersas, lo que lleva a que muchas veces la información climática no esté disponible donde se la necesita.

Varios métodos estadísticos se han desarrollado para estimar el valor de variables meteorológicas en áreas sin EMC y así resolver el problema de la falta de estaciones. Estos métodos difieren en concepto y en formulación matemática (Borrough y McDonnell, 1998). Algunos utilizan información topográfica y geográfica mediante modelos empíricos de regresión simple o múltiple (Edwards, 1972; Hargy, 1997, Agnew y Palutikof, 2000; Brown y Comrie, 2002). Otros métodos, como los interpoladores locales, sólo utilizan datos climáticos de estaciones meteorológicas. En éstos, la estimación en un punto dado proviene de los datos de las EMC más cercanas. Usando los datos cercanos, se formula alguna función matemática que se utiliza para estimar el valor de la variable en dicho punto. Estos métodos, como la inversa de la distancia, han sido frecuentemente utilizados para pronósticos climáticos y mapeo de las variables meteorológicas (Thiessen, 1911; Willmott *et al.*, 1985; Hutchinson, 1995; New *et al.*, 2000). Sin embargo, la complejidad topográfica genera una diversidad de microclimas donde las variables climáticas son muy difíciles de estimar (Daly *et al.*, 2002).

Otra opción es la de estimar las precipitaciones desde el espacio usando instrumentos pasivos y activos (radar) de forma combinada. Esta idea surgió en la década de 1980 (Kummerow *et al.*, 2000) y puede ser una fuente importante de información debido a la cobertura espacial que ofrecen. El radar para estimar precipitaciones a bordo de TRMM (*Tropical Rainfall Measuring Mission*) es el primer radar diseñado específicamente para estimar la precipitación desde el espacio (Kummerow *et al.*, 2000).

Éste y otros instrumentos utilizados para generar datos provenientes de TRMM han brindado información muy valiosa acerca de la estructura de las precipitaciones. Algunos ejemplos indican que se ha podido mostrar la propagación de precipitaciones en tierra y sobre los océanos (Takayabu *et al.*, 1999), la supresión de las precipitaciones en nubes contaminadas por smog (Rosenfeld, 2000) y hasta se ha podido estudiar la distribución del tamaño de gotas (Haddad *et al.*, 1997; Viltard *et al.*, 2000) y la humedad de suelo (Mao *et al.*, 2008). Los principales instrumentos a bordo de TRMM se describen en Kummerow *et al.* (1998).

Los productos de la misión TRMM han sido validados con datos de superficie para distintos lugares del planeta (Wolff *et al.*, 2005) y se ha encontrado que en general resultan buenos estimadores de la precipitación inclusive en terrenos montañosos (Duan y Bastiaanssen, 2013). Sin embargo, cerca de cuerpos de agua continentales, la performance de la estimación baja (Karaseva *et al.*, 2012), por lo que en Entre Ríos debería estudiarse el uso de estos productos antes de utilizarlos libremente.

Las referencias más cercanas son de estudios hechos para toda Sudamérica (Rozante *et al.*, 2010), Perú (Lavado Casimiro *et al.*, 2009) y el noroeste de Buenos Aires (Campos y Figueroa Schibber, 2014), trabajos en los cuales se hallaron buenos resultados considerando la escala espacial. Sin embargo, muchos de los trabajos que evalúan su precisión y/o exactitud han logrado resultados satisfactorios en la escala mensual (Adler *et al.*, 2003; Chiu *et al.*, 2006a,b; Nicholson *et al.*, 2003a,b), pero para usos agronómicos suele ser necesaria una escala de tiempo menor, como la diaria, decádica o quincenal, siempre que éstas se encuentren disponibles. Un reciente estudio de Brizuela *et al.* (2015) indica que en Entre Ríos los datos del producto 3B42RT de TRMM podrían usarse con un acumulado de 8 días para el sector agrícola ya que, tanto para dicho período de acumulación como para la escala mensual, hallaron una relación moderadamente fuerte que explicó un 50% o más de la variabilidad en la correlación con datos observados.

El objetivo de este capítulo es evaluar la capacidad de TRMM para estimar la precipitación en distintos períodos de acumulación (entre un día y un mes) en Entre Ríos. De producir resultados satisfactorios, los datos de TRMM se utilizarán en combinación con otros índices espectrales para estimar rendimientos agrícolas. La hipótesis es que al presentar mejor cobertura espacial que las EMC, los productos TRMM podrían ofrecer mejores estimaciones de la precipitación en comparación con métodos de interpolación.

3.2 Metodología

Debido a la mayor disponibilidad de datos de estaciones meteorológicas a escala mensual, se hicieron dos tipos de análisis según la escala temporal. A escala mensual se compararon las estimaciones de precipitación basadas en interpolaciones versus precipitaciones reales (observadas) y TRMM versus precipitaciones reales. A escala menor al mes, se evaluó la precisión de TRMM para distintos períodos de acumulación.

3.2.1 Análisis mensual

3.2.1.1 Datos de precipitación mensual

Se utilizaron datos de precipitaciones mensuales de nueve estaciones meteorológicas convencionales (tabla 3.1), cinco de la provincia de Entre Ríos y cuatro fuera de la provincia (figura 3.1) para realizar las interpolaciones, en el período 2000-2012. Los datos de estas estaciones tienen un control de calidad realizado en origen para disminuir datos erróneos o dudosos y completar datos faltantes.

Tabla 3.1. EMC utilizadas para el análisis de la capacidad de TRMM de estimar precipitación mensual.

Estación	Latitud (°)	Longitud (°)
Galeguaychú (SMN), Entre Ríos	-33,01	-58,61
Concepción del Uruguay (INTA), Entre Ríos	-32,49	-58,34
Concordia (INTA), Entre Ríos	-31,37	-58,12
Paraná (INTA), Entre Ríos	-31,84	-60,53
Gobernador Echagüe (DH), Entre Ríos	-32,39	-59,27
Santa Fé (FICH-UNL), Santa Fé	-31,64	-60,67
San Pedro (INTA), Buenos Aires	-33,68	-59,68
Salto Grande (INUMET), República Oriental del Uruguay	-31,27	-57,89
Colonia (INUMET), República Oriental del Uruguay	-34,34	-57,69

Referencias: SMN: Servicio Meteorológico Nacional; INTA: Instituto Nacional de Tecnología Agropecuaria; DH: Dirección de Hidráulica de la Provincia de Entre Ríos; FICH-UNL: Facultad de Ingeniería y Ciencias Hídricas de la Universidad Nacional del Litoral; INUMET: Instituto Uruguayo de Meteorología.

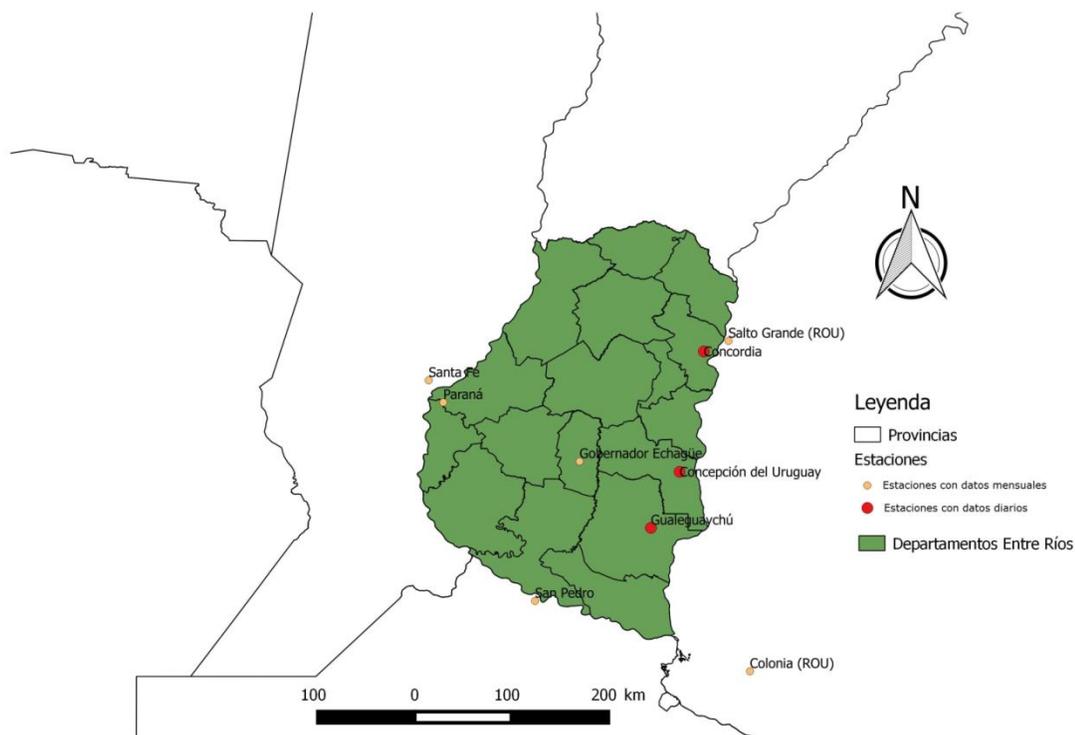


Figura 3.1. Mapa con la ubicación de las EMC utilizadas para evaluar la capacidad de TRMM de estimar precipitaciones mensuales y de distintos períodos de acumulación en Entre Ríos.

3.2.1.2 Metodología

Los datos de cada estación dentro de la provincia de Entre Ríos fueron estimados a través de dos métodos de interpolación y a través del producto “TRMM_3B43” que provee datos acumulados mensuales con una resolución espacial de 0,25° x 0,25° de latitud y longitud. Los métodos de interpolación resultaron de las siguientes ecuaciones:

$$\text{Pond1} = \sum (ppi * d1) \quad (1)$$

$$\text{Pond2} = \sum (ppi * d2) \quad (2)$$

siendo Pond1 y Pond2 los datos de precipitaciones estimados a través de cada método para cada estación, ppi es el valor de las precipitaciones de cada una de las estaciones restantes, d1 es el cociente entre la inversa de la distancia entre cada estación y la estación a estimar y la suma de todas las inversas de las distancias, y d2 es el cociente entre la inversa de la distancia entre cada estación y la estación a estimar

elevada al cuadrado y la suma de todas las inversas de las distancias elevadas al cuadrado.

Se realizaron correlaciones entre los distintos métodos de estimación y los datos observados para cada EMC ($n = 12 \text{ meses/año} * 13 \text{ años} = 156 \text{ meses}$) y una correlación general con todos los datos agrupados ($n = 156 \text{ meses/EMC} * 5 \text{ EMC} = 780 \text{ meses}$). Se calcularon los errores absoluto, relativo, cuadrático medio y la raíz cuadrada del error cuadrático medio. A su vez, se calcularon los coeficientes de disparidad de Theil (Smith y Rose, 1995) para cada método. Estos coeficientes discriminan entre distintas fuentes asociadas al error. Luego, a partir de este último método, se seleccionó aquel método con menor error aleatorio y se lo corrigió con el fin de mejorar las estimaciones. Esta corrección se llevó a cabo de dos formas, primero teniendo en cuenta la ecuación de regresión de cada estación y segundo, teniendo en cuenta la ecuación de regresión con todos los datos agrupados. Por último, se compararon ambas formas de corrección para determinar si la ecuación general con datos agrupados puede ser utilizada de manera generalizada en la estimación de precipitaciones mensuales en la provincia de Entre Ríos.

3.2.2 Análisis para distintos períodos de acumulación

3.2.2.1 Datos de precipitación diaria

Se utilizaron datos de precipitación diaria de tres EMC de la provincia de Entre Ríos: Gualaguaychú, Concepción del Uruguay y Concordia (figura 3.1). El período analizado fue 2000-2012.

3.2.2.2 Metodología

Los datos diarios de las estaciones fueron acumulados en períodos de tiempo creciente cada 2 días desde 1 hasta 29 días. Estos mismos períodos fueron considerados para acumular los datos de precipitación derivados del producto “TRMM_3B42_daily” que provee datos diarios con una resolución espacial de $0.25^\circ \times 0.25^\circ$ de latitud y longitud.

Para la evaluación del producto “TRMM_3B42_daily” con respecto de las EMC se calculó el error relativo como el cociente entre el error absoluto y el valor observado de precipitación en las estaciones y se realizaron correlaciones para obtener el coeficiente de determinación (R^2). Además, se utilizó una metodología propuesta por Schaefer (1990) para evaluar la capacidad de detección de eventos de precipitación según la cantidad de

días acumulados. Para esto se calcularon la Probabilidad de Detección, la Tasa de Falsas Alarmas y el Índice Crítico de Aciertos (POD, FAR y CSI, respectivamente y por sus siglas en inglés) como:

$$POD=A/(A+B) \quad (3)$$

$$FAR=C/(A+C) \quad (4)$$

$$CSI=A/(A+B+C) \quad (5)$$

donde A es el número de aciertos (número de eventos en los que se registra lluvia y TRMM lo detecta), B es el número de veces que llueve pero TRMM no lo detecta, y C es el número de veces que TRMM detecta lluvia pero las EMC no.

3.3 Resultados

3.3.1 Análisis mensual

El método de estimación de las precipitaciones mensuales basado en TRMM presentó el mejor ajuste en todas las EMC. El coeficiente de determinación (R^2) de TRMM fue superior a 0,90 en todas las estaciones excepto en Gobernador Echagüe donde todos los métodos presentaron R^2 menores a 0,70 (figura 3.2). En cambio, los coeficientes de determinación de Pond 1 y Pond2 variaron entre 0,57 y 0,88, y entre 0,63 y 0,88, respectivamente.

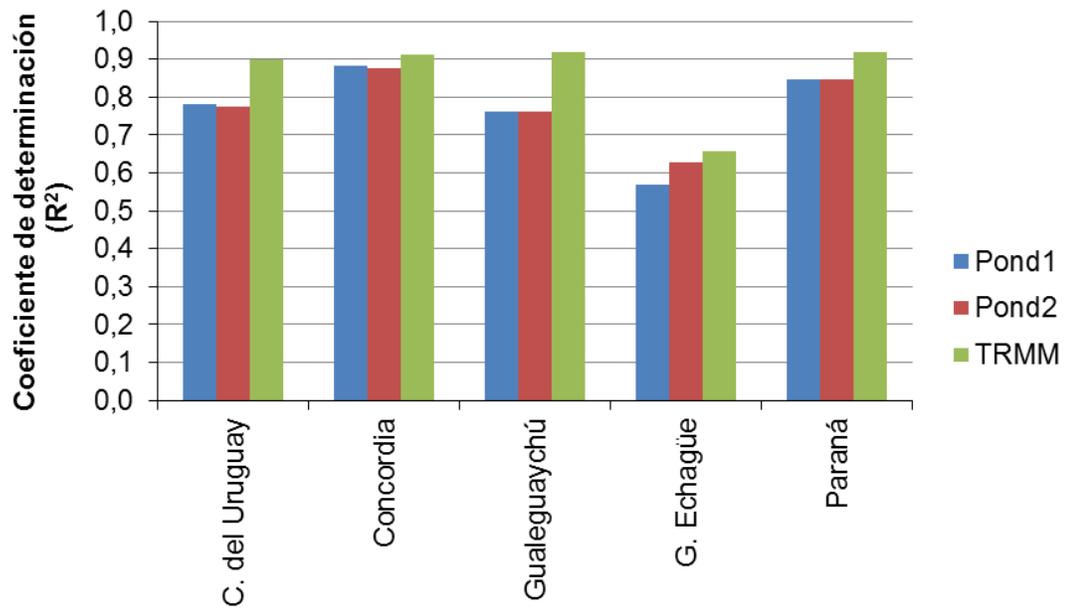


Figura 3.2. Coeficiente de determinación (R^2) para la correlación entre las precipitaciones observadas en cada EMC y las precipitaciones estimadas por cada método.

Al considerar el ajuste con todos los datos agrupados (figura 3.3) también se observó que el método TRMM presentó un mejor ajuste al estimar precipitaciones mensuales.

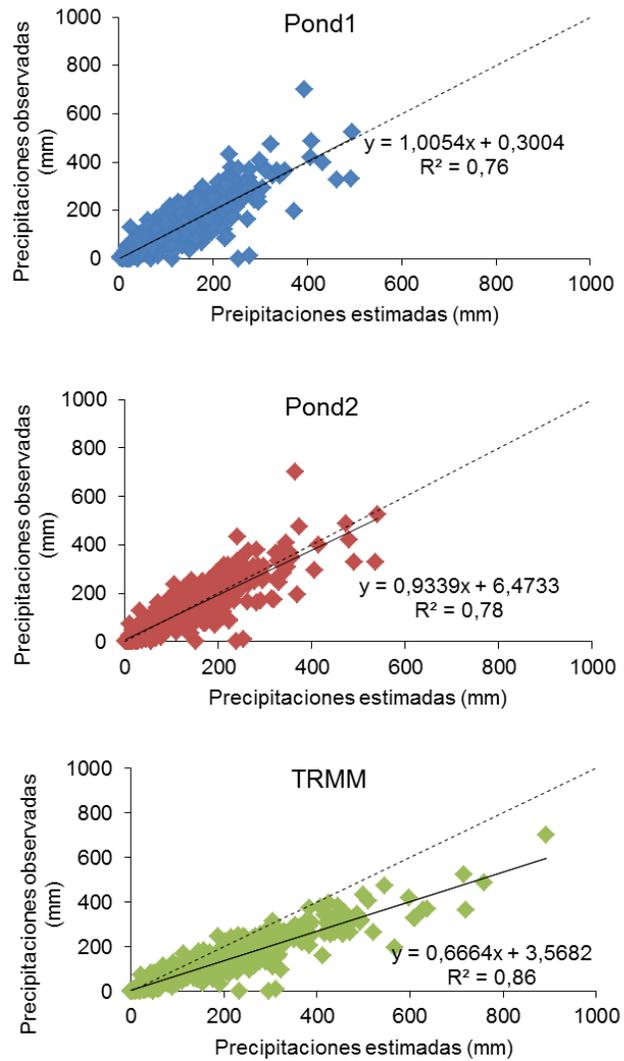


Figura 3.3. Correlación entre precipitaciones estimadas y precipitaciones observadas para los tres métodos (Pond1, Pond2 y TRMM) con todos los datos agrupados.

Sin embargo, se puede apreciar una desviación más marcada de la línea 1:1 para TRMM que para los otros dos métodos (mayor precisión y menor exactitud). Por ello, el cálculo de errores muestra valores más altos para TRMM (tabla 3.2).

Tabla 3.2. Errores en las estimaciones para los tres métodos y por EMC.

Localidad	Error	Pond1	Pond2	TRMM
C. del Uruguay				
	Error absoluto	26,2	26,2	53,7
	Error relativo	37,0	35,0	60,8
	ECM	37,5	38,6	74,8
	RMSE	6,1	6,2	8,6
Concordia				
	Error absoluto	25,6	23,1	44,7
	Error relativo	28,6	24,7	40,2
	ECM	34,6	34,2	66,1
	RMSE	5,9	5,8	8,1
Gualedguaychú				
	Error absoluto	30,0	28,8	50,1
	Error relativo	54,7	46,7	69,8
	ECM	46,3	46,4	66,1
	RMSE	6,8	6,8	8,1
G. Echagüe				
	Error absoluto	35,6	31,9	57,2
	Error relativo	75,9	66,9	100,9
	ECM	54,6	51,4	85,7
	RMSE	7,4	7,2	9,3
Paraná				
	Error absoluto	25,4	24,3	41,4
	Error relativo	73,4	41,5	64,8
	ECM	36,7	36,4	57,5
	RMSE	6,1	6,0	7,6
Promedio				
	Error absoluto	28,6	26,9	49,4
	Error relativo	53,9	43,0	67,3
	ECM	41,9	41,4	70,0
	RMSE	6,5	6,4	8,4

Referencias: Error absoluto expresado en mm; Error relativo expresado en %; ECM: error cuadrático medio, expresado en mm²; RMSE: raíz cuadrada del error cuadrático medio (por sus siglas en inglés), expresado en mm.

Si bien el error de estimación fue mayor para TRMM que para Pond1 y Pond2, una mayor parte de ese error fue no aleatorio. Los coeficientes de disparidad de Theil reflejan errores asociados a las diferencias medias entre los valores observados y predichos por el modelo (U_{bias}), y asociados a la diferencia entre la pendiente del modelo y la línea de pendiente 1:1 ($U_{\beta=1}$) mayores en TRMM (tabla 3.3). Sin embargo, también muestran un

error de tipo aleatorio (U_e) aproximadamente 5 veces mayor en los métodos Pond1 y Pond2.

Tabla 3.3. Coeficientes de disparidad de Theil para cada método de estimación de las precipitaciones mensuales.

Coeficientes de disparidad de Theil	Pond ₁	Pond ₂	TRMM
U_{bias}	0,0004	0,0002	0,4541
$U_{\beta=1}$	0,0001	0,0171	0,3340
U_e	0,9995	0,9827	0,2119

Por lo tanto, el método de estimación de precipitaciones mensuales a través de TRMM se seleccionó para ser corregido. Esto se realizó tanto con la ecuación de ajuste de cada estación (TRMMcor), como con la ecuación de ajuste con todos los datos agrupados (TRMMcor2). Ambos métodos de corrección redujeron los errores a menos de la mitad (figura 3.4) y no presentaron diferencias significativas entre sí en la estimación de precipitaciones ($p < 0,01$). La ecuación obtenida con todos los datos agrupados para la estimación de las precipitaciones fue:

$$TRMMcor2 = 0,666 * TRMM + 3,568 \quad (6)$$

siendo TRMMcor2 la precipitación mensual estimada y TRMM el dato de precipitación mensual del producto "TRMM_3B43".

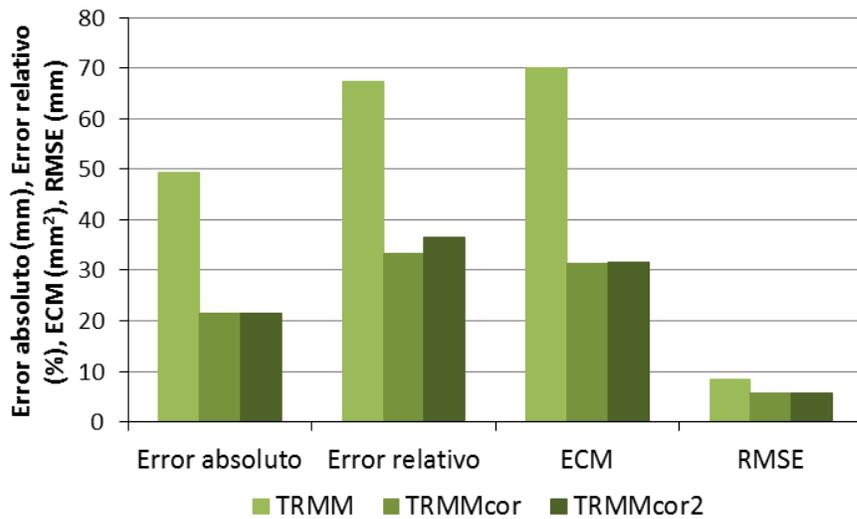


Figura 3.4. Valores de error para TRMM sin corregir (TRMM) y corregido a través de la ecuación de cada estación (TRMMcor) y a través de la ecuación con todos los datos agrupados (TRMMcor2).

3.3.2 Análisis para distintos períodos de acumulación

La correlación entre datos de las EMC y de TRMM mostró que el R^2 aumenta en las tres localidades (C. del Uruguay, Concordia y Gualeguaychú) a medida que aumenta la cantidad de días acumulados, hasta un máximo de $R^2 = 0,82$ en las tres EMC. Por su parte, el error relativo presentó un mínimo en todas las localidades con un período de acumulación de 29 días (figura 3.5).

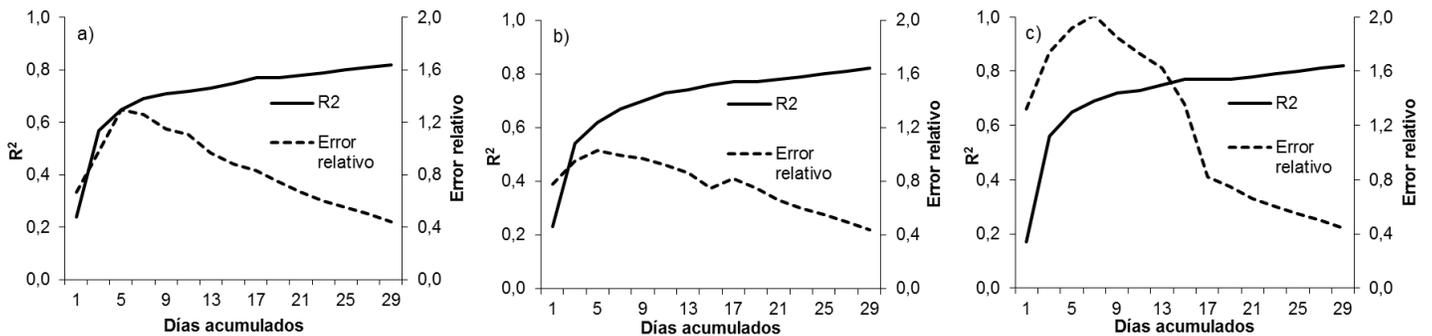


Figura 3.5. Coeficiente de determinación (R^2) en la correlación entre datos de las EMC y TRMM y error relativo para distinta cantidad de días acumulados para a) C. del Uruguay, b) Concordia y c) Gualeguaychú.

Al analizar los índices propuestos por Schaefer (1990), valores de CSI = 0,95 (próximos al máximo) se obtienen con 15 días de acumulación de la precipitación en las tres EMC. El máximo valor de CSI (0,99 en las tres EMC) se obtiene a partir de 23 días de acumulación de la precipitación (figura 3.6).

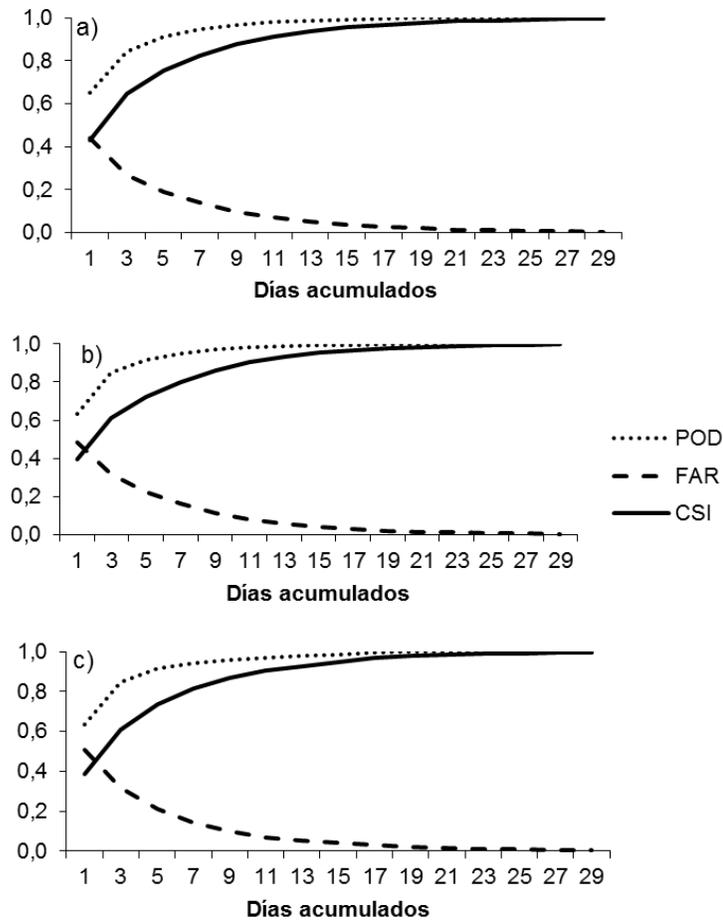


Figura 3.6. Valores (adimensionales) de POD, FAR y CSI para a) C. de Uruguay, b) Concordia, y c) Gualeguaychú.

3.4 Discusión

A escala mensual, la capacidad de estimar las precipitaciones resultó mejor con TRMM que con cualquiera de los dos métodos de interpolación utilizados. Esto se verificó tanto al realizar el análisis a nivel de las EMC (figura 3.2) analizadas individualmente como con todos los datos agrupados (figura 3.3). A su vez, el menor error de tipo aleatorio de TRMM permitió realizar nuevas estimaciones corregidas mediante las ecuaciones

generadas. El coeficiente de correlación promedio hallado en ambos métodos de TRMM corregidos (0,93 para ambos métodos) es superior al hallado por Lavado Casimiro *et al.* (2009) en la cuenca amazónica peruana, donde probablemente la topografía pudo influir en las estimaciones, además de haber considerado menos años que en este estudio. El valor de coeficiente de correlación promedio hallado es también superior al coeficiente de correlación (0,84) citado por Karaseva *et al.* (2012) con datos de TRMM sin corregir, lo que demuestra la validez de haber llevado a cabo la corrección, y es igual al hallado por Duan y Bastiaanssen (2013) con datos de TRMM a nivel mensual recalculados con una metodología que mejora la resolución espacial. La estimación de precipitaciones mensuales lograda mediante la ecuación con todos los datos agrupados no resultó diferente ($p < 0,01$) de la estimación particular de cada EMC, lo que permite utilizar la ecuación de forma generalizada para la provincia de Entre Ríos.

A escala diaria y de distintos períodos de acumulación se observó que el ajuste (R^2) aumenta con los días acumulados, similar a lo observado por Brizuela *et al.* (2015) en Entre Ríos. Por su parte, el error relativo aumenta con pocos días acumulados debido a la mayor cantidad de períodos sin precipitación (lo que eleva el error) y luego desciende ya que es esperable que los períodos de mayor tiempo aproximen mejor la cantidad total de la precipitación. Con respecto a los índices propuestos por Schaefer (1990), una metodología sería ideal si cumple $POD = 1$, $FAR = 0$, y $CSI = 1$. En este estudio se determinó que esas condiciones se cumplen a medida que se aproxima a un período acumulado de 29 días. Sin embargo, valores aceptables de CSI ($CSI > 0,80$; Cohkngamwong y Chiu, 2008) se obtienen con 7 días de acumulación de la precipitación y se estableció al período de acumulación de 15 días ($CSI = 0,95$ para las tres EMC individuales) como el mínimo que no disminuye la precisión con respecto a períodos más largos. Esta frecuencia es útil para usos agronómicos o hidrológicos de la precipitación, con la ventaja que presenta TRMM de cubrir mejor la superficie que las estaciones meteorológicas convencionales.

Debido a que los resultados a partir de 15 días de acumulación fueron satisfactorios, los datos de TRMM acumulados cada 16 días serán utilizados en conjunto con índices espectrales de vegetación y de temperatura de superficie para estimar rendimientos agrícolas departamentales. Este período de acumulación coincide con la frecuencia de los productos MODIS que se utilizarán en el próximo capítulo.

Capítulo 4: **Estimación de
rendimientos a través de
sensores remotos**

4.1 Introducción

La detección de la vegetación verde es una de las principales aplicaciones de los sensores remotos para el manejo de recursos ambientales y la toma de decisiones. En la agricultura, el monitoreo de las condiciones de los cultivos durante la estación de crecimiento y las predicciones de rendimientos son importantes para la estimación de la producción de granos en la campaña (Doraiswamy *et al.*, 2003). Estimaciones precisas y oportunas de la disminución en la producción agropecuaria causada por desastres naturales, como sequías o ataques de plagas, pueden resultar críticas para países cuya economía es dependiente de dicha producción. Estas estimaciones podrían prevenir situaciones desastrosas y colaborar en el planeamiento estratégico para cubrir las demandas (Doraiswamy *et al.*, 2004). En este contexto, es marcado el interés por los satélites de observación terrestre y su aplicación en los más variados ámbitos de investigación en el que los recursos naturales juegan un rol central (Chuvieco Salinero, 2002).

Existen diversos tipos de sistemas de sensores remotos utilizados en agricultura, pero los más comunes son los sistemas pasivos montados en satélites que captan la energía electromagnética reflejada por las plantas, siendo el Sol la fuente de energía principal para este tipo de sistemas. La reflectancia de una determinada superficie es la relación entre el flujo radiante incidente y el flujo radiante reflejado, y es determinada por las características ópticas y distribución espacial de todos los constituyentes de dicha superficie (vegetación, suelo, agua) así como sus proporciones. De esta forma y según Gilabert *et al.* (1997), un índice de vegetación puede definirse como un parámetro calculado a partir de los valores de reflectancia en distintas longitudes de onda y que pretende extraer de los mismos la información relacionada con la vegetación, minimizando la influencia de perturbaciones debidas al suelo y a las condiciones atmosféricas. La mayoría de los índices de vegetación definidos hasta el momento tienen en común el uso de los valores de reflectancia en las zonas espectrales del rojo e infrarrojo cercano.

En la década del '70 empezaron a elaborarse los primeros índices de vegetación, siendo el RVI (*Ratio Vegetation Index*; Pearson y Miller, 1972) el primero y más simple de todos. Éste consiste en el cociente entre las bandas correspondiente a las zonas espectrales del rojo (zona correspondiente a uno de los picos de absorción de radiación por parte de la clorofila) e infrarrojo cercano (zona del espectro donde la radiación es

reflejada fuertemente por los efectos de la pared celular y de la interface agua-aire de los espacios intercelulares) (Rencz, 1999). Luego, Rouse *et al.* (1974) propusieron el NDVI (*Normalized Difference Vegetation Index*), que resulta de la diferencia normalizada entre ambas bandas y toma valores entre -1 y +1 y es, quizás, el índice de vegetación más utilizado por su sencillez para calcularlo y por su menor sensibilidad a los efectos del suelo y las condiciones atmosféricas. Cuando la vegetación comienza a sufrir un estrés, esta condición puede ser revelada por cálculos de NDVI o por otros índices, debido a que la pigmentación verde típica de una vegetación sana y vigorosa comienza a tomar tintes marrones debido a la degradación de la clorofila, lo que aumenta la reflectancia en las regiones del espectro correspondientes al rojo. A su vez, también se producen alteraciones en el mesófilo de la hoja que disminuyen la reflectancia en la región del infrarrojo cercano.

Aunque claramente relacionados con la absorción por parte de la clorofila del follaje, los índices de vegetación han sido relacionados con otras varias propiedades de las plantas, incluyendo el índice de área foliar (Qi *et al.*, 1995), el porcentaje de cobertura y biomasa (Gamon *et al.*, 1993, 1995), productividad (Weigand y Richardson, 1987) y propiedades biofísicas como la capacidad fotosintética (Sellers, 1985).

Basado en la utilización de sensores remotos, el experimento LACIE (*Large Area Crop Inventory Experiment*) llevado a cabo por distintas agencias estadounidenses (USDA, NASA y NOAA) en 1974, fue el primero en intentar predecir rendimientos agrícolas (McDonald, 1979). Ya en la década del '90, se logró correlacionar datos de NDVI con el rendimiento final de los cultivos, tanto al considerar la estación de crecimiento completa (Groten, 1993) como solamente los estadíos de llenado de grano (Doraiswamy y Cook, 1995). Cabe aclarar que en aquella época se utilizaban datos provenientes del sensor AVHRR (*Advanced Very High Resolution Radiometer*) a bordo de satélites de la NOAA y que tenían una resolución espacial baja (1,1 km). Uno de los índices más utilizados en la generación de mapas fue el VHI (*Vegetation Health Index*) que consideraba la condición de la vegetación en relación a la disponibilidad de agua y a la temperatura (Kogan, 1995b, 1997, 2001).

El avance de la informática ha posibilitado quitar las restricciones que se presentaban hace algunos años para el análisis de datos (Rencz, 1999). Esto ha llevado a que se construya una gran variedad de índices como el NDWI (*Normalized Difference Water Index*), el NDDI (*Normalized Difference Drought Index*) y el NMDI (*Normalized*

Multiband Drought Index). El NDWI (Gao, 1996) utiliza bandas del infrarrojo cercano (750 a 1000 nm) y del infrarrojo de onda corta (1000 a 2500 nm, porción del espectro electromagnético que, a diferencia del infrarrojo cercano, es sensible a la presencia de agua), y estima el contenido de agua líquida en la canopia de la vegetación. A su vez, el contenido de agua de la vegetación puede ser útil en la estimación de rendimientos (Penuelas *et al.*, 1993), ya que indica en qué condiciones están creciendo los cultivos y los efectos de dichas condiciones sobre la producción. Gu *et al.* (2007) encontraron que el NDWI respondía más rápido a la sequía que el NDVI y, a su vez, propusieron el NDDI que demostró ser aún más rápido y se calcula utilizando el NDVI y NDWI. El NMDI (Wang y Qu, 2007) utiliza el infrarrojo cercano (860 nm) y dos porciones del infrarrojo de onda corta (1640 y 2130 nm), y en su trabajo original detectó adecuadamente las sequías tanto en áreas con suelo desnudo como áreas densamente vegetadas.

El tiempo de anticipación con que la predicción de rendimiento puede ser realizada ha variado en los distintos trabajos previos. En India, y utilizando AVHRR, se han reportado estimaciones de rendimiento precisas con 75 días de anticipación a la cosecha en trigo (Gupta *et al.*, 1993) y 45 días de anticipación a la cosecha en sorgo Potdar (1993). Mkhabela *et al.* (2005) investigaron la predicción temprana del rendimiento de maíz en cuatro regiones agroecológicas de Suazilandia (África) usando NDVI proveniente de AVHRR. Estos autores establecieron regresiones lineales entre el NDVI acumulado promedio y el rendimiento de maíz, y determinaron que podían predecir efectivamente el rendimiento hasta dos meses antes de la cosecha. A partir del uso de datos provenientes de MODIS (*Moderate Resolution Imaging Spectroradiometer*), se han reportado dos meses de anticipación en la predicción de rendimientos de trigo en Canadá (Mkhabela *et al.*, 2011), un mes y medio de anticipación en Ucrania (Becker-Reshef *et al.*, 2010) y 40 días de anticipación en China (Ren *et al.*, 2008).

El objetivo de este capítulo es determinar la capacidad de un conjunto modelos basados en índices espectrales y en datos de TRMM para estimar el rendimiento de maíz y de soja a nivel departamental en Entre Ríos. Para ello, se utilizarán los índices espectrales propuestos por Rhee *et al.* (2010). En el citado trabajo se combinaron distintas fuentes de datos (temperatura de superficie e índices de vegetación de MODIS y precipitación de TRMM) y hallaron altas correlaciones entre los distintos índices y el rendimiento final de maíz y soja cuando se utilizaron datos de un mes y medio a dos meses previos a la cosecha de ambos cultivos. Por lo tanto, se evaluarán las

correlaciones entre dichos índices y otros índices nuevos propuestos en este trabajo, calculados en distintos períodos del ciclo de maíz y de soja, y el rendimiento final de dichos cultivos. La hipótesis es que existen índices espectrales y períodos dentro del ciclo de cada cultivo que optimizan la estimación de rendimientos a través de sensores remotos. Debido a las diferencias ambientales a nivel departamental en la provincia de Entre Ríos y en los momentos en los que se produce el período crítico en maíz y soja, se espera que varíen los índices y periodos óptimos para estimar rendimiento entre departamentos y cultivos.

4.2 Metodología

4.2.1 Datos de sensores remotos

Se utilizaron valores de reflectancia (ρ) de distintas bandas (tabla 4.1) del producto MOD09 y la temperatura de superficie LST (*Land Surface Temperature*) del producto MOD11A2 (resolución espacial = 1 km) provenientes de MODIS.

Tabla 4.1. Especificaciones de las bandas del producto MOD09 utilizadas para el cálculo de índices de vegetación.

Banda	Longitud de onda (nm)	Resolución Espacial (m)
1	620-670	250
2	841-876	250
5	1230-1250	500
6	1628-1652	500
7	2105-2155	500

Los productos MODIS fueron adquiridos de <https://wist.echo.nasa.gov/api/> para el período comprendido entre el 16 de octubre (día juliano 289) y el 22 de marzo (día juliano 81) entre los años 2000/2001 y 2014/2015 (15 años). Con los datos de reflectancia primero se calcularon los índices de vegetación básicos (NDVI, NMDI, NDWI y NDDI) y luego se calcularon los índices escalados (metodología explicada en el siguiente párrafo), el VHI (cada 8 días) y combinados (cada 16 días) (tabla 4.2). Para los índices combinados se utilizaron datos de precipitación proveniente del producto “TRMM_3B42_daily” que fueron adquiridos desde la página de la NASA (<https://pmm.nasa.gov/data-access/downloads/trmm>) y sumados en períodos de 16 días de modo que el acumulado

de cada período coincida con las fechas de los productos MODIS. Este período de acumulación tiene un adecuado ajuste en la estimación de precipitaciones en la región de estudio (Vaiman y Durante, 2016). Luego, fueron escalados para ser incluidos en los índices combinados.

El método de escalado se llevó a cabo debido a que las variables predictoras fueron calculadas como promedios departamentales y cada departamento presenta condiciones ambientales (por ejemplo, de suelo) que pueden variar. El escalado de los índices se lleva a cabo considerando los valores mínimos y máximos de cada píxel y cada período en los 15 años, y produce valores de cada índice que van de 0 a 1 en cada píxel. De esta manera se logra discriminar la componente meteorológica de la componente ecosistémica, similar a lo realizado por Kogan (1995a,b) con el *Vegetation Condition Index* usando NDVI. El escalado se realizó de modo que el valor 0 indique la condición más seca y el valor 1 la condición más húmeda. Tanto los valores de TRMM escalados (que se incorporaron a los índices combinados) como los de los índices de vegetación fueron transformados a una resolución espacial de 1km, con la cual se realizó todo el trabajo.

Los índices combinados CI1, CI2 y CI3 son los propuestos por Rhee *et al.* (2010) mientras que CI4 y CI5 (tabla 4.2) son combinaciones propuestas en este trabajo para asignarle una mayor importancia al estado de la vegetación. Cabe aclarar que tanto NDWI como su derivado NDDI tienen tres fórmulas de cálculo que dependen de las bandas que se utilicen. De aquí en adelante, el NDWI_5 será aquel en que se utilice la banda 5 del producto MOD09 de MODIS en el cálculo, NDWI_6 el que utilice la banda 6 y así sucesivamente. Por lo tanto, se calcularon tres NDWI y tres NDDI, y se obtuvo un total de 8 índices escalados (si bien Sc LST y Sc TRMM son escalados, no se los consideró individualmente para estimar rendimientos).

Tabla 4.2. Índices básicos, escalados (prefijo “Sc”) y combinados (prefijo “CI”). p hace referencia a la reflectancia de la banda en cuestión. Los prefijos “min” y “max” indican que se utilizó el valor mínimo y máximo, respectivamente, de cada píxel en el período de 15 años completo y en cada fecha. “VI” hace referencia a cualquiera de los índices de vegetación básicos (NDVI, NMDI, NDWI o NDDI).

Índice	Fórmula
NDVI	$(p_{banda2} - p_{banda1}) / (p_{banda2} + p_{banda1})$
NMDI	$(p_{banda2} - (p_{banda6} - p_{banda7})) / (p_{banda2} + (p_{banda6} - p_{banda7}))$
NDWI	$(p_{banda2} - p_{banda5} \text{ (o 6 o 7)}) / (p_{banda2} + p_{banda5} \text{ (o 6 o 7)})$
NDDI	$(NDVI - NDWI) / (NDVI + NDWI)$
Sc LST	$(LST_{max} - LST) / (LST_{max} - LST_{min})$
Sc NDVI (=VCI)	$(NDVI - NDVI_{min}) / (NDVI_{max} - NDVI_{min})$
Sc NMDI	$(NMDI - NMDI_{min}) / (NMDI_{max} - NMDI_{min})$
Sc NDWI	$(NDWI - NDWI_{min}) / (NDWI_{max} - NDWI_{min})$
Sc NDDI	$(NDDI_{max} - NDDI) / (NDDI_{max} - NDDI_{min})$
Sc TRMM	$(TRMM - TRMM_{min}) / (TRMM_{max} - TRMM_{min})$
VHI	$(1/2) \times ScLST + (1/2) \times ScNDVI$
C11	$(1/3) \times ScLST + (1/3) \times ScTRMM + (1/3) \times ScVI$
C12	$(1/4) \times ScLST + (2/4) \times ScTRMM + (1/4) \times ScVI$
C13	$(2/5) \times ScLST + (2/5) \times ScTRMM + (1/5) \times ScVI$
C14	$(1/5) \times ScLST + (1/5) \times ScTRMM + (3/5) \times ScVI$
C15	$(1/4) \times ScLST + (1/4) \times ScTRMM + (2/4) \times ScVI$

Los índices combinados se calcularon cada 16 días y dichos valores fueron promediados en 8 períodos de tiempo diferentes dependiendo del cultivo (maíz o soja) con el que se fueran a correlacionar con el rendimiento (figura 4.1). Si bien se consideraron fechas diferentes, para cada cultivo se tuvo en cuenta el mismo criterio de selección de fechas en cuanto a su relación con los distintos estadios fenológicos del ciclo del cultivo.

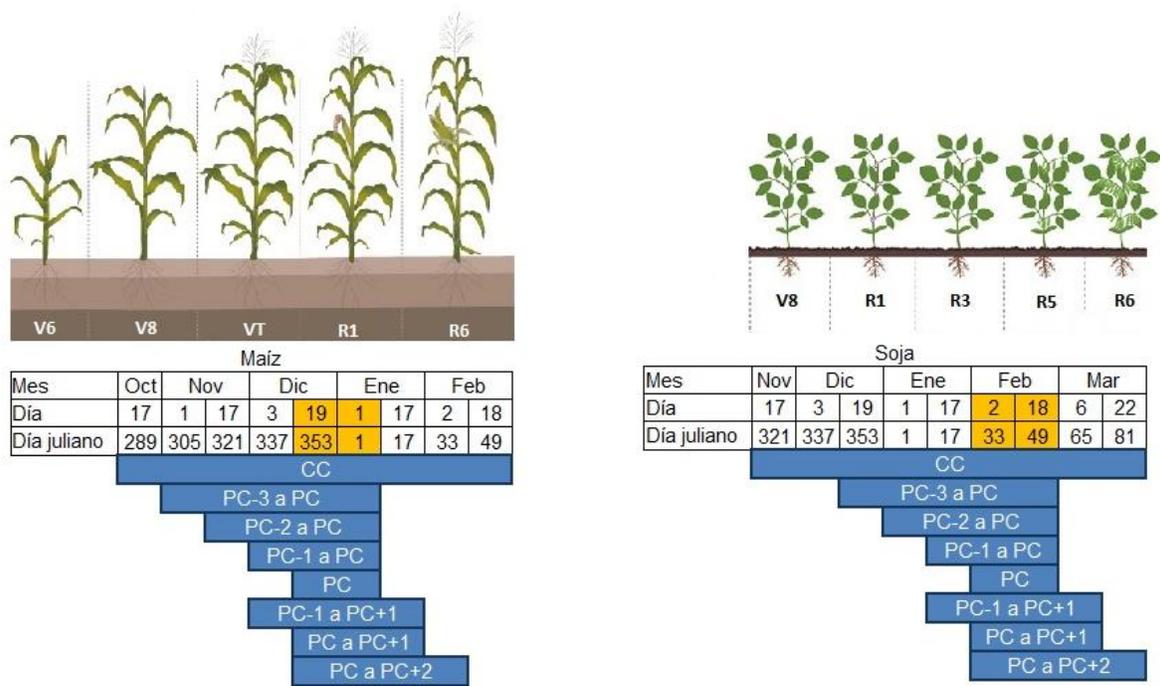


Figura 4.1. Períodos (bloques azules) en los que se promedió cada índice combinado para correlacionar con el rendimiento final del cultivo y estadios fenológicos aproximados. Referencias: CC = ciclo completo, PC = período crítico (fecha marcada en color anaranjado), PC-n o PC+n = n indica el número de fechas previas consideradas (en períodos de 16 días) antes (-) o después (+) del PC.

Los índices escalados y el VHI fueron calculados cada 8 días y analizados también en 8 períodos, similares a los períodos analizados para los índices combinados (figura 4.2).

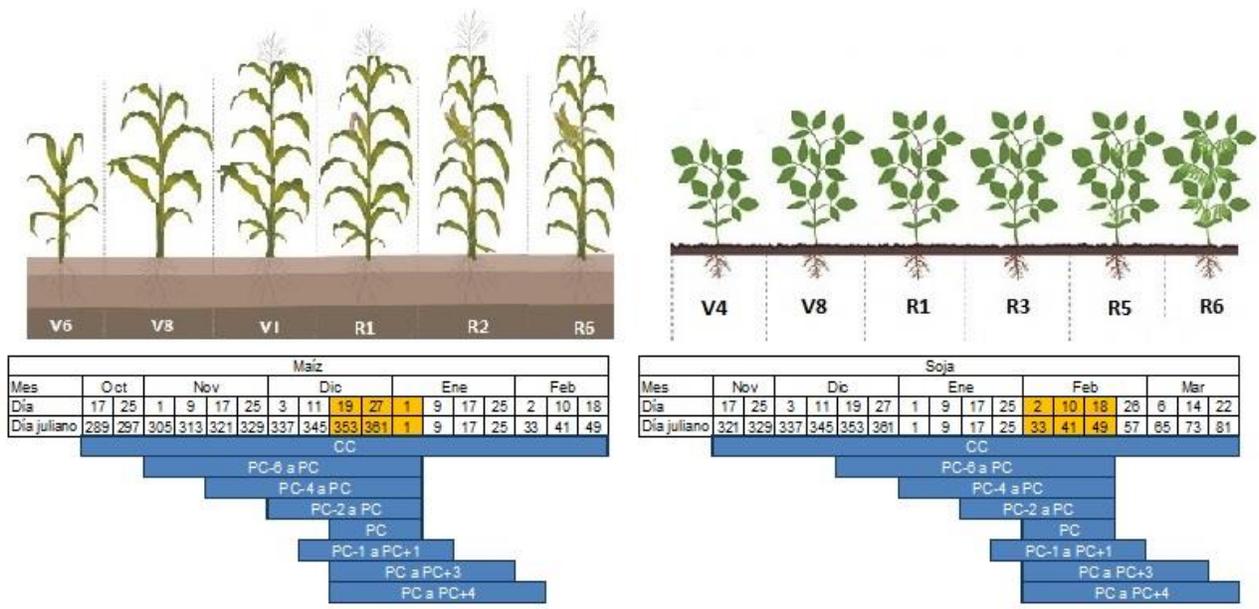


Figura 4.2. Períodos (bloques azules) en los que se promedió cada índice escalado y VHI para correlacionar con el rendimiento final del cultivo y estadios fenológicos aproximados. Referencias: CC = ciclo completo, PC = período crítico (fecha marcada en color anaranjado), PC-n o PC+n = n indica el número de fechas previas consideradas (en períodos de 8 días) antes (-) o después (+) del PC.

4.2.2 Construcción de las variables predictoras o independientes

Para la predicción de rendimientos se realizaron correlaciones lineales entre los datos de rendimiento equivalente (variable Y o dependiente) y de los 49 índices (8 índices escalados, VHI y 40 índices combinados -que surgen de 5 formas de combinar cada uno de los 8 índices escalados-) y sus 8 períodos en cada cultivo en los 15 años de datos disponibles (n = 15). El nombre de la variable predictor (variable X o independiente) surge de la combinación del índice y el período utilizados. Así, para citar dos ejemplos, la variable predictor del rendimiento en maíz Sc_NDVI-289-49 indica que el índice utilizado es el NDVI escalado y la fecha considerada es el ciclo completo (17 de octubre -día juliano 289- a 18 de febrero -día juliano 49-) y la variable predictor CI4_NDWI_5-353-17 indica que el índice utilizado es el que surge de $(1/5) \times ScLST + (1/5) \times ScTRMM + (3/5) \times Sc_NDWI_5$ y la fecha considerada comprende desde el período crítico al período crítico más un período de 16 días más (19 de diciembre -día juliano 353- a 17 de enero -día juliano 17-). La unidad de muestreo fue el área de cada departamento.

4.2.3 Generación de modelos lineales de predicción de rendimiento

Previo a la generación de los modelos, se testeó la normalidad del conjunto de datos completo. Luego, éste fue dividido en subconjuntos de calibración y validación. Para evaluar la capacidad de predicción de los modelos, se extrajo de manera aleatoria el 70% de los datos para calibración, y el 30% se usó para la validación en 100 iteraciones. En cada iteración, un modelo de regresión lineal generado con el subconjunto de datos de calibración se usó para predecir el rendimiento de maíz y soja del subconjunto de validación y se estimaron algunos descriptores de la capacidad de predicción de los modelos. Como descriptores de la capacidad de predicción se usaron: la raíz cuadrada del cuadrado medio del error (RMSE, por sus siglas en inglés), el error relativo, el coeficiente de determinación (R^2), que proveen una medida de la bondad de ajuste, y los valores de la pendiente y la ordenada al origen de la ecuación de ajuste lineal entre los valores observados y predichos. El procesamiento se realizó mediante el software libre RStudio (R Core Team, 2016).

4.2.4 Datos de rendimientos departamentales

Los datos de rendimiento de maíz y soja utilizados para las correlaciones surgen de los rendimientos equivalentes cuya metodología de cálculo fue explicada en el Capítulo 2 (punto 2.2.4). En este capítulo sólo se utilizaron los rendimientos equivalentes del período 2000/2001 a 2014/15.

4.3 Resultados

4.3.1 Modelos lineales de predicción de rendimiento

Los modelos con menor error de predicción para ambos cultivos presentaron valores de RMSE aceptables en todos los departamentos. Estos modelos presentaron RMSE menores a 800 kg.ha⁻¹ en maíz y menores a 300 kg.ha⁻¹ en soja, con errores relativos próximos al 10% (Tabla 4.3). Además, todos los modelos, a excepción del correspondiente al menor RMSE en Feliciano, resultaron significativos ($p < 0,05$), con coeficientes de determinación de predicción (R^2 de predicción) aceptables y levemente mayores en maíz que en soja.

El índice que más se repitió en cada cultivo como mejor estimador al considerar el RMSE (Sc_NDDI_5 en maíz y Sc_NDWI_7 en soja; tabla 4.3) presentó diferencias significativas entre los distintos períodos (figura 4.3). En maíz, se obtuvieron medianas del RMSE menores en el período crítico y en soja en períodos previos al período crítico, período crítico y ciclo completo. En maíz, la menor mediana del RMSE del Sc_NDDI_5 se halló en el período crítico (553 kg.ha⁻¹) con diferencias de aproximadamente 200 kg.ha⁻¹ con respecto a la mayor mediana del RMSE que se halló al considerar el ciclo completo (745 kg.ha⁻¹). En cambio, en soja, el Sc_NDWI_7 en el período crítico y el ciclo completo no presentaron diferencias significativas. En este cultivo la menor mediana del RMSE se obtuvo al considerar el ciclo completo (260 kg.ha⁻¹) y la mayor mediana del RMSE (330 kg.ha⁻¹) se obtuvo al considerar tanto el período que va desde el período crítico a tres fechas posteriores como el período crítico a cuatro fechas posteriores.

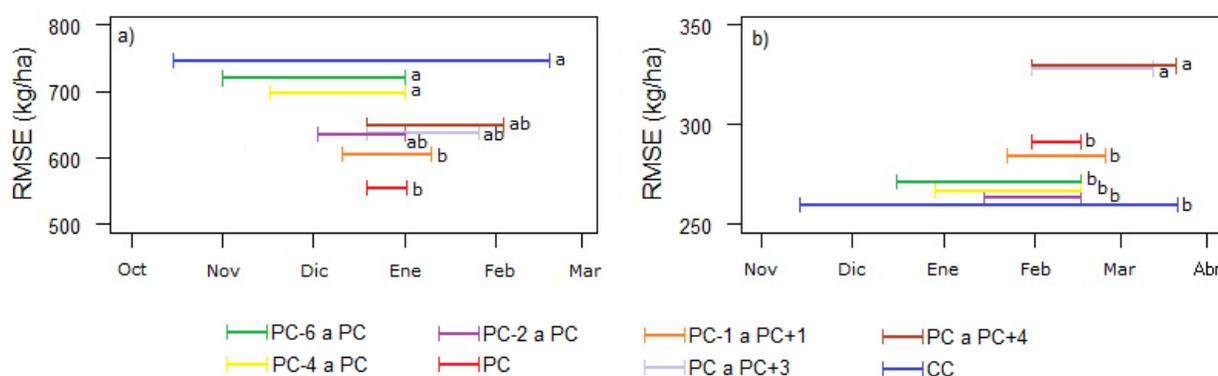


Figura 4.3. RMSE de los modelos cuyos índices fueron más frecuentes al considerar todos los departamentos: a) Sc_NDDI_5 en maíz y b) Sc_NDWI_7 en soja. Los distintos colores hacen referencia a los ocho períodos analizados en cada cultivo. Letras distintas indican diferencias estadísticamente significativas ($p < 0,05$).

Los modelos con el menor RMSE en cada cultivo incluyeron al índice NDWI escalado basado en la banda 7 (Sc_NDWI_7 en soja y Sc_NDDI_7 en maíz, que se calcula con el NDWI_7) y el período crítico del cultivo. En maíz, el mejor modelo incluyó el período comprendido entre el 19 de diciembre y el 1 de enero (días julianos 353-1, período crítico propiamente dicho), siendo mayoría los modelos que utilizaron éste período. El menor error de predicción se obtuvo en Villaguay (RMSE = 363 kg.ha⁻¹). En soja, el mejor modelo incluyó el período comprendido entre el 17 de enero y el 18 de febrero (días julianos 17-49, incluye al período crítico), aunque resultó más frecuente el

período correspondiente al ciclo completo (días julianos 321-81). El menor error de predicción se obtuvo en Nogoyá (RMSE = 132 kg.ha⁻¹).

Los modelos previamente mencionados presentaron los R² de predicción más elevados y errores relativos aceptables (menores a un 15% en promedio en maíz y a menores a un 10% en promedio en soja). En maíz, el Sc_NDWI_7-353-1 produjo un R² de predicción de 0,88 en Villaguay y 0,85 en San Salvador. En soja, el Sc_NDWI_7-17-49 produjo R² de predicción de 0,76 en La Paz y 0,74 en Nogoyá. El mayor R² en maíz y en soja se correspondió con el segundo y tercer menor error relativo, respectivamente. El error relativo producido por Sc_NDWI_7-353-1 en maíz en Villaguay fue el segundo menor con 8% (sólo superado por Sc_NDDI_7-353-1 en Nogoyá con 6%) mientras que, en soja, el error relativo producido por Sc_NDWI_7-17-49 en La Paz fue el tercer menor con un 7% de error (superado por Sc_NDWI_7-17-49 en Nogoyá con 5% y por Sc_NDDI_7-321-81 en Gualeguaychú con 6%). En ambos cultivos, el mayor R² de predicción se obtuvo en el período crítico (maíz, PC = días julianos 353-1 = 19 de diciembre a 1 de enero) o en un período próximo a éste (soja, PC-2 a PC = días julianos 17-49 = 17 de enero a 18 de febrero).

Tabla 4.3. Mínimo RMSE hallado para cada variable en cada departamento. Se muestra además el error relativo y el R² de predicción de dichas variables.

Departamento	Maíz				Soja			
	RMSE (kg.ha ⁻¹)	Error relativo (%)	Variable	R ² de predicción	RMSE (kg.ha ⁻¹)	Error relativo (%)	Variable	R ² de predicción
Colón	499	11	Sc_NDDI_5-353-1	0,81 **	217	9	Sc_NDDI_7-33-49	0,67 *
Concordia	517	11	Sc_NDDI_5-337-1	0,70 *	237	9	Sc_NDDI_5-17-49	0,69 *
Diamante	651	11	Sc_NDDI_5-345-9	0,63 **	211	8	Sc_NDWI_7-321-81	0,74 **
Federación	541	10	Sc_NDVI-353-1	0,57 *	259	7	VHI-321-81	0,63 *
Federal	547	11	Sc_NDDI_5-353-1	0,56 *	246	7	Sc_NDWI_7-1-49	0,68 *
Feliciano	777	16	CI4_NDWI_5-353-17	0,28	242	10	Sc_NDDI_5-1-49	0,57 *
Gualeguay	517	10	Sc_NDWI_5-353-1	0,73 **	212	8	Sc_NDDI_7-321-81	0,56 *
Gualeguaychú	539	12	CI4_NDDI_5-321-1	0,73 **	167	6	Sc_NDDI_7-321-81	0,72 **
La Paz	542	11	Sc_NDDI_7-345-9	0,64 *	233	7	Sc_NDWI_7-17-49	0,76 **
Nogoyá	364	6	Sc_NDDI_7-353-1	0,81 **	132	5	Sc_NDWI_7-17-49	0,74 **
Paraná	505	9	Sc_NDDI_6-353-1	0,76 **	243	10	Sc_NDDI_6-321-81	0,64 *
San Salvador	694	11	Sc_NDWI_7-353-1	0,85 **	228	10	Sc_NDDI_5-25-57	0,76 **
Tala	472	9	Sc_NDWI_5-353-1	0,74 **	191	8	Sc_NDWI_7-321-81	0,64 *
Uruguay	370	9	CI4_NDDI_7-305-1	0,84 **	236	11	Sc_NDWI_7-321-81	0,58 *
Victoria	636	11	Sc_NDDI_5-353-25	0,62 *	240	8	Sc_NDDI_7-353-49	0,56 *
Villaguay	363	8	Sc_NDWI_7-353-1	0,88 **	221	9	Sc_NDDI_7-321-81	0,71 **
General	789	13	Sc_NDDI_6-353-25	0,45 **	264	9	Sc_NDWI_7-17-49	0,58 **

Referencias: * significativo al 5%; ** significativo al 1%; General: todos los departamentos juntos.

El Sc_NDWI_7 produjo muy buenas correlaciones con el rendimiento de ambos cultivos. Al considerar los datos de éste índice en los departamentos en que se produjo el mínimo RMSE (Villaguay en maíz y Nogoyá en soja) y al considerar los períodos de mejor ajuste para cada cultivo (días julianos 353-1 en maíz y 17-49 en soja) se obtuvieron correlaciones lineales significativas ($p < 0,01$) con el rendimiento (figura 4.4).

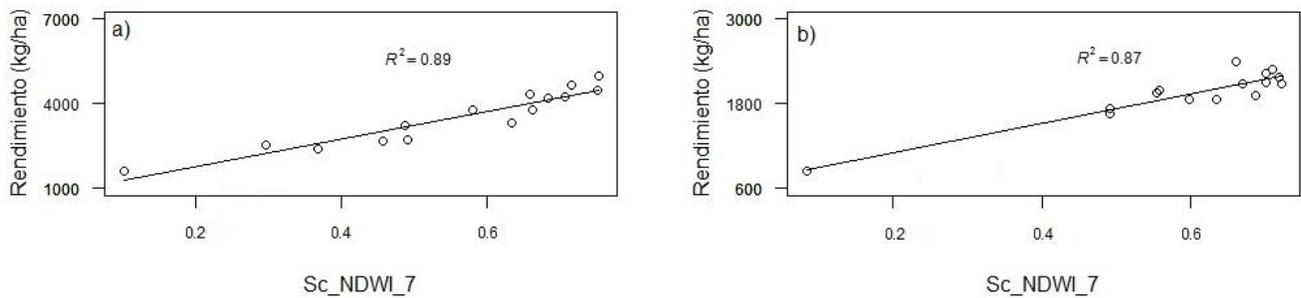


Figura 4.4. Regresiones lineales entre las variables a) Sc_NDWI_7-353-1 en maíz en el departamento Villaguay y b) Sc_NDWI_7-17-49 en soja en el departamento Nogoyá, y el rendimiento de cada cultivo.

4.3.2 Comparación de índices combinados

Las cinco formas de cálculo de los índices combinados que surgieron del índice más frecuente en maíz (NDDI_5) y en soja (NDWI_7) se compararon en los períodos con menor RMSE en cada cultivo (período crítico en maíz y ciclo completo en soja). La mediana del RMSE de todos los departamentos en dichos índices resultó menor con las combinaciones CI4 (743 kg.ha⁻¹ en maíz y 291 kg.ha⁻¹ en soja) y CI5 (789 kg.ha⁻¹ en maíz y 299 kg.ha⁻¹ en soja) y, en ambos cultivos, las medianas del RMSE de CI1, CI2 y CI3 (852, 851 y 880 kg.ha⁻¹ en maíz y 321, 346 y 344 kg.ha⁻¹ en soja, respectivamente) no mostraron diferencias entre sí (figura 4.5).

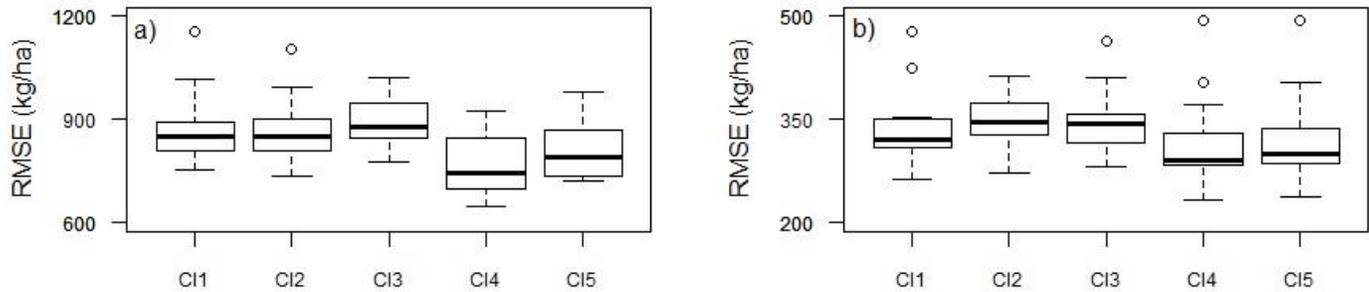


Figura 4.5. Diagramas de caja y bigote mostrando el RMSE de las distintas formas de cálculo de los índices combinados: a) NDDI_5 para el período crítico en maíz y b) NDWI_7 para el ciclo completo en soja.

4.4 Discusión

Los modelos más precisos para estimar rendimientos en soja y en maíz (excepto tres casos) fueron aquellos cuyos índices habían sido escalados (cada 8 días). Éstos presentaron un menor RMSE y una mayor correlación que los índices combinados (cada 16 días). Los máximos valores de coeficientes de determinación en maíz ($R^2 = 0,90$) y en soja ($R^2 = 0,80$) también se encontraron en los índices escalados. Esto puede deberse a que si bien los índices combinados utilizan mayor cantidad de información (temperatura de superficie, precipitaciones e índice de vegetación), probablemente tenga más importancia una mayor frecuencia en los datos (8 días contra 16 días) ya que así se captarían mejor los cambios fenológicos y de estado en la vegetación frecuentemente asociados a precipitaciones puntuales en períodos acotados.

En maíz, de los modelos lineales generados para predecir rendimiento, aquellos que presentaron el menor valor de mediana del RMSE (Sc_NDDI_5_353-1 con $553 \text{ kg}\cdot\text{ha}^{-1}$, error relativo = 11% -dato no mostrado-) como el mínimo absoluto de RMSE (Sc_NDWI_7_353-1 con $363 \text{ kg}\cdot\text{ha}^{-1}$, error relativo = 8%) se obtuvieron al considerar sólo el período crítico. A su vez, los mayores valores de R^2 de predicción (Sc_NDDI_6_353-1 y Sc_NDDI_7_353-1 con 0,90) y la mayor mediana del R^2 de predicción (Sc_NDWI_5_353-1 con 0,71 – datos no mostrados-) también se obtuvieron al considerar solamente el período crítico del cultivo. Los niveles de error mencionados se encuentran dentro de un rango aceptable si se los compara con los errores del 10-20% obtenidos en otros trabajos (Prasad *et al.*, 2006; Moriondo *et al.*, 2007; Mkhabela *et al.* 2011).

En soja se halló un patrón similar, ya que el mínimo RMSE (Sc_NDWI_7_17-49 con 132 kg.ha⁻¹, error relativo = 5%) y el mayor valor de R² de predicción (Sc_NDDI_5_17-49, Sc_NDDI_6_17-49 y Sc_NDDI_7_17-49 con 0,90, datos no mostrados) se encontraron en variables que incluían al período crítico del cultivo (dos períodos de 8 días previo al período crítico hasta el período crítico, PC-2 a PC). La mayor mediana del R² de predicción (Sc_NDWI_7_321-81 con 0,63) y la menor mediana del RMSE (Sc_NDDI_7_321-81 con 248 kg.ha⁻¹, error relativo = 9% -dato no mostrado-) se obtuvieron al considerar el ciclo completo del cultivo. La menor mediana del RMSE previamente mencionada es menor a la hallada por Holzman *et al.* (2014) quienes obtuvieron valores de 366 y 376 kg.ha⁻¹ en la Pampa Interior y Pampa Arenosa (Argentina), respectivamente, al utilizar índices derivados de MODIS.

Los mejores resultados hallados al utilizar los índices NDWI y NDDI (que se calcula utilizando el NDWI), pueden explicarse por varias razones. Por un lado, pueden deberse a que el NDWI es un buen indicador de los cambios en el contenido de agua de la vegetación, es menos sensible a los efectos de dispersión atmosférica que el NDVI (Gao, 1996) y presenta una respuesta más rápida a las condiciones de sequía que el NDVI (Gu *et al.*, 2007). Por otro lado, los índices que utilizan las bandas de la región del infrarrojo de onda corta o SWIR (*Short Wave Infrared*; bandas 5, 6 y 7) se saturan más tarde en el ciclo de maíz y soja que el NDVI (Roberts *et al.*, 1997; Jackson *et al.*, 2004; Chen *et al.*, 2005), permitiendo analizar un rango más amplio de condiciones.

Otras causas de las mejores estimaciones logradas con los índices NDWI y NDDI pueden encontrarse en la diferente reflectividad de la vegetación en las porciones del espectro electromagnético utilizadas en la confección de los índices. La reflectancia en SWIR responde a cambios en el contenido de agua de la vegetación, mientras que la reflectancia en el infrarrojo cercano o NIR (*Near Infrared*, banda 2) es influenciada por la estructura interna y el contenido de materia seca de las hojas, pero no por el contenido de agua. Por esto, la banda NIR ha sido utilizada como referencia en la normalización (Gao, 1996; Roberts *et al.*, 1997; Sims y Gamon, 2002) debido a su relativa insensibilidad a los cambios en el contenido de agua de la vegetación comparada con longitudes de onda más largas del NIR y del SWIR, y a su mejor capacidad de penetración en la canopia en relación a las bandas correspondientes a la porción visible del espectro electromagnético (Chen *et al.*, 2005).

Considerando las distintas formas de cálculo de NDWI y NDDI, también se encontraron leves diferencias en la capacidad de estimar los rendimientos departamentales tanto en maíz como en soja. La diferencia de ajustes logradas con las bandas SWIR puede deberse a que, por ejemplo, el NDWI calculado con la banda 7 presenta un rango mayor de valores que el NDWI calculado con la banda 6 (Chen *et al.*, 2005) lo que posibilita un mejor seguimiento de las condiciones de la vegetación. En relación a la diferencia entre cultivos, Chen *et al.* (2005) encontraron que el NDWI estimaba mejor el contenido de agua de la vegetación en maíz que en soja. Algo similar se determinó en este trabajo, pero al estimar rendimientos.

En general, se puede decir que es necesario considerar los valores de los índices alrededor del período crítico de cada cultivo. Los resultados indican que en maíz es importante considerar los valores de los índices de vegetación (especialmente NDWI y NDDI) durante fines de diciembre para estimar mejor los rendimientos departamentales. En soja, en cambio, se observó que el período crítico (principios a mediados de febrero), períodos que incluyeron momentos previos al período crítico y el ciclo completo (mediados de noviembre a mediados de marzo) son importantes en la estimación, con la ventaja del PC sobre el CC de poder realizar una estimación anticipada sin resignar precisión en las estimaciones. Las bandas 5, 6 y 7 (SWIR) responden mejor al crecimiento de la vegetación bajo condiciones de alta cobertura vegetal (Gao, 1996; Chen *et al.*, 2005), lo que se logra en etapas avanzadas del ciclo de maíz y soja. Esto podría explicar porque las estimaciones resultaron mejores al considerar períodos próximos al período crítico de cada cultivo.

En general, la precisión (medida a través del RMSE) hallada en los índices combinados propuestos en este trabajo (CI4 y CI5) y el rendimiento de ambos cultivos fue mayor que con los índices originales (CI1, CI2 y CI3) propuestos por Rhee *et al.* (2010). Esto puede deberse a que los factores para la ponderación en el cálculo de los índices CI4 y CI5 dan más importancia a la información proveniente de la reflectancia de la vegetación que a la temperatura de superficie y a la precipitación.

Capítulo 5: **Discusión general**

En este capítulo se presentan los principales resultados del trabajo en relación con el objetivo general de determinar y comparar la capacidad de distintos índices (climáticos y espectrales) de estimar los rendimientos agrícolas a escala departamental en la provincia de Entre Ríos. De los tres objetivos específicos planteados, dos estaban dedicados al estudio directo de las relaciones entre los distintos índices y el rendimiento de maíz y soja (capítulos 2 y 4) y uno (capítulo 3) dirigido a evaluar la capacidad de TRMM para estimar la precipitación en Entre Ríos y de esta forma incorporar dicha información en los índices espectrales. A continuación, se resumen los principales resultados en relación con cada objetivo específico y se compara la capacidad de los distintos índices para estimar rendimiento de maíz y soja. Por último, se proponen algunas aplicaciones de los resultados obtenidos.

5.1 Resumen de los principales resultados

Dada la relación entre las condiciones ambientales en las que crecen y la productividad que logran, los cultivos agrícolas deben ser monitoreados para poder predecir con anticipación su rendimiento. Sin embargo, en Entre Ríos no se cuenta con un sistema objetivo de estimaciones de rendimiento para maíz y soja, los cultivos de verano más importantes en la provincia. Por esto, se correlacionaron datos de distinto origen para intentar lograr modelos de predicción del rendimiento aceptables. Primero se utilizaron datos climáticos y luego se utilizaron datos espectrales. Sin embargo, una de las formas de cálculo de los datos espectrales incluía datos de TRMM, de los cuales no existía una evaluación de larga duración en la provincia.

En primera instancia se evaluó la capacidad de los datos de precipitaciones mensuales y de SPI en distintos meses y se los relacionó con la serie histórica de rendimiento de ambos cultivos. Los modelos lineales generados con estos datos (Capítulo 2) mostraron, en general, un ajuste bajo entre las precipitaciones departamentales (estimadas por interpolación) y los rendimientos de ambos cultivos. El SPI, que se basa en el registro de precipitaciones a largo plazo, el cual se ajusta a una distribución de probabilidades y a continuación se transforma en una distribución normal, mostró precisiones (medidas a través del RMSE) levemente superiores en ambos cultivos, con diferencias entre fechas en soja, pero no en maíz. Los mayores coeficientes de determinación en maíz, tanto con precipitaciones como con SPI, se obtuvieron al considerar datos de diciembre, mes en el cual se produce el período crítico del cultivo.

Algo similar se obtuvo para la soja, donde los modelos lineales con menor RMSE fueron aquellos que utilizaron información de la precipitación previa al período crítico y del SPI centrado en dicho período (febrero).

Previo al análisis de los datos espectrales y sus índices, se evaluó la capacidad de los datos de precipitación provenientes de TRMM de estimar las precipitaciones reales en la provincia de Entre Ríos (Capítulo 3). Por un lado, a escala mensual, los datos de TRMM mostraron un mejor ajuste con las precipitaciones reales que las precipitaciones estimadas mediante dos métodos de interpolación. Además, los datos de TRMM presentaron un error de tipo no aleatorio muy inferior, por lo que el método de estimación con datos de TRMM pudo ser corregido. De esta forma se logró un método de estimación de precipitaciones que redujo a aproximadamente la mitad los errores relativos y el RMSE de las estimaciones con los datos originales de TRMM. Por otro lado, las estimaciones de distintos períodos de acumulación de las precipitaciones entre 1 y 29 días mostraron que el coeficiente de determinación aumenta con mayores períodos de acumulación y el error relativo mostró un mínimo en el período de 29 días en las tres estaciones meteorológicas utilizadas para la evaluación. Los índices propuestos por Schaefer (1990) demuestran que las estimaciones son muy buenas a partir de los 15 días de acumulación, período en el que se logra un R^2 aproximado de 0,75 en las estimaciones de las tres estaciones meteorológicas utilizadas para la evaluación. Por lo tanto, se estableció que el período de acumulación de 16 días era adecuado para ser utilizado en los índices espectrales combinados que se utilizarían para estimar rendimiento.

Los índices espectrales mostraron una variada capacidad para predecir rendimientos departamentales en ambos cultivos. De los 392 modelos (49 índices por 8 períodos), las mejores estimaciones se obtuvieron con aquellos modelos que utilizaron al NDWI o su derivado NDDI en su cálculo, con RMSE menores a $500 \text{ kg}\cdot\text{ha}^{-1}$ en maíz y a $300 \text{ kg}\cdot\text{ha}^{-1}$. A su vez, los índices escalados (cada 8 días) fueron más efectivos que los índices combinados (cada 16 días). En general, los modelos mejoraron sus estimaciones cuando se consideró el período crítico en maíz, y períodos que consideraron momentos previos al período crítico hasta dicho período, el período crítico o el ciclo completo en soja. La falta de diferencias significativas entre los períodos mencionados en soja, sugiere que podrían usarse las estimaciones en el período crítico en lugar del ciclo completo ya que el primero brindaría mayor anticipación.

5.2 Comparación entre índices climáticos y espectrales

A los fines de comparar los modelos derivados de índices climáticos y de índices espectrales, se analiza por un lado la totalidad de los mismos en base a la frecuencia relativa acumulada de los RMSE obtenidos. Por otro lado, se comparan el mejor modelo derivado de índices climáticos con el mejor modelo derivado de índices espectrales para cada cultivo. Estas comparaciones muestran que se obtuvieron menores RMSE de predicción con los índices espectrales en las estimaciones de rendimientos departamentales.

Al considerar modelos derivados de índices climáticos en maíz, en el 50% de los casos el RMSE fue menor a $1358 \text{ kg}\cdot\text{ha}^{-1}$ (error relativo menor a 33%) y sólo en el 5% de los casos el RMSE fue menor a $962 \text{ kg}\cdot\text{ha}^{-1}$ (error relativo menor al 27%). En cambio, al considerar los modelos derivados de índices espectrales, en el 50% de los casos el RMSE fue menor a $827 \text{ kg}\cdot\text{ha}^{-1}$ (error relativo menor al 17%) y en el 5% de los casos el RMSE fue menor a $575 \text{ kg}\cdot\text{ha}^{-1}$ (error relativo menor al 12%). Esto demuestra una diferencia a favor de los modelos derivados de índices espectrales (figura 5.1).

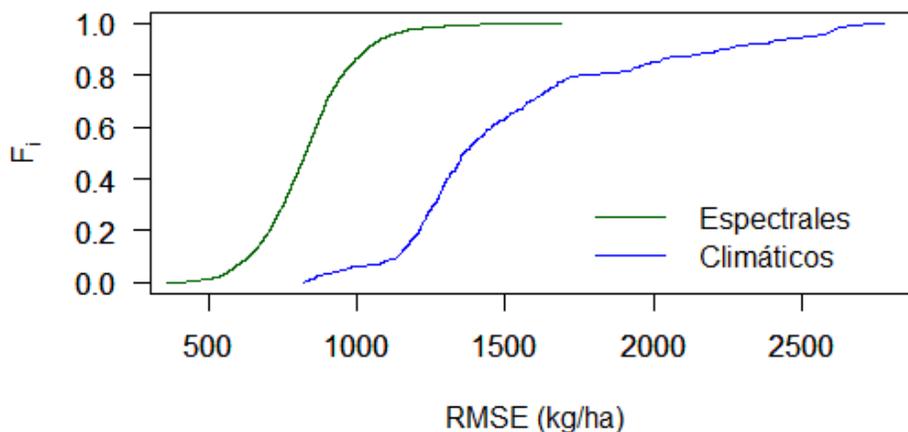


Figura 5.1. Frecuencia relativa acumulada (F_i) en función del RMSE para la totalidad de los modelos en maíz separados por tipo de índices (climáticos y espectrales).

En cuanto a los modelos derivados de índices climáticos en soja, en el 50% de los casos el RMSE fue menor a $377 \text{ kg}\cdot\text{ha}^{-1}$ (error relativo menor a 22%) y en el 5% de los casos el RMSE fue menor a $319 \text{ kg}\cdot\text{ha}^{-1}$ (error relativo menor a 18%). En cambio, al considerar los modelos derivados de índices espectrales, en el 50% de los casos el

RMSE fue menor a $356 \text{ kg}\cdot\text{ha}^{-1}$ (error relativo menor a 16%) y en el 5% de los casos fue menor a $262 \text{ kg}\cdot\text{ha}^{-1}$ (error relativo menor a 12%). Esto demuestra una diferencia a favor de los modelos derivados de índices espectrales, aunque no tan marcada como en maíz (figura 5.2). Una de las posibles causas de la mayor diferencia de RMSE en maíz puede deberse a que la soja presenta una fenología mucho más variable por las distintas fechas de siembra posibles en la provincia. Esto, sumado a la elección de fechas fijas para todos los años para definir el período crítico, puede llevar a desfasajes entre los momentos en los que se realizan las estimaciones y el verdadero estado fenológico de los cultivos en los distintos años.

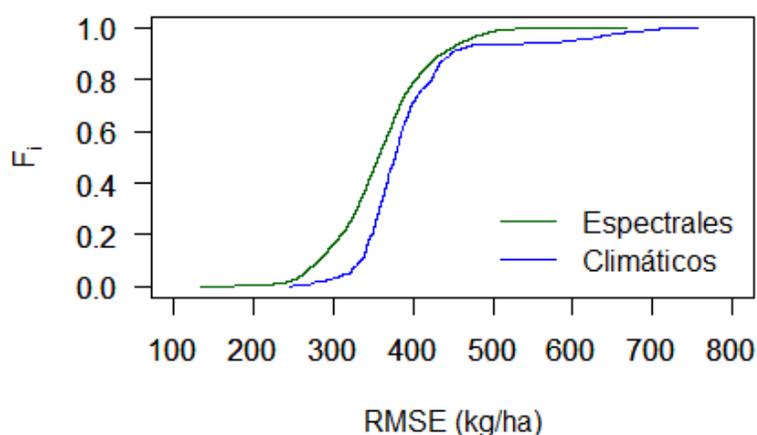


Figura 5.2. Frecuencia relativa acumulada (F_i) en función del RMSE para la totalidad de los modelos en soja separados por tipo de índices (climáticos y espectrales).

En maíz, la mejor estimación lograda con índices climáticos se obtuvo con el SPI de enero y febrero (SPI-Ene-Feb) en el departamento Federal, con un RMSE de $820 \text{ kg}\cdot\text{ha}^{-1}$ (figura 5.3.a). El error relativo fue del 22%. En cambio, la mejor estimación lograda con índices espectrales se produjo con el Sc_NDWI_7 en el período crítico (PC = 19 de diciembre a 1 de enero, días julianos 351-1) en el departamento Villaguay con un RMSE de $363 \text{ kg}\cdot\text{ha}^{-1}$. El error relativo fue del 8%.

En soja, la mejor estimación lograda con índices climáticos se obtuvo con el SPI de enero a marzo (SPI-Ene-Mar) en Federación con un RMSE de $245 \text{ kg}\cdot\text{ha}^{-1}$ (figura 5.3.b). El error relativo fue del 8%. En cambio, la mejor estimación lograda con índices espectrales se produjo con el Sc_NDWI_7 en el período comprendido entre el 17 de

enero y el 18 de febrero (PC-2 a PC, días julianos 17-49) en Nogoyá con un RMSE de 132 kg.ha⁻¹. El error relativo fue del 5%.

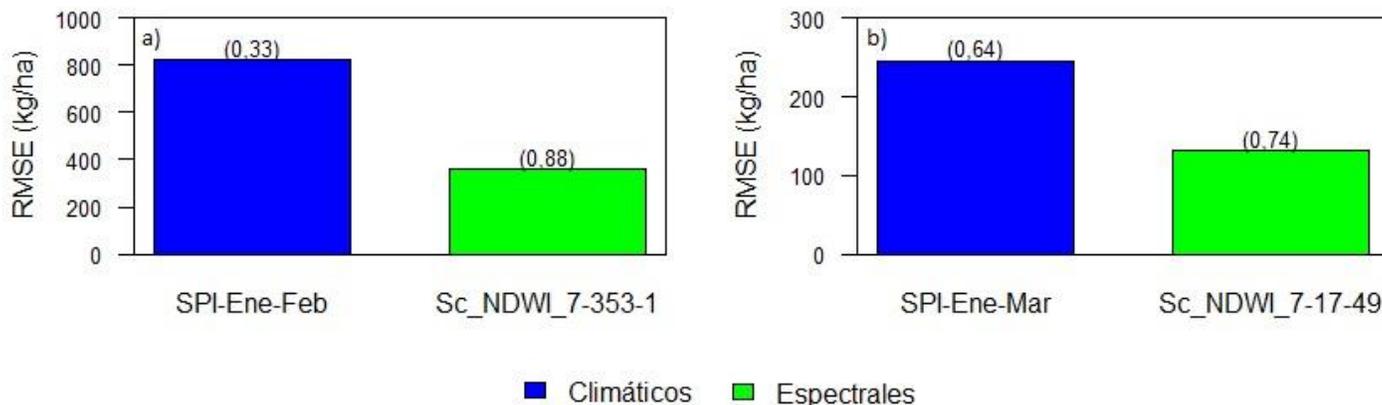


Figura 5.3. Menor RMSE obtenido con cada tipo de índice (climático o espectral) en a) maíz y b) soja. En a) se muestra al SPI-Ene-Feb en Federal y al Sc_NDWI_7-353-1 en Villaguay. En b) se muestra al SPI-Ene-Mar en Federación y al Sc_NDWI_7-17-49 en Nogoyá. Entre paréntesis se muestra el R² de predicción.

5.3 Aportes y posibles aplicaciones

Por un lado, los resultados del capítulo cuyo objetivo era evaluar la capacidad de TRMM de estimar las precipitaciones en Entre Ríos (Capítulo 3) demostró que estos datos resultan mejores estimadores que la interpolación. Tanto a nivel mensual como a nivel de distintos períodos de acumulación se lograron estimaciones muy buenas con TRMM (las estimaciones mejoran al considerar más días acumulados) que posibilitarían su utilización para la mayoría de los posibles usos agronómicos. Se estableció un período de 15 días de acumulación como el mínimo que no disminuye la precisión de las estimaciones, y un óptimo de un mes (período con el cual se logran las mejores estimaciones de la precipitación real). A nivel mensual, se obtuvieron mayores correlaciones entre precipitaciones reales y estimadas mediante TRMM que con los dos métodos de interpolación utilizados, y también un menor error de tipo aleatorio. Esto permitió obtener una ecuación de estimación de las precipitaciones a nivel provincial con una resolución espacial que es mucho mayor a la obtenida con datos interpolados de estaciones meteorológicas convencionales.

Por otro lado, los resultados de los capítulos destinados a estimar rendimientos mostraron que las precipitaciones y el SPI (Capítulo 2) presentaron una menor precisión en la estimación que los índices espectrales (Capítulo 4). En el caso de maíz, el SPI de 3 meses del período enero a febrero (que incluye precipitaciones de diciembre) fue importante para estimar rendimientos, pero se lograron mejores resultados y más anticipación con el Sc_NDWI_7 en el período crítico (19 de diciembre a 1 de enero). De forma similar, en soja se halló que el SPI de 3 meses de enero a marzo (que incluyen las precipitaciones del período crítico del cultivo en febrero) fue importante para estimar rendimientos, pero el Sc_NDWI_7 alrededor del período crítico (17 de enero a 18 de febrero), mostró mejor precisión y más anticipación.

Los trabajos que intentan estimar rendimientos a escala de departamento o distrito mediante sensores remotos suelen combinar modelos de simulación con información satelital (Lobell *et al.*, 2003; Doraiswamy *et al.*, 2004). Uno de los índices más utilizados en estas estimaciones ha sido el NDVI (Groten, 1993; Mochheim y Barber, 1998). Sin embargo, en este trabajo se lograron estimaciones de rendimientos departamentales muy buenas mediante modelos provenientes de simples regresiones lineales al utilizar el índice NDWI y sus derivados. Esto puede deberse a la menor sensibilidad a los efectos de dispersión atmosférica del NDWI en relación al NDVI (Gao, 1996) y a que las bandas de la región del infrarrojo de onda corta (SWIR) se saturan más tarde en el ciclo de maíz y soja que el NDVI (Roberts *et al.*, 1997; Jackson *et al.*, 2004; Chen *et al.*, 2005).

La anticipación lograda en las estimaciones es comparable a la obtenida en los trabajos de otras partes del mundo. En maíz, las mejores estimaciones de rendimiento se lograron con dos meses previos a la cosecha (estimaciones con datos hasta enero y cosecha en marzo), igual a la anticipación lograda en maíz por Mkhabela *et al.* (2005) de dos meses en Suazilandia. En soja también se logró una anticipación de alrededor de dos meses previos a la cosecha (estimaciones con datos hasta mediados de febrero y cosecha a mediados de abril), similar a la anticipación lograda por Holzman *et al.* (2014) de entre uno y tres meses en Argentina.

Una de las limitantes de los índices espectrales es que para su cálculo se utilizan datos de toda la superficie departamental y no solamente de los cultivos. Cambios en el uso de la tierra a través de los años pueden influir en los valores obtenidos y modificar el ajuste de las estimaciones. Lograr identificar áreas sembradas con cada cultivo puede resultar en una mejora de las estimaciones.

Los resultados de esta tesis aportan información nueva para la provincia de Entre Ríos. Los modelos logrados en este trabajo podrían implementarse por los sistemas de monitoreo de instituciones provinciales y/o nacionales o empresas interesadas para obtener estimaciones anticipadas de producción. La provincia de Entre Ríos cuenta con el Sistema Integrado de la Bolsa de Cereales de Entre Ríos (SIBER) que informa los rendimientos departamentales una vez cosechado el cultivo. Si bien durante cada campaña, y principalmente después del período crítico de cada cultivo, se publican informes con el rendimiento que podría alcanzarse, éste es un dato subjetivo derivado de más de 200 colaboradores y suele presentarse como un dato a nivel provincial (no a nivel departamental). Los modelos lineales obtenidos en este trabajo podrían ampliarse con más datos en años futuros o implementarse operativamente en su forma original. Estos modelos aportarían: 1) objetividad en las estimaciones, 2) adecuada anticipación en la estimación y 3) datos a nivel departamental.

Capítulo 6: Bibliografía

Adler, R. F.; Kummerow, C.; Bolvin, D.; Curtis, S.; Kidd, C. 2003. Status of TRMM Monthly Estimates of Tropical Precipitation. En: Tao, W. K et al. (eds). Cloud Systems, Hurricanes, and the Tropical Rainfall Measuring Mission (TRMM), 223-234.

Agnew, M. D.; Palutikof, J. P. 2000. GIS-based construction of base line climatologies for the Mediterranean using terrain variables. *Clim. Res.*, 14: 115–127.

Alexandersson, H.; Moberg, A. 1997. Homogenization of Swedish temperature data. Part I. Homogeneity test for linear trends. *Int. J. Climatol.*, 17: 25–34.

Andrade, H. A.; Sadras, V. O. 2002. Bases para el manejo del maíz, girasol y la soja. FCA-UNMDP, Dekalb-Press. 449 p.

Andriani, J. M.; Andrade, F. H.; Suero, E. E.; Dardanelli, J. L. 1991. Water deficits during reproductive growth of soybeans. I. Their effects on dry matter accumulation, seed yield and yield components. *Agronomie*, 11: 737-746.

Becker-Reshef, I.; Vermote, E.; Lindeman, M.; Justice, C. 2010. A generalized regression-based model for forecasting winter wheat yields in Kansas and Ukraine using MODIS data. *Remote Sensing of Environment*, 114: 1312-1323.

Bettolli, M. L.; Penalba, O. C.; Vargas, W. M. 2002. Asociación entre el rendimiento de la soja y extremos de precipitación acumulada. IX Reunión Argentina de Agrometeorología. 18-20 septiembre de 2002, Vaquerías, Córdoba.

Bettolli, M. L.; Penalba, O. C.; Vargas, W. M. 2004. Cuantificación de la relación rendimiento de la soja- precipitación. Enfoque regional. X Reunión Argentina y IV Latinoamericana de Agrometeorología. Disponible en <http://agro.unc.edu.ar/~clima/AADA/Congresos/MDQ/presidente.htm>. [Fecha de consulta 04/01/2017].

Blum, A. 2005. Drought resistance, water-use efficiency, and yield potential – are they compatible, dissonant, or mutually exclusive? *Australian Journal of Agricultural Research*, 56: 1159-1168.

Boken; V. K.; Shaykewich, C. F. 2002. Improving an operational wheat yield model using phenological phase-based Normalized Difference Vegetation Index. *Int. J. Remote Sens.*, 23, 4155–4168.

Borrough, P. A.; McDonnell, R. A. 1998. Principles of geographical information systems. Oxford University Press, Oxford.

Boyer, J. S. 1982. Plant productivity and environment. *Science*, 218: 443-448.

Brizuela, A.; Nosetto, M.; Aguirre, C.; Bressán, M. 2015. Comparación de datos de precipitación estimada por Trmm con mediciones en estaciones meteorológicas de Entre Ríos, Argentina. *UD y la Geomática*, 10, 18-26

- Brown, D. P.; Comrie, A. C. 2002. Spatial modeling of winter temperatura and precipitation in Arizona and New Mexico, USA. *Clim. Res.*, 22: 115 –128.
- Campos, A. N.; Figueroa Schibber, E. 2014. "Evaluación de la información satelital para el estudio de la dinámica hidrológica de la Llanura Pampeana". 2do Encuentro de Investigadores en Formación en Recursos Hídricos (IFRH), 9 y 10 de octubre de 2014, Buenos Aires, Argentina.
- Chaudhari, K. N; Dadhwal, V. K. 2004. Assessment of impact of drought-2002 on the production of major kharif and rabi crops using standardized precipitation index. *Journal of Agrometeorology*, 6: 10–15.
- Chen, D.; Huang, J.; Jackson, T. J. 2005. Vegetation water content estimation for corn and soybeans using spectral indices derived from MODIS near- and short-wave infrared bands. *Remote Sensing of Environment*, 98: 225 – 236.
- Chiu, L. S.; Liu, Z.; Vongsaard, J.; Morain, S.; Budge, A.; Bales, C.; Neville, P. 2006a. Comparison of TRMM and water división rain rates over New Mexico. *Adv. Atmos. Sci.*, 23: 1-13.
- Chiu, L. S.; Shin, B.; Kwaiktowski, J.; 2006b. Surface rain rate from TRMM algorithms. En: Qu, I. J. et al. (eds) *Earth Science Satellite Remote Sensing*, Springer and Tsinghua University Press, 317–336.
- Chokngamwong, R.; Chiu, L. S. 2008. Thailand Daily Rainfall and Comparison with TRMM Products. *Journal of Hydrometeorology*, 9:256-266.
- Chuvieco Salinero, E. 2002. Teledetección ambiental. La observación de la tierra desde el espacio. Ed. Ariel. 1era edición. 592 pp.
- Cox, W. J.; Joliff, G. D. 1986. Growth and yield of sunflower and soybean under soil water deficits. *Agron. J.* 78: 226-230.
- Dadhwal, V. K.; Sridhar, V. N. 1997. A non-linear regression form for VI-crop yield relation incorporating acquisition data normalization. *Int. J. Remote Sensing*, 18 (6): 1403–1408.
- Daly, C.; Gibson, W. P.; Taylor, G. H.; Johnson, G. L.; Pasteris, P. 2002. A knowledge-based approach to the statistical mapping of climate. *Clim. Res.*, 22: 99-113.
- 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 rendimiento a escala departamental en Córdoba, Argentina. *Agricultura Técnica (Chile)*, 67 (4): 362-371.
- Doraiswamy, P. C.; Cook, P. W. 1995. Spring wheat yield assessment using NOAAVHRR data. *Can. J. Remote Sens.*, 21: 43–51.
- Doraiswamy, P. C.; Moulin, S.; Cook, P. W.; Stern, A. 2003. Crop yield assessment from remote sensing. *Photogrammetric Engineering and Remote Sensing*, 69 (6): 665-674.
- Doraiswamy, P. C., Hatfield, J. L., Jackson, T. J., Akhmedov, B., Prueger, J., Stern, A. 2004. Crop condition and yield simulations using Landsat and MODIS. *Remote Sensing of Environment*, 92: 548-559.

Duan, Z.; Bastiaanssen, W. G. M. 2013. First results from Version 7 TRMM 3B43 precipitation product in combination with a new downscaling–calibration procedure. *Remote Sensing of Environment*, 131: 1-13.

Easterling, D. R.; Peterson, T. 1995. A new method for detecting undocumented discontinuities in climatological time series. *Int. J. Climatol.*, 15: 369–377.

Eck, H. V. 1986. Effects of water deficits on yield components, and water use efficiency of irrigated corn. *Agron. J.*, 78:1035-1040.

Edwards, K. A. 1972. Estimating areal rainfall by fitting surfaces to irregularly spaced data. In: *Proc Int Symp Distribution of Precipitation in Mountainous Areas, Vol 2*. World Meteorological Organisation, Geneva, 565–587.

Edwards, D. C.; McKee, T. B. 1997. Characterization of 20th century drought in the United States at multiple time scale. *Climatology Report Number 97-2*. Department of Atmospheric Science, Colorado State University, Fort Collins, CO, USA.

Gamon, J. A., Field, C. B., Roberts, D. A., Ustin, S. L., Vallentini, R. 1993. Functional patterns in an annual grassland during an AVIRIS overflight. *Remote Sensing of Environment*, 44: 239-253.

Gamon, J. A., Field, C. B., Goulden, M. L., Griffin, K. L., Hartley, A. E., Joel, G., Penuelas, J., Vallentini, R. 1995. Relationships between NDVI, canopy structure, and photosynthesis in three Californian vegetation types. *Ecol. Appl.*, 5: 28-41.

Gao, B. 1996. NDWI — A normalized difference water index for remote sensing of vegetation liquid water from space. *Remote Sensing of Environment*, 58: 257–266.

Gilbert, M. A., González-Piquera, J., García-Haro, J. 1997. Acerca de los índices de vegetación. *Revista de Teledetección*, 8: 1-10.

Gitonga, G.W. 1995. Forecasting Maize Crop yield in Kenya Using Meteorological Satellite Data. *Proceedings of The 1995 Meteorological Satellite Data User's Conference*, 4-8 September, Winchester, United Kingdom, 93-100.

Groten, S. M. E. 1993. NDVI-crop monitoring and early yield assessment of Brukina Faso. *International Journal of Remote Sensing*, 14 (8):1495–1515.

Gu, Y.; Brown, J. F.; Verdin, J. P.; Wardlow, B. 2007. A five-year analysis of MODIS NDVI and NDWI for grassland drought assessment over the central Great Plains of the United States. *Geophysical Research Letters*, 34. doi:10.1029/2006GL029127.

Gupta, R. K.; Prasad, S.; Rao, G. H.; Nadham, T. S. V. 1993. District level wheat yield estimation using NOAA/AVHRR NDVI temporal profile. *Advanced Space Research*, 13: 253–256.

Guttman, N.B., 1994: On the sensitivity of sample L moments to sample size. *Journal of Climate*, 7 (6): 1026–1029.

- Haddad, Z. S.; Smith, E. A.; Kummerow, C. D.; Iguchi, T.; Farrar, M. R.; Durden, S. L.; Alves, M.; Olson, W. S. 1997. The TRMM “day-1” radar/radiometer combined rain-profiling algorithm. *J. Meteor. Soc. Japan*, 75: 799–809.
- Hall, A. J.; Rebella, C. M.; Ghera, C. M.; Culot, J. P. 1992. Field-crops systems of the pampas. En: C. J. Pearson (Ed.), *Field crop systems. Ecosystems of the world*, vol 18, pp 413-450 Elsevier, Amsterdam.
- Hargy, V. T. 1997. Objectively mapping accumulated temperature for Ireland. *Int. J. Climatol.*, 17: 909–927.
- Hayes, M. J.; Decker, W. L. 1996. Using NOAA AVHRR data to estimate maize production in the United States corn belt. *Int. J. Remote Sensing*, 17: 3189–3200.
- Holzman, M. E.; Rivas, R.; Piccolo, M. C. 2014. Estimating soil moisture and the relationship with crop yield using surface temperature and vegetation index. *International Journal of Applied Earth Observation and Geoinformation*, 28: 181–192.
- Hutchinson, M. F. 1995. Interpolating mean rainfall using thin plate smoothing splines. *Int. J. Geogr. Inf. Syst.*, 9: 385–403.
- Jackson, T. J.; Chen, D.; Cosh, M.; Li, F.; Anderson, M.; Walthall, C. 2004. Vegetation water content mapping using Landsat data derived normalized difference water index for corn and soybeans. *Remote Sensing of Environment*, 92: 475– 482.
- Karaseva, M. O.; Prakash, S.; Gairola, R. M. 2012. Validation of high-resolution TRMM-3B43 precipitation product using rain gauge measurements over Kyrgyzstan. *Theor. Appl. Climatol.*, 108: 147–157.
- Kogan, F. N. 1995a. Drought of the late 1980s in the United States as derived from NOAA polar-orbiting satellite data. *Bulletin of the American Meteorological Society*, 76: 655–668.
- Kogan, F. N. 1995b. Application of vegetation index and brightness temperature for drought detection. *Advanced Space Research*, 15: 91–100.
- Kogan, F. N. 1997. Global drought watch from space. *Bulletin of the American Meteorological Society*, 78: 727-636.
- Kogan, F. N. 2001. Operational space technology for global vegetation assessment. *Bulletin of the American Meteorological Society*, 82: 1949–1964.
- Kramer, P. J. 1983. *Water relations of plants*. San Diego, CA: Academic Press.
- Kummerow, C.; Barnes, W.; Kozu, T.; Shiue, J.; Simpson, J. 1998. The Tropical Rainfall Measuring Mission (TRMM) sensor package. *J. Atmos. Oceanic Technol.*, 15: 809–816.
- Kummerow, C.; Simpson, J.; Thiele, O.; Barnes, W.; Chang, A. T. C.; Stocker, E.; Adler, R. F.; Hou, A.; Kakar, R.; Wentz, F.; Ashcroft, P.; Kozu, T.; Hong, Y.; Okamoto, K.; Iguchi, T.; Kuroiwa, H.; Im, E.; Haddad, Z.; Huffman, G.; Ferrier, B.; Olson, W. S.; Zipser, E.; Smith, E. A.; Wilheit, T. T.;

North, G.; Krishnamurti, T.; Nakamura, K. 2000. The status of the Tropical Rainfall Measuring Mission (TRMM) after two years in orbit. *Journal of Applied Meteorology*, 39: 1965-1982.

Labus, M. P.; Nielsen, G. A.; Lawrence, R. L.; Engel, R. 2002. Wheat yield estimates using multi-temporal NDVI satellite imagery. *Int. J. Remote Sens.*, 23: 4169–4180.

Lavado Casimiro, W. S.; Labat, D.; Guyot, J. L.; Ronchail, J.; Ordoñez, J. J. 2009. Validación de lluvia utilizando TRMM en dos cuencas amazónicas peruanas y su aplicación en modelos mensuales de balance hídrico. *Revista Peruana Geo-Atmosférica*, 1: 11-19.

Li, Y. P.; Ye, W.; Wang, M.; Yan, X.D. 2009. Climate change and drought: a risk assessment of crop-yield impacts. *Climate Research*, 39 (1): 31–46.

Llano, M. P.; Vargas, W. 2015. Climate characteristics and their relationship with soybean and maize yields in Argentina, Brazil and the United States. *Int. J. Climatol.* Published online in Wiley Online Library (wileyonlinelibrary.com) DOI: 10.1002/joc.4439.

Lobell, D. B.; Asner, G. P.; Ortiz-Monasterio, J. I.; Benning, T. L. 2003. Remote sensing of regional crop production in the Yaqui Valley, Mexico: Estimates and uncertainties. *Agriculture, Ecosystems and Environment*, 94: 205–220.

Magrin, G. O.; Grondona, M. O.; Travasso, M. I.; Boullón, D. R.; Rodríguez, G. R.; Messina, C. D. 1998. Impacto del fenómeno ENSO sobre la producción de cultivos en la región pampeana argentina. Mimeo, presentado en Reunión académica sobre el fenómeno de El Niño y el agro argentino. Academia Nacional de Ciencias, Buenos Aires, Mayo 1998.

Mao, K. B.; Tang, H. J.; Zhang, L. X.; Li, M. C.; Guo, Y.; Zhao, D. Z. 2008. A method for retrieving soil moisture in Tibet region by utilizing microwave index from TRMM/TMI data. *Int. J. Remote Sensing*, 29 (10): 2903-2923.

MacDonald, R. B. (editor). 1979. The LACIE Symposium, Proceedings of Technical Sessions, 23–26 October 1978, NASA, Lyndon B. Johnson Space Center, Houston, Texas, 1125 p.

McKee T. B.; Doesken, N. J.; Kleist, J. 1993. The relationship of drought frequency and duration to time scales. Preprints Eighth Conf on Applied Climatology Anaheim CA. Amer Meteor Soc, 179–184.

McKee, T. B.; Doesken, N. J.; Kleist, J. 1995. Drought monitoring with multiple time scales. Proceedings of the Ninth Conference on Applied Climatology. Amer Meteor Soc Boston, 233–236.

Mika, J.; Kerényi, J.; Rimoczi-paal, A.; Merza, A.; Szinell, C.; Csiszar, I. 2002. On correlation of maize and wheat yield with NDVI: example of Hungary (1985–1998). *Adv. Space Res.*, 30 (11): 2399–2404.

Ministerio de Agroindustria. 2017. Datos Abiertos Agroindustria. Disponible en: <https://www.agroindustria.gob.ar/datosabiertos/> [Fecha de consulta 20/01/2017].

Mishra, V.; Cherkauer, K. A. 2010. Retrospective droughts in the crop growing season: Implications to corn and soybean yield in the Midwestern United States. *Agricultural and Forest Meteorology*, 150: 1030-1045.

Mkhabela, M. S.; Bullock, P.; Raj, S.; Wang, S.; Yang, Y. 2011. Crop yield forecasting on the Canadian Prairies using MODIS NDVI data. *Agric. For. Meteorol.*, 151: 385–393.

Mkhabela, M. S.; Mkhabela, M. S.; Mashinini, N. N., 2005. Early maize yield forecasting in the four agro-ecological regions of Swaziland using NDVI data derived from NOAA's-AVHRR. *Agric. Forest Meteorol.*, 129 (1–2): 1–9.

Mochheim, K. P.; Barber, D. G. 1998. Canada's using NOAA NDVI data. *Canadian Journal of Remote Sensing*, 24: 17–27.

Mood, A. M.; Graybill, F. A. 1963. *Introduction to the Theory of Statistics*, 2nd Edition. McGraw-Hill, New York, NY, USA.

Moriondo, M.; Maselli, F.; Bindi, M. 2007. A simple model of regional wheat yield based on NDVI data. *Eur. J. Agron.*, 26: 266–274.

New, M.; Hulme, M.; Jones, P. 2000. Representing twentieth century space-time climate variability. Part II. Development of 1901 monthly grids of terrestrial surface climate. *J. Clim.*, 13: 2217–2238.

Nicholson, S. E.; Some, B.; McCollum, J.; Nelkin, E.; Klotter, D.; Berte, Y.; Diallo, B. M.; Gaye, I.; Kpabeba, G.; Ndiaye, O.; Noukpozoukou, J. N.; Tanu, M. M.; Thiam, A.; Toure, A.; Traore, A. K. 2003a. Validation of TRMM and Other Rainfall Estimates with a High-Density Gauge Dataset for West Africa. Part I: Validation of GPCP Rainfall Product and Pre-TRMM Satellite and Blended Products. *Journal of Applied Meteorology*, 42: 1337-1354.

Nicholson, S. E.; Some, B.; McCollum, J.; Nelkin, E.; Klotter, D.; Berte, Y.; Diallo, B. M.; Gaye, I.; Kpabeba, G.; Ndiaye, O.; Noukpozoukou, J. N.; Tanu, M. M.; Thiam, A.; Toure, A.; Traore, A. K. 2003b. Validation of TRMM and Other Rainfall Estimates with a High-Density Gauge Dataset for West Africa. Part II: Validation of TRMM Rainfall Products. *Journal of Applied Meteorology*, 42: 1355-1368.

OMM (Organización Meteorológica Mundial). 1994. *Quarterly Bulletin*, Geneva.

OMM (Organización Meteorológica Mundial). 2012. Índice normalizado de precipitación. Guía del usuario. OMM-Nº 1090, 23 págs. Ginebra, Suiza.

Otegui, M. E. 1992. Incidencia de una sequía alrededor de antesis en el cultivo de maíz. Consumo de agua, producción de materia seca y determinación del rendimiento. Tesis de Magister Scientiae. Facultad de Ciencias Agrarias. Univ. Nac. de Mar del Plata. 93 pp.

Palmer, W. 1965. *Meteorological Drought*. Research paper no.45, U.S. Department of Commerce Weather Bureau, 58 p. Disponible en <http://www.ncdc.noaa.gov/temp-and-precip/drought/docs/palmer.pdf>

Patel, N. R.; Chopra, P.; Dadhwal, V. K. 2007. Analyzing spatial patterns of meteorological drought using standardized precipitation index. *Meteorol. Appl.* 14: 329–336.

Pearson, R. L.; Miller, L. D. 1972. Remote mapping of standing crop biomass for estimation of the productivity of the short-grass Prairie, Pawnee National Grassland, Colorado. *8th International Symposium on Remote Sensing of Environment*, 1357-1381.

Penalba, O. C.; Beltrán, A; Messina, C. 2005. Monthly rainfall in central-eastern Argentina and ENSO: a comparative study of rainfall forecast methodologies. *Revista Brasileira de Agrometeorología*, 13 (2): 49-61.

Penuelas, J.; Filella, I.; Biel, C.; Serrano, L.; Save, R. 1993. The reflectance at the 950– 970 mm region as an indicator of plant water status. *International Journal of Remote Sensing*, 14: 1887–1905.

Podestá, G.; Letson, D.; Messina, C.; Royce, F.; Ferreyra, R. A.; Jones, J.; Hansen, J.; Llovet, I.; Grondona, M.; O’Brien, J. J. 2002. Use of ENSO-related climate information in agricultural decision making in Argentina: a pilot experience. *Agricultural Systems*, 74: 371–392.

Potdar, M. B. 1993. Sorghum yield modeling based on crop growth parameters determined from visible and near-IR channel NOAA AVHRR data. *International Journal of Remote Sensing*, 14: 895– 905.

Prasad, A.K.; Chai, L.; Singh, R.P.; Kafatos, M., 2006. Crop yield estimation model for Iowa using remote sensing and Surface parameters. *Int. J. Appl. Earth Observ. Geoinformat.*, 8 (1): 26–33.

Qi, J.; Cabot, F.; Moran, M. S.; Dedieu, G. 1995. Biophysical parameter estimations using multidirectional spectral measurements. *Remote Sensing of Environment*, 54: 71-83.

Quarmby, N.A.; Milnes, M.; Hindle, T.L.; Silleos, N., 1993. The use of multi-temporal NDVI measurements from AVHRR data for crop yield estimation and prediction. *Int. J. Remote Sens.*, 14: 199–210.

R Core Team (2016). R: A language and environment for statistical computing. R Foundation for Statistical Computing, Vienna, Austria. URL <https://www.R-project.org/>.

Ren, J.; Chen, Z.; Zhou, Q.; Tang, H. Regional yield estimation for winter wheat with MODIS-NDVI data in Shandong, China. *Int. J. Appl. Earth Observ. Geoinformat.*, 10: 403-413.

Rencz, A. N. 1999. Manual of remote sensing. Remote sensing for the Earth sciences (Volume 3). 3^o Edition. American Society for Photogrammetry and Remote Sensing. 707 pp.

Rhee, J.; Im, J.; Carbone, G. J. 2010. Monitoring agricultural drought for arid and humid regions using multi-sensor remote sensing data. *Remote Sensing of Environment*, 114: 2875-2887.

Rhoades, D. A.; Salinger, M. J. 1993. Adjustment of temperatura and rainfall records for site changes. *Int. J. Climatol.*, 13: 899–913.

Roberts, D. A.; Green, R. O.; Adams, J. B. 1997. Temporal and spatial patterns in vegetation and atmospheric properties from AVIRIS. *Remote Sensing of Environment*, 62: 223– 240.

Rosenfeld, D. 2000. Suppression of rain and snow by urban and industrial air. *Science*, 287: 1793–1796.

Rötter, R.; van de Geijn, S.C. 1999. Climate change effects on plant growth, crop yield and livestock. *Climatic Change*, 43 (4): 651–681.

Rouse, J. W.; Haas, R. H.; Schell, J. A.; Deering, D. W.; Harlan, J. C. 1974. Monitoring the vernal advancement of retrogradation of natural vegetation. NASA/OSFC. Type III. Final Report. Greenbelt MD. pp 371.

Rozante, J. R.; Moreira, D. S.; de Goncalves, L. G. G.; Vila, D. A. 2010. Combining TRMM and Surface Observations of Precipitation: Technique and Validation over South America. *Weather and Forecast*, 25: 885-894.

Salter, P. J.; Goode, J. E. 1967. Crop responses to water at different stages of growth. Bucks, England: Commonwealth Agricultural Bureaux, Farnham Royal.

Schaefer, J. T. 1990. The critical success index as an indicator of warning skill. *Wea. Forecasting*, 5: 570-575.

Seiler, R. A.; Kogan, F.; Sullivan, J. 1998. AVHRR-based vegetation and temperature condition indices for drought detection in Argentina. *Advances in Space Research*, 21 (3): 481-484.

Sellers, P. J. 1985. Canopy reflectance, photosynthesis and transpiration. *Int. J. Remote Sensing*, 6: 1335-1372.

Sims, D. A.; Gamon, J. A. 2002. Estimation of vegetation water content and photosynthetic tissue area from spectral reflectance: A comparison of indices based on liquid water and chlorophyll absorption features. *Remote Sensing of Environment*, 84: 526 – 537.

Sivakumar, M.; Das, H.; Brunini, O. 2005. Impacts of Present and future climate variability and change on agriculture and forestry in the arid and semi-arid tropics. *Climatic Change*, 70 (1): 31–72.

Smith, E. P.; Rose, K. A. 1995. Model goodness-of-fit analysis using regression and related techniques. *Ecological Modeling*, 77: 49–64.

Takayabu, Y. N.; Iguchi, T.; Kachi, N.; Shibata, A.; Kanzawa, H. 1999. Abrupt termination of the 1997–98 El Niño in response to a Madden–Julian oscillation. *Nature*, 402: 279–282.

Teigen, L.D., Thomas Jr., M., 1995. Weather and yield, 1950–94: relationships, distributions, and data. Commercial Agriculture Division, Economic Research Service, U.S. Department of Agriculture, Staff Paper No. 9527.

Thiam, A., Eastman, J. R. 2006. IDRISI Andes. Guide to GIS and image processing. Manual Version 15.00. Capítulo 18: Índices de vegetación. pp: 218-230. Clark University, Worcester Massachusetts.

- Thiessen, A. H. 1911. Precipitation averages for large areas. *Mon. Weather Rev.*, 39: 1082–1084.
- Thom, H. C. S. 1966. Some methods of climatological analysis. Secretariat of the World Meteorological Organization.
- Thomson, A.M.; Brown, R.A.; Rosenberg, N.J.; Izaurrealde, R.C.; Benson, V. 2005. Climate change impacts for the conterminous USA: an integrated assessment. *Climatic Change*, 69 (1): 43–65.
- Unganai, L. S.; Kogan, F. N. 1998. Drought monitoring and corn yield estimation in Southern Africa from AVHRR Data. *Remote Sens. Environ.* 63: 219–232.
- Vaiman, N.; Durante, M. 2016. Estimación de las precipitaciones mediante interpolación vs datos satelitales para Entre Ríos (Argentina). XVI Reunión Argentina y VIII Latinoamericana de Agrometeorología. 20-23 de septiembre de 2016, Puerto Madryn, Chubut.
- Viltard, N.; Kummerow, C.; Olson, W. S.; Hong, Y. 2000. Combined use of the radar and radiometer of TRMM to estimate the influence of drop size distributions on rain retrievals. *J. Appl. Meteor.*, 39: 2103–2114.
- Wang, L.; Qu, J. J. 2007. NMDI: A normalized multi-band drought index for monitoring soil and vegetation moisture with satellite remote sensing. *Geophysical Research Letters*, 34. doi:10.1029/2007GL031021.
- Weigand, C. L.; Richardson, A. J. 1987. Spectral components analysis: rationale, and results for three crops. *Int. J. Remote Sensing*, 8: 1011-1032.
- Wilhite, D. A. 1993. Planning for drought: a methodology, drought assessment, management and planning: theory and case studies. In *Drought Assessment, Management and Planning: Theory and Case Studies* (D. A. Wilhite, Ed.), Kluwer Academic, Boston, 87–109.
- Willmott, C. J.; Rowe, C. M.; Philpot, W. D. 1985. Small-scale climate maps: a sensitivity analysis of some common assumptions associated with grid-point interpolation and contouring. *Am. Cartographer*, 12: 5–16.
- Wolff, D. B.; Marks, D. A.; Amitai, E.; Silberstein, D. S.; Fisher, B. L.; Tokay, A.; Wang, J.; Pippitt, L. 2005. Ground Validation for the Tropical Rainfall Measuring Mission (TRMM). *Journal of Atmospheric and Ocean Technology*, 22: 365-380.
- Yamoaha, C. F.; Walters, D. T.; Shapiro, C. A.; Francis, C. A.; Hayesc, M. J. 2000. Standardized precipitation index and nitrogen rate effects on crop yields and risk distribution in maize. *Agriculture, Ecosystems and Environment*, 80: 113–120.
- Zang, X. 1998. On the estimation of biomass of submerged vegetation using Landsat thematic mapper (TM) imagery: a case study of the Honghu Lake, PR China. *Int. J. Rem. Sens.*, 19(l): 11-20.