



**Universidad Nacional de Córdoba
Facultad de Ciencias Agropecuarias
Escuela para Graduados**



**ESTIMACIÓN DEL RENDIMIENTO DE SOJA
EMPLEANDO INFORMACIÓN SATELITAL Y MODELOS
DE SIMULACIÓN DE CULTIVOS**

Gustavo Gabriel Ovando.

**Tesis para optar al Grado de
Doctor en Ciencias Agropecuarias**

Córdoba, 2019

ESTIMACIÓN DEL RENDIMIENTO DE SOJA EMPLEANDO INFORMACIÓN SATELITAL Y MODELOS DE SIMULACIÓN DE CULTIVOS

Gustavo Gabriel Ovando.

Comisión Asesora de Tesis

Director: PhD. Andrés Ravelo.

Asesor: Dr. Marcelo Scavuzzo.

Asesor: Dr. Andrés Ferreyra.

Tribunal Examinador de Tesis

Dr. Carlos M. Di Bella:

Dr. Mariano P. Grilli:

Dr. Carlos M. Scavuzzo:

Presentación formal académica

Fecha:

Facultad de Ciencias Agropecuarias
Universidad Nacional de Córdoba



DEDICATORIA

A Gloria, Mónica, Cecilia y Lucía, Karina, Catalina y Dany quienes me han apoyado incondicionalmente brindándome su comprensión, cariño y amor.

A mis padres Leonor y Héctor por inculcarme la perseverancia y el esfuerzo como metodología para alcanzar mis objetivos.

A mis hermanos Adriana y Horacio y mi sobrino Hernán por su eterna amistad.

AGRADECIMIENTOS

A mi comisión asesora de tesis: Dr. Andrés Ravelo, Dr. Marcelo Scavuzzo y Dr. Andrés Ferreyra.

A mis compañeros de trabajo Antonio de la Casa, María Rosa Ateca, Roberto Zanvettor, Karina Torterolo, Juan Pablo Clemente, Guillermo Díaz, Pablo Díaz, Mónica Bocco y Silvina Sayago, por su permanente apoyo y compañerismo.

Al los Ing. Agr. Pablo Montiel y Victor Capuccino y los productores Carné, Copello, Del Pino, Lencinas y Giordano, por su valiosa colaboración al permitirnos utilizar sus establecimientos para la toma de datos.

A Rosa Casadio, León de la Casa, los Sres. Ibarra y Ruiz por su colaboración en la toma de datos.

A la Facultad de Ciencias Agropecuarias de la Universidad Nacional de Córdoba y a la Escuela para Graduados.

RESUMEN

La estimación de la productividad de la soja es un dato estratégico a nivel regional. Los modelos de cultivos proveen una descripción continua del crecimiento y desarrollo del cultivo. La teledetección permite el monitoreo del crecimiento y desarrollo de la vegetación en un área determinada. El objetivo general de este estudio fue predecir parámetros biofísicos del cultivo de soja, integrando datos de teledetección del sensor MODIS en el modelo de cultivo STICS. En diez lotes con soja de la región central de la provincia de Córdoba se realizaron observaciones de: índice de área foliar (LAI), fracción de la radiación fotosintéticamente activa interceptada (*f*IPAR), cobertura del cultivo (%C), materia seca de la parte aérea (MS), fase fenológica, contenido de agua del suelo (HS) y rendimiento. El modelo de transferencia radiativa PROSAIL se utilizó para generar una base de datos que se invirtió empleando redes neuronales artificiales (ANN), con el fin de estimar LAI a partir de valores de reflectancias de MODIS. Se forzó al modelo STICS a tomar valores de LAI (STICS-f) y con ambos se simuló MS y rendimiento, como así también HS. Las reflectancias simuladas con PROSAIL mostraron la evolución típica con el incremento del LAI: un aumento de la absorción en azul y rojo e incremento en la reflectancia NIR. La ANN con mejor desempeño en la inversión de PROSAIL consideró como datos de entrada solamente las reflectancias en azul, rojo y NIR para estimar el LAI. En la calibración de los coeficientes del cultivo del modelo STICS, se debió considerar las diferentes fechas y densidades de siembra como así también la longitud del ciclo de las variedades utilizadas. Como era de esperar, al pasar del modelo STICS a STICS-f, los errores de estimación del LAI disminuyen (%RMSE de 29,2% a 12,2%), como así también los errores al estimar MS; sin embargo, resultaron elevados en comparación con la bibliografía analizada. Cuando el análisis considera solamente la materia seca vegetativa, los errores disminuyen considerablemente. El contenido de humedad del suelo hasta 2m de profundidad y el rendimiento, fueron estimados adecuadamente tanto con STICS como con STICS-f, cuyos valores de %RMSE estuvieron en torno a 10%.

Palabras clave: soja, modelo STICS, modelo PROSAIL, MODIS

ABSTRACT

The estimation of soybean productivity is a strategic information at the regional level. While crop models provide a continuous description of crop growth, remote sensing also allows monitoring the growth and development of vegetation also for a given area. The general objective of this study was to predict biophysical parameters of soybean crop, integrating remote sensing data from the MODIS sensor with the STICS crop model. At central region of Córdoba province, observations were made, in ten plots with soybean: leaf area index (LAI), fraction of intercepted photosynthetically active radiation (*fIPAR*), crop coverage (% C), dry matter the aerial (MS), phenological stage, soil moisture content (HS) and yield. The radiative transfer model PROSAIL was used to generate a database that was inverted using artificial neural networks (ANN) to estimate LAI from MODIS reflectance values. The STICS model was forced to take LAI values (STICS-f), to estimate MS and yield, as well as HS. The simulated reflectances with PROSAIL showed the typical evolution with the increase of LAI: an increase for the absorption in blue and red bands and an increase in the NIR reflectance. Only data of the reflectance in blue, red and NIR were used as input in the ANN with better performance in the inversion of PROSAIL to estimate LAI. In the calibration of STICS model, crop coefficients for the different sowing dates and densities as well as the cycle length of the varieties used should be considered. As expected, when changing from STICS to STICS-f model, the LAI estimation errors decrease (% RMSE from 29.2% to 12.2%), as well as errors in MS estimating; however, they were high in comparison with the literature analyzed. When considering vegetative dry matter, the errors decrease markedly. The moisture content of the soil up to 2m depth and the yield were properly estimated with both STICS and STICS-f, models, whose %RMSE values were around 10%.

Keywords: soybean, STICS model, PROSAIL model, MODIS

TABLA DE CONTENIDOS

CAPÍTULO 1 – INTRODUCCIÓN.....	1
1.1. Modelos de Cultivos	2
1.2. Teledetección.....	6
1.3. Índices de Vegetación.....	9
1.4. Modelos de Transferencia Radiativa.....	11
1.5. Redes Neuronales Artificiales	13
Hipótesis.....	15
OBJETIVO GENERAL.....	16
OBJETIVOS ESPECÍFICOS.....	16
ESTRUCTURA DE LA TESIS.....	17
CAPÍTULO 2 - MATERIAL Y MÉTODOS	19
2.1 Descripción del área de estudio.....	19
2.2. Procedimientos para estimar diferentes parámetros del cultivo de soja.	21
2.3. Caracterización de los suelos de la región.....	22
2.4. Medición de parámetros biofísicos y del contenido de humedad del suelo.....	23
2.5. Información Satelital.....	24
2.6. Modelo de transferencia radiativa PROSPECT + SAIL.	26
2.6.1. Datos de entrada para PROSPECT	26
2.6.1.1. Contenido de clorofila (<i>Cab</i> , $\mu\text{g cm}^{-2}$):.....	26
2.6.1.2. Contenido de carotenoides (<i>Car</i> , $\mu\text{g cm}^{-2}$):	27
2.6.1.3. Contenido de pigmentos marrones (<i>Cbrown</i> , adimensional):	27
2.6.1.4. Espesor de agua equivalente de la hoja (<i>Cw</i> , g cm^{-2} ó cm):	27
2.6.1.5. Contenido de materia seca por unidad de área (<i>Cm</i> , g cm^{-2}):	28
2.6.1.6. Índice de estructura del mesófilo de la hoja (<i>N</i> , adimensional):	28
2.6.1. Datos de entrada para SAIL	29
2.6.2.1. Ángulo foliar promedio (<i>Angl</i> , °)	29
2.6.2.2. Índice de Área Foliar (<i>LAI</i> , m^2 de hoja m^{-2} suelo)	30
2.6.2.3. Hot Spot (<i>hspot</i> , adimensional)	30

2.6.2.4. Geometría del sensor-sol-píxel observado.....	31
2.6.2.5. Coeficiente de humedad del suelo (<i>psoil</i> , adimensional)	33
2.6.2.6. Fracción de radiación solar difusa respecto de la radiación solar incidente (<i>Skyl</i> , adimensional).	34
2.7. Obtención de la base de datos del modelo PROSPECT+SAIL.....	35
2.8. Inversión del Modelo PROSPECT+SAIL mediante el empleo de Redes	36
2.8.1. Arquitectura de la Red Neuronal	36
2.8.2. Entrenamiento y validación de la Red Neuronal	38
2.9. Modelo STICS para la simulación del cultivo de soja.....	39
2.9.1. Información meteorológica empleada:	40
2.9.2. Características del suelo:	41
2.9.3. Manejo del cultivo:	42
2.9.4. Características del cultivo:	42
2.9.5. Utilización del Índice de Área Foliar en el modelo STICS:	42
2.10. Estimación de parámetros biofísicos de la soja.	44
CAPÍTULO 3 - RESULTADOS.....	46
3.1. Determinación del porcentaje de cobertura de soja.....	46
3.2. Relación entre la Fracción de la Radiación Fotosintéticamente Activa Interceptada y la cobertura de soja.....	48
3.3. Relación entre índice de área foliar y la cobertura de soja.....	49
3.4. Relación entre el índice de área foliar y el NDVI.....	50
3.5. Relación entre el NDVI y <i>fIPAR</i>	51
3.6. Relación entre el NDVI y %C.....	52
3.7. Relación entre el NDVI y Biomasa de la parte Aérea.....	53
3.8. Modelo de transferencia radiativa PROSAIL.....	54
3.9. Estimación del LAI a partir de Redes Neuronales Artificiales.	61
3.10. Modelo STICS.....	68
3.10.1. Índice de Área Foliar.....	70
3.10.2. Materia seca de la parte aérea.....	75
3.10.3. Humedad del suelo.....	79
3.10.4. Rendimiento.....	83

CAPÍTULO 4 - DISCUSIÓN	85
4.1. Determinación del porcentaje de cobertura de soja.....	85
4.2. Relación entre la Fracción de la Radiación Fotosintéticamente Activa Interceptada y la cobertura de soja.....	86
4.3. Relación entre índice de área foliar y la cobertura de soja.....	87
4.4. Relación entre el índice de área foliar y el NDVI.....	88
4.5. Relación entre el NDVI y <i>f</i> IPAR.....	90
4.6. Relación entre el NDVI y %C.....	91
4.7. Relación entre el NDVI y Biomasa de la parte Aérea.....	92
4.8. Modelo de transferencia radiativa PROSAIL.....	93
4.9. Estimación del LAI a partir de Redes Neuronales Artificiales.	95
4.10. Modelo STICS.....	98
4.10.1. <i>Índice de Área Foliar</i>	98
4.10.2. <i>Materia seca de la parte aérea</i>	99
4.10.3. <i>Humedad del suelo</i>	100
4.10.4. <i>Rendimiento</i>	101
CAPÍTULO 5 - CONCLUSIONES	103
CAPÍTULO 6 - BIBLIOGRAFÍA	106

LISTA DE TABLAS

Tabla 2.1 Características de los horizontes de los suelos de la Serie Villa del Rosario	22
Tabla 2.2 Características de los horizontes de los suelos de la Serie Matorrales.	22
Tabla 2.3 Características de los horizontes de los suelos de la Serie Oncativo.	23
Tabla 2.4 Distribución de frecuencias del ángulo foliar en soja (Tomado de Goel & Strebel, 1984).	30
Tabla 2.5 Rango y distribución de las variables que se modificaron en la simulación del modelo PROSPECT+SAIL para obtener el valor de reflectancia.	35
Tabla 2.6 Arquitectura de las distintas redes neuronales empleadas en la inversión del modelo PROSPECT+SAIL.	38
Tabla 3.1 Valores del coeficiente de determinación y errores de validación de los distintos modelos de redes neuronales empleados para estimar el LAI a partir de la inversión del modelo PROSAIL, respecto de los valores de LAI calculados a partir de su relación con el %C obtenido mediante fotografías digitales verticales.	62
Tabla 3.2 Valores del coeficiente de determinación y errores de validación de los distintos modelos de redes neuronales para valores observados de LAI menores o iguales que 4.	66
Tabla 3.3 Diferencias entre los coeficientes de determinación y los errores de validación de los distintos modelos de redes neuronales para todos los valores observados de LAI y aquellos menores o iguales que 4.	66
Tabla 3.4 Parámetros del cultivar del modelo STICS calibrados para cada lote.	68
Tabla 3.5 Coeficientes de ajuste para estimar LAI en STIC-f en los distintos lotes.	69
Tabla 3.6 Coeficientes de determinación y errores estadísticos en la estimación del índice de área foliar (LAI) con STICS y STICS-f.	70
Tabla 3.7 Coeficientes de determinación y errores estadísticos en la estimación de materia seca (MS) y materia seca vegetativa (MS-veg) con STICS y STICS-f.	75
Tabla 3.8 Coeficientes de determinación y errores estadísticos en la estimación del contenido hídrico del suelo (HS) con STICS y STICS-f.	79
Tabla 3.9 Coeficientes de determinación y errores estadísticos en la estimación del rendimiento (RTO) con STICS y STICS-f.	83

LISTA DE FIGURAS

Figura 2.1 Ubicación del área de estudio y de los establecimientos rurales utilizados para simular el crecimiento, desarrollo y rendimiento del cultivo de soja.	20
Figura 2.2 Diagrama de flujo de los diferentes procesos empleados para estimar humedad del suelo, materia seca y rendimiento del cultivo de soja.	21
Figura 2.3 Proyección sinusoidal utilizada en las imágenes MODIS/AQUA con horizontales (h) y verticales (v), en el recuadro rojo se muestra la escena v12, h12 que contiene a la zona central de Córdoba.	25
Figura 2.4 Geometría de la radiación incidente y reflejada sobre una superficie. La función de distribución de reflectancia bidireccional (BRDF) queda caracterizada por los ángulos cenitales del sol (tts) y de vista (tto) y por el ángulo acimutal relativo (tts).	32
Figura 2.5 Esquema de la red neuronal artificial utilizada para invertir el modelo de transferencia radiativa.	37
Figura 2.6 Parámetros del suelo de la Serie Oncativo, empleados para la simulación del cultivo de soja.	41
Figura 2.7 Módulo para interpolar el Índice de Área Foliar, a lo largo del ciclo de cultivo, a partir de datos observados.	43
Figura 3.1 Evolución de la cobertura del suelo a lo largo del ciclo del cultivo, calculada a partir de las fotografías digitales (izquierda) clasificadas por el método de máxima verosimilitud en suelo y vegetación (derecha) para el lote 1 del área de estudio. Las fotografías presentan el estado fenológico según escala desarrollada por Fehr <i>et al.</i> (1971), en tanto que las imágenes clasificadas muestran los valores de porcentaje de cobertura (%C).	47
Figura 3.2 Relación entre la fracción de la radiación fotosintéticamente activa interceptada por el canopeo ($fIPAR$) con respecto a la cobertura de soja (%C) para las campañas 2005-2006 y 2007-2008.	48
Figura 3.3 Relación entre Índice de Área Foliar (LAI) y la Cobertura de Soja (%C) para las campañas 2005-2006 y 2007-2008.	49
Figura 3.4 Relación entre Índice de Área Foliar (LAI) y el Índice de Vegetación de la Diferencia Normalizada (NDVI) para la campaña 2005-2006, considerando las distintas fases fenológicas según la escala de Fehr <i>et al.</i> (1971).	50

Figura 3.5 Relación entre la fracción de la radiación fotosintéticamente activa interceptada (<i>fIPAR</i>) y el Índice de Vegetación de la Diferencia Normalizada (NDVI) para la campaña 2005-2006, considerando las distintas fases fenológicas según la escala de Fehr <i>et al.</i> (1971).	51
Figura 3.6 Relación entre la fracción del suelo cubierta por el cultivo (%C) y el Índice de Vegetación de la Diferencia Normalizada (NDVI) para la campaña 2005-2006, considerando las distintas fases fenológicas según la escala de Fehr <i>et al.</i> (1971)	52
Figura 3.7 Relación entre la Biomasa de la parte aérea y el Índice de Vegetación de la Diferencia Normalizada (NDVI) para la campaña 2005-2006, considerando las distintas fases fenológicas según la escala de Fehr <i>et al.</i> (1971).	53
Figura 3.8 Relación entre las reflectancias en las bandas banda azul y rojo e infrarrojo cercano, y NDVI estimados a partir de PROSAIL y los observados por MODIS.	54
Figura 3.9 Valores de reflectancia en la banda azul estimados por PROSAIL para 1000 valores de la base de datos tomados al azar y los observados por MODIS en todos los lotes con soja (campaña 2005-2006), en función del LAI.	55
Figura 3.10 Valores de reflectancia en la banda roja estimados por PROSAIL para 1000 valores de la base de datos tomados al azar y los observados por MODIS en todos los lotes con soja (campaña 2005-2006), en función del LAI.	56
Figura 3.11 Valores de reflectancia en la banda NIR estimados por PROSAIL para 1000 valores de la base de datos tomados al azar y los observados por MODIS en todos los lotes con soja (campaña 2005-2006), en función del LAI.	56
Figura 3.12 Valores de NDVI calculados a partir de PROSAIL para 1000 valores de la base de datos tomados al azar y los obtenidos de MODIS en todos los lotes con soja (campaña 2005-2006), en función del LAI.	57
Figura 3.13 Dispersión entre los valores de mediana de reflectancia azul de PROSAIL y las medianas de MODIS MYD13Q1, calculadas con intervalos de 0,5 de LAI.	58
Figura 3.14 Dispersión entre los valores de mediana de reflectancia rojo de PROSAIL y las medianas de MODIS MYD13Q1, calculadas con intervalos de 0,5 de LAI.	59
Figura 3.15 Dispersión entre los valores de mediana de reflectancia NIR de PROSAIL y las medianas de MODIS MYD13Q1, calculadas con intervalos de 0,5 de LAI.	60
Figura 3.16 Dispersión entre los valores de mediana de NDVI de PROSAIL y las medianas de MODIS MYD13Q1, calculadas con intervalos de 0,5 de LAI.	60

Figura 3.17 Dispersión entre los valores de LAI estimados con los modelos de redes neuronales A001, A002 y A003 con respecto a los valores obtenidos a partir de fotografías digitales verticales en todos los lotes con soja (campaña 2005-2006).	63
Figura 3.18 Dispersión entre los valores de LAI estimados con los modelos de redes neuronales A004, A005 y A006 con respecto a los valores obtenidos a partir de fotografías digitales verticales en todos los lotes con soja (campaña 2005-2006).	64
Figura 3.19 Dispersión entre los valores de LAI estimados con los modelos de redes neuronales A007, A008 y A009 con respecto a los valores obtenidos a partir de fotografías digitales verticales en todos los lotes con soja (campaña 2005-2006)..	65
Figura 3.20 Variación de los valores de R^2 y RMSE para distintos intervalos de LAI hasta los que se evaluó el desempeño del modelo de redes neuronales A008 en la fase de validación.	67
Figura 3.21 Relación entre los valores de índice de área foliar (LAI) observados y estimados por los modelos STICS y STICS-f, campaña 2005-2006.	71
Figura 3.22 Evolución del índice de área foliar (LAI) simulado con STICS y observado en todos los lotes de soja, campaña 2005-2006.	72
Figura 3.23 Evolución del índice de área foliar (LAI) simulado con STICS-f y observado en todos los lotes de soja, campaña 2005-2006.	73
Figura 3.24 Relación entre los valores de la materia seca de la parte aérea (MS) y materia seca de la parte aérea vegetativa (MS-Veg) observados y estimados por los modelos STICS y STICS-f, campaña 2005-2006.	76
Figura 3.25 Evolución de la materia seca aérea (MS) y la materia seca vegetativa (MS-Veg) simuladas con STICS y la materia seca aérea observada de todos los lotes de soja, campaña 2005-2006.	77
Figura 3.26 Evolución de la materia seca aérea (MS) y la materia seca vegetativa (MS-Veg) simuladas con STICS-f y la materia seca aérea observada de todos los lotes de soja, campaña 2005-2006.	78
Figura 3.27 Relación entre los valores del contenido hídrico del suelo (HS) observados y estimados por los modelos STICS y STICS-f, campaña 2005-2006.	80
Figura 3.28 Evolución del contenido de humedad del suelo (HS), simulado con STICS y observado de todos los lotes de soja, campaña 2005-2006.	81
Figura 3.29 Evolución del contenido de humedad del suelo (HS), simulado con STICS-f y observado de todos los lotes de soja, campaña 2005-2006.	82
Figura 3.30 Relación entre los valores de rendimientos de soja observados y estimados por los modelos STICS y STICS-f, campaña 2005-2006.	84

LISTA DE ABREVIATURAS

%C	Porcentaje de cobertura del cultivo
%RMSE	Raíz del error cuadrático medio relativo
a	Máxima tasa de senescencia del índice de área foliar
Angl	Ángulo foliar promedio
ANN	Redes neuronales artificiales
argi	Contenido de arcilla en el horizonte superficial
b	Máxima tasa de crecimiento del índice de área foliar
BIAS	Error promedio
BRFs	Factores de reflectancia bidireccional
Cab	Contenido de clorofila
calc	Porcentaje de calcáreo en superficie
Car	Contenido de carotenoides
Cbrown	Contenido de pigmentos marrones
Cm	Contenido de materia seca por unidad de área
CsurNsol	Proporción de carbono respecto de nitrógeno del humus del suelo
Cw	Espesor de agua equivalente de la hoja
d	Índice de concordancia
DAF	Densidad aparente del suelo
E	Neuronas de la capa de entrada
EVI	<i>Enhanced vegetation index</i>
epc	Espesor de cada capa del suelo
est	Promedio de la variable estimada por el modelo
est_i	Variable estimada por el modelo
fAPAR	Fracción de radiación fotosintéticamente activa absorbida por la vegetación.
fIPAR	Fracción de radiación fotosintéticamente activa interceptada por la vegetación
GPS	Sistema de Posicionamiento Global
HCCF	Humedad a capacidad de campo
HMINF	Humedad en el punto de marchitez permanente
HS	Contenido hídrico del suelo hasta 2m de profundidad
hspot	<i>Hot Spot</i>
INTA	Instituto Nacional de Tecnología Agropecuaria
IPAR	Radiación fotosintéticamente activa interceptada por el canopeo
k	Índice de área foliar máximo
LAI	Índice de área foliar
LAI_(d)	Índice de área foliar en el día d, a partir de la emergencia
LP DAAC	<i>Processes Distributed Active Archive</i>
LUT	Tablas de correspondencia
MAE	Error absoluto promedio
MERIS	<i>MEdium-spectral Resolution, Imaging Spectrometer</i>
MODIS	<i>MODerate-Resolution Imaging Spectrometer</i>

MS	Materia seca de la parte aérea
MS-Veg	Materia seca de la parte aérea vegetativa
MVC	Máximo valor compuesto
N	Índice de estructura del mesófilo de la hoja
n	tamaño de la muestra
NDVI	Índice de vegetación de la diferencia normalizada
NIR	Banda de infrarrojo cercano
Norg	Contenido de nitrógeno orgánico en el horizonte de humificación
O	Neuronas de la capa oculta
$\overline{\text{obs}}$	Promedio de la variable observada
obs_i	Variable observada
PAR	Radiación Fotosintéticamente Activa
pH	Potencial hidrógeno
phobase	Fotoperíodo base
phosat	Fotoperíodo de saturación
profhum	Profundidad del horizonte de humificación
PROSAIL	Combinación de los modelos PROSPECT y SAIL
PROSPECT	Modelo de propiedades ópticas de las hojas <i>Leaf Optical Properties Spectra</i>
psoil	Coefficiente de humedad del suelo
R	Banda de color rojo
R²	Coefficiente de determinación
RMSE	Raíz del error cuadrático medio
RTO	Rendimiento del cultivo
RUE	Eficiencia en el uso de la radiación
S	Neuronas de la capa de salida
SAIL	Modelo de transferencia de la radiación del canopy <i>Scattering by Arbitrary Inclined Leaves</i>
Skyl	Fracción de radiación solar difusa respecto de la radiación solar incidente
St_(d)	Suma de temperatura por el método residual, en el día d, a partir de la emergencia
stamflax	Grados días entre la máxima tasa de crecimiento foliar y el máximo índice de área foliar
stdrpmat	Grados días entre el comienzo de llenado de granos y la madurez fisiológica
STICS	Modelo de cultivo <i>Simulateur multIdisciplinaire pour les Cultures Standard</i>
STICS-f	Modelo de cultivo <i>Simulateur multIdisciplinaire pour les Cultures Standard</i> forzado a utilizar datos de LAI como entrada.
stlaxsen	Grados días entre el máximo índice de área foliar y la senescencia foliar
stlevamf	Grados días entre emergencia y la máxima tasa de crecimiento foliar
stlevdrp	Grados días entre la emergencia y el comienzo de llenado de granos

stsenlan	Grados días entre la senescencia foliar y el índice de área foliar nulo
SWIR	Banda de Infrarrojo de Onda Corta
T_f	Suma de temperatura cuando ocurre la máxima tasa de senescencia del índice de área foliar
T_i	Suma de temperatura cuando ocurre la máxima tasa de crecimiento del índice de área foliar
tto	Ángulo cenital de vista
tts	Ángulo cenital del sol
tts	Ángulo acimutal relativo
VI	Índices de vegetación
w_j	Pesos que conectan a las neuronas de la capa oculta con las de la capa de salida
w_{ji}	Pesos que conectan a las neuronas de entrada con las de la capa oculta
ρ_{dλ}	Reflectancia del suelo seco
ρ_{sλ}	Reflectancia del suelo
ρ_{wλ}	Reflectancia del suelo completamente húmedo

INTRODUCCIÓN

La soja es el cultivo más importante en Argentina, tanto por la superficie sembrada como por los réditos económicos que le genera al productor agrícola y al estado nacional. En la campaña 2015/16 se sembraron a nivel nacional 20.602.542 ha. En la provincia de Córdoba, para esa campaña, la superficie sembrada alcanzó las 5.579.530 ha; lo que representa alrededor del 80% del área provincial cultivada con granos. El área sembrada con soja en el departamento Río Segundo es 325.986 ha con un rendimiento promedio de 3,39 Mg.ha⁻¹ (MAGyP, 2016).

El monitoreo de los cultivos agrícolas durante su ciclo vegetativo puede proveer información para realizar predicciones del rendimiento con bastante antelación al momento de cosecha. Esto es importante para la toma de decisión en distintos niveles, tanto para actividades logísticas como para actividades comerciales (Bach 1998; Bingfng & Chenglin, 2000; Clevers *et al.*, 2002; Lobell *et al.*, 2003; Lobell & Asner, 2004; Rizzi & Rudorff 2005).

La estimación de la productividad de la soja es un dato estratégico a nivel regional para la planificación del almacenaje y transporte. A nivel nacional, constituye una valiosa información para establecer los posibles saldos exportables (Ravelo *et al.*, 2003).

Actualmente, la producción agrícola en la provincia de Córdoba, Argentina se estima a partir de un relevamiento de productores para determinar el área sembrada y el rendimiento del distrito. Estos métodos son laboriosos, necesitan disponer de personal de campo a nivel regional, y no producen resultados con la rapidez requerida por los mercados (Rosenthal *et al.*, 1998).

Rosenthal *et al.* (1998) usaron un enfoque distinto: combinaron tecnologías de sistemas de información geográfica con modelos de simulación de cultivos para determinar la producción regional de sorgo granífero en Australia y de mijo en África.

1.1. Modelos de Cultivos

Los modelos de cultivos simulan los procesos biofísicos en el sistema suelo-planta-atmósfera para proveer una descripción continua del crecimiento y desarrollo del cultivo. Existen diversas ópticas para el modelado de cultivos en función de los distintos objetivos, disponibilidad de datos y experiencia profesional de los investigadores (Tharakan *et al.*, 2000). Dichos objetivos pueden ser desde suministrar información básica para la planificación y la toma de decisiones por parte de los productores hasta ayudar a los científicos a definir las prioridades de investigación (Dourado-Neto *et al.*, 1998). Uno de los principales objetivos de los modelos de simulación de cultivos es estimar la producción agrícola como una función dependiente de las condiciones meteorológicas y edáficas, como así también del manejo del cultivo (Hoogenboom, 2000).

De acuerdo con la base conceptual y la estructura interna del modelo, se puede distinguir entre modelos empíricos, y modelos de procesos o mecanísticos. Los modelos empíricos utilizan principalmente el análisis estadístico para interpretar y describir datos sobre crecimiento y la producción de la biomasa en una gran cantidad cultivos. Con este tipo de modelos sólo se pueden hacer predicciones para otros cultivos que crecen bajo condiciones similares (Mohren & Burkhart, 1994).

Los modelos mecanísticos, por otra parte, se sustentan en un sistema de componentes funcionales y en sus interacciones con el ambiente del sistema para predecir el comportamiento de un cultivo. Los componentes funcionales se eligen en un nivel específico de jerarquía, generalmente por debajo del nivel del sistema completo (Makela *et al.*, 2000). Estos modelos describen la relación entre los procesos fisiológicos de las plantas tales como la intercepción de la luz, la fotosíntesis, la respiración y la evapotranspiración, con los factores ambientales tales como la radiación solar, la temperatura y la disponibilidad de agua y nutrientes (Bourdôt *et al.*, 1999; Prusinkiewicz, 2004).

Los modelos mecanísticos simulan periódicamente el crecimiento y desarrollo de los cultivos, estimando los flujos y balances de carbón, nitrógeno, agua y energía entre los diversos componentes, para finalmente obtener una estimación del rendimiento en el momento de maduración del cultivo (Bourdôt *et al.*, 1999; Tharakan *et al.*, 2000; Prusinkiewicz, 2004). Estos modelos son altamente complejos y resultan difíciles de documentar y mantener. Para salvar estos inconvenientes, quienes modelan el crecimiento y desarrollo de los cultivos han adoptado estructuras modulares (Jones *et al.*, 2001).

Jégo *et al.* (2010) emplearon el modelo *Simulateur multIdisciplinaire pour les Cultures Standard* (STICS) para estimar el índice de área foliar (LAI), biomasa y rendimiento regional de trigo y soja en el este de Canadá. Mercau *et al.* (2007) utilizaron el modelo CROPGRO-soybean para predecir fenología, biomasa y componentes del rendimiento de soja a través de diferentes condiciones ambientales de la región pampeana de Argentina.

La mayoría de los modelos de productividad de los ecosistemas, como así también los modelos de balance de carbón y modelos globales de clima, hidrología y bioquímica requieren de parámetros biofísicos para calcular la fotosíntesis, la evapotranspiración y la productividad primaria neta (Running & Gower, 1991; Potter *et al.*, 2003). Entre esos parámetros se encuentran el LAI, el porcentaje de cobertura vegetal (%C) y la fracción de radiación fotosintéticamente activa absorbida por la vegetación (*f*APAR). El porcentaje de cobertura vegetal, también es empleado en muchos modelos de transferencia entre el suelo, la vegetación y la atmósfera; y en modelos de balance superficial de energía, dado que separan a los paisajes en áreas cubiertas con vegetación y áreas de suelo desnudo (Glenn *et al.*, 2008). El %C también ha sido utilizado para el modelado del clima regional y global y el monitoreo del cambio climático global (Jiménez-Muñoz *et al.*, 2009).

El LAI es una variable estructural del canopeo definido como el área de una de las caras de las hojas verdes por unidad de área de suelo, especialmente en canopeos de hojas anchas (Myneni *et al.*, 2002). Por su parte, la *f*APAR es una variable radiométrica que representa la proporción de la radiación solar que es absorbida, por las hojas verdes,

respecto del total que es recibido, en la porción del espectro electromagnético comprendido entre 0,4 – 0,7 micrómetros. Este rango corresponde a la parte visible del espectro de radiación y es la que resulta fotosintéticamente activa (PAR) (Fensholt *et al.*, 2004; Maas & Rajan, 2008).

En determinaciones a campo $fAPAR$ es generalmente sustituida por la fracción de la radiación fotosintéticamente activa interceptada ($fIPAR$), la cual es calculada a partir de mediciones de PAR por encima y por debajo del canopeo. Generalmente se asume que el 5% de la luz interceptada es reflejada o absorbida por tejidos no fotosintéticos cuando el canopeo está completamente verde (Zhou *et al.*, 2017). En tal sentido Gobron *et al.* (2006) y Pickett-Heaps *et al.* (2014), demostraron que excepto bajo circunstancias particulares, la $fIPAR$ es un buen sustituto de $fAPAR$, dado que las diferencias numéricas entre esos dos flujos, interceptado y absorbido, están frecuentemente confinados dentro de ± 0.1 del rango de precisión de $fAPAR$.

La variación de la radiación fotosintéticamente activa interceptada por el canopeo (IPAR) en la porción del espectro electromagnético comprendido entre 0,4 – 0,7 micrómetros (Fensholt *et al.*, 2004; Maas & Rajan, 2008) es un factor determinante de la fotosíntesis bruta diaria, mientras que la variación de la respiración autotrófica es determinada por cambios en la biomasa de las hojas, tallos y raíces y de sus tasas de respiración. La radiación diaria fotosintéticamente activa interceptada por el canopeo del cultivo (IPAR, $MJ\ m^{-2}$) puede calcularse según la siguiente expresión (Maas, 1993):

$$IPAR = \beta R(1 - e^{-k \cdot LAI}) \quad (1)$$

Siendo β la fracción de la radiación total que corresponde a PAR (aproximadamente 0,45), R la radiación solar diaria ($MJ\ m^{-2}$) y k el coeficiente de extinción específico del cultivo.

El coeficiente de extinción en canopeos vegetales de acuerdo a Ross (1981) resultaría independiente de la longitud de onda, considerando el tamaño de los elementos de dispersión (hojas, ramas, tallitos, etc.) con respecto a la longitud de onda de la radiación solar (Myneni *et al.*, 2002).

Una aproximación que emplean los modelos de cultivo para estimar la tasa diaria de acumulación de carbono por unidad de área fue propuesta por Monteith (1977), en la cual la tasa de acumulación de carbono es expresada como el producto entre la radiación solar interceptada y de la eficiencia en el uso de la radiación (Choudhury, 2000; Solorio Elizalde *et al.*, 2008).

$$\frac{\partial W}{\partial t} = RUE \cdot fIPAR \cdot \beta \cdot R \quad (2)$$

donde $\frac{\partial W}{\partial t}$ es la tasa de cambio de la materia seca en función del tiempo y RUE es la eficiencia en el uso de la radiación.

Asumiendo que la tasa de producción de biomasa por unidad de radiación interceptada a través de toda la estación de crecimiento, así como la irradiancia son constantes, y que el área foliar es proporcional a la biomasa total, Goudriaan & Monteith (1990) derivaron una ecuación para la biomasa del cultivo (W) dependiente del tiempo (t), como una función de la tasa de crecimiento relativa máxima (Rm) y de la tasa de crecimiento absoluta máxima (Cmax).

$$W(t) = \left(\frac{C \max}{Rm} \right) \left[\ln \left\{ 1 + \left[\frac{fIPAR_0}{1 - fIPAR_0} \right] \exp(Rm \cdot t) \right\} \right] \quad (3)$$

donde $fIPAR_0$ es la fracción de radiación incidente que es interceptada por el canopeo del cultivo ($IPAR \cdot (\beta R)^{-1}$) en el tiempo $t=0$. La ecuación (3) es apropiadamente descripta como expo-lineal debido a que la biomasa se incrementa exponencialmente en los momentos iniciales y linealmente en etapas intermedias (Monteith, 2000).

Los modelos de cultivos pueden ser herramientas útiles para la estimación de rendimientos regionales. Sin embargo, estos modelos requieren disponer de los parámetros y/o de las condiciones iniciales para cada situación. Esta información puede variar considerablemente de un lote a otro, y generalmente no está disponible (Duke & Guérif, 1998; Guérif & Duke 2000).

1.2. Teledetección

La teledetección, particularmente en el dominio óptico, brinda información espacial extensiva del estado real de los cultivos (Maas, 1988; Guérif & Duke, 2000; Dadhwal, 2003; Lobell *et al.*, 2003; Doraiswamy *et al.*, 2004). La teledetección se ha empleado para apoyar la parametrización de los modelos; por ejemplo, acoplando un modelo de transferencia radiativa con un modelo de simulación de cultivos, a través de una variable que representa la estructura del canopeo, tal como el índice de área foliar (LAI) (Guérif & Duke, 2000).

La teledetección tiene la ventaja que puede producir imágenes multitemporales en intervalos frecuentes, lo cual facilita el monitoreo del crecimiento y desarrollo de la vegetación en un área determinada (Ahmadi 2009).

El vocablo teledetección deriva del francés “*téledétection*”, traducción dada en 1967 al término anglosajón “*remote sensing*” o percepción remota. Definir el concepto de teledetección no es sencillo ya que no existe una definición única universalmente aceptada. En su más amplio sentido se entiende por percepción remota “la adquisición de información sobre un objeto a distancia, esto es, sin que exista contacto material entre el objeto o sistema observado y el observador”. La teledetección parte del principio físico de la existencia de una perturbación (energía electromagnética, campos gravitacionales, ondas sísmicas, etc.) producida en el medio por el sistema observado, la cual se transmite al sistema receptor para ser registrada, almacenada y, posteriormente, interpretada. La transferencia de radiación electromagnética es la interacción física más estudiada en la teledetección (Chuvienco, 2000). Todos los cuerpos reflejan o emiten los flujos energéticos bajo la forma de radiación. La variación relativa de la energía reflejada o emitida en

función de la longitud de onda, constituye lo que se denomina su firma espectral. Cada tipo de cubierta superficial tiene una curva de emisividad y reflectividad espectral característica. La teledetección tiene por objeto la determinación de los materiales y los fenómenos que tienen lugar en la superficie terrestre, a través de su firma espectral y permite estudiar las variaciones espectrales, espaciales y temporales de la superficie terrestre (Chuvieco, 2000).

Con la aparición de satélites como plataforma para sensores de radiación electromagnética se logró obtener imágenes, en distintas longitudes de onda de grandes superficies. Estas imágenes pueden combinarse con información espacial proveniente de otros medios (suelos, información meteorológica, etc.) para constituir un sistema de información geográfica (Maracchi *et al.*, 2000).

Existen dos metodologías para estimar el rendimiento de un cultivo con sensores remotos. El primero consiste en un procedimiento directo en el cual las predicciones son derivadas directamente de las mediciones obtenidas por teledetección. El segundo método, denominado indirecto, incorpora datos provenientes de la teledetección en un modelo de simulación de cultivos para controlar las salidas del modelo (LAI, biomasa, etc.) o, mediante un mecanismo de retroalimentación, ajustar las condiciones iniciales del modelo (Basso *et al.*, 2010).

Las imágenes del satélite NOAA AVHRR se emplearon tradicionalmente para estimar o predecir rendimientos de cultivos usando métodos de correlación estadísticos (Fuqin & Guoliang, 1991; Hochheim & Barber, 1998; McNairn & Brown, 1999; Bingfng & Chenglin, 2000; Ravelo *et al.*, 2003; Kastens *et al.*, 2005, Seiler *et al.*, 2007). Groten (1993) demostró que los valores del índice de vegetación de la diferencia normalizada (NDVI) acumulados estacionalmente se correlacionaron con los rendimientos de cultivos reportados en regiones semiáridas. Doraiswamy & Cook (1995) señalaron que los valores de NDVI acumulados para el trigo de primavera durante el período de llenado de granos mejoraron la estimación del rendimiento potencial del cultivo en Dakota del Norte (EEUU). Este procedimiento produce ecuaciones de regresión específicas del sitio para predecir el rendimiento del cultivo. Además, la relación entre rendimiento y NDVI puede

no ser adecuada en condiciones meteorológicas extremas. Por último, la diferencia entre condiciones muy buenas y promedio de cultivos son enmascaradas por el efecto de saturación del NDVI. A partir de los datos del satélite NOAA AVHRR, la relación pierde sensibilidad, con valores por encima de 0,6 para maíz y soja (Doraiswamy *et al.*, 2004). Ren *et al.* (2008) emplearon la acumulación de NDVI de MODIS a nivel de condado para estimar el rendimiento de trigo en China. Povkh *et al.* (2005) emplearon índices de vegetación de imágenes MODIS para estimar el rendimiento de trigo en Rusia mediante regresiones lineales. Ma *et al.* (2001) estimaron el rendimiento de soja a partir de valores de NDVI medido en R5 con un radiómetro a campo, y encontraron que las condiciones de cultivo, como así también los distintos cultivares podían modificar la relación entre el índice de vegetación y el rendimiento.

Prasad *et al.* (2006) estimaron el rendimiento de soja en Iowa, USA, mediante el empleo de regresiones múltiples de AVHRR- NDVI, humedad del suelo, temperatura de la superficie y precipitaciones. La resolución espacial de 1 km del NOAA-AVHRR también es un factor limitante en la exactitud de la obtención de parámetros biofísicos específicos del cultivo, tanto a escala de lote como a escala regional (Doraiswamy & Cook 1995). La resolución espacial (250 m) y temporal (diaria) de los datos de MODIS ofrecen un gran potencial para la obtención de parámetros biofísicos del cultivo, y mejoró la precisión de la estimación del rendimiento de los cultivos (Doraiswamy *et al.*, 2004). A pesar que los datos del satélite LANDSAT TM, en razón de su resolución espacial (30 m), podrían ser más adecuados en áreas donde los lotes son pequeños, su baja frecuencia temporal y la posibilidad de cobertura nubosa durante sus pasadas poco frecuentes, limitan la obtención de parámetros biofísicos del cultivo, los que cambian morfológica y fisiológicamente durante la estación de crecimiento (Doraiswamy *et al.*, 2004). El empleo de sensores de resolución espacial media a alta, tales como Landsat TM o SPOT-XS, permiten la detección de buena parte de la variación espacial de las características de la vegetación, aunque la falta de suficiente resolución temporal dificulta el monitoreo de la dinámica del desarrollo fenológico de la vegetación (Busetto *et al.*, 2008).

1.3. Índices de Vegetación

Varios índices de vegetación (VI) fueron desarrollados y empleados en las últimas décadas para estimar las propiedades biofísicas del canopeo, tendiente a relacionar las reflectancias de hojas o de canopeos con sus características (Danson *et al.*, 2003; Jiang *et al.*, 2006; Hatfield *et al.*, 2008). Esos índices combinan la reflectancia espectral de dos o más bandas espectrales, generalmente del rojo (R) e infrarrojo cercano (NIR). La base de esta relación es la fuerte absorción de la banda roja por la clorofila y la baja absorción en el NIR por las hojas verdes (Shanahan *et al.*, 2001). A nivel del canopeo, las reflectancias son mayores en las longitudes de onda del NIR a medida que transcurre el ciclo del cultivo, debido al incremento de la biomasa (Hatfield *et al.*, 2008).

La mayoría de los VI pueden clasificarse en cinco categorías (Lu *et al.*, 2015):

1. Reflectancia de una sola banda o índices de diferencias entre bandas simple (SD) (Ej. R_{680} o $1/R_{550} - 1/R_{750}$)
2. Índices de cocientes simples (SR) (Ej. R_{672}/R_{550})
3. Índices de diferencia normalizada (ND) (Ej. NDVI: $(R_{800} - R_{650}) / (R_{800} + R_{650})$)
4. Índices que utilizan las derivadas de las reflectancias (Ej. D_{730})
5. Otras formas de índices (Ej. $R_{705} / (R_{717} + R_{491})$).

Donde los valores de los subíndices indican la longitud de onda (nm) de las reflectancias.

Una forma de emplear datos de satélites para calibrar un modelo de simulación de rendimiento de un cultivo fue descrita por Maas (1988). Maas (1993) al establecer una relación entre NDVI y LAI, pudo ajustar las variables de estado del modelo durante el período de simulación para asegurar la concordancia entre los valores de LAI estimados por el modelo y los obtenidos a partir de la información del satélite. La limitación de este enfoque es que la relación entre el NDVI del canopeo y el LAI puede no ser consistente a través del área de estudio debido a diferencias en las características del suelo, población de plantas y otros factores (Doraiswamy *et al.*, 2004). En tal sentido, los sensores ópticos pueden proveer la información sobre el estado actual del cultivo a través de la estación de

crecimiento para calibrar un modelo de crecimiento a escala del lote (Clevers, 1988; Bouman, 1991). Hadria *et al.* (2006) estimaron el rendimiento regional de trigo en una región semiárida de Marruecos, empleando estimaciones de LAI obtenidas a partir de valores de NDVI en combinación con el modelo de cultivo STICS.

Tanto el LAI como $fAPAR$ pueden estimarse a partir de datos provenientes de satélites empleando relaciones empíricas entre ambos valores e índices de vegetación, los cuales incluyen, entre otros, al cociente entre las bandas R y NIR y el NDVI (Asrar *et al.*, 1984; Chen & Chilar, 1996; Colombo *et al.*, 2003). En tal sentido, Daughtry y colaboradores (1992) presentaron una relación lineal entre $fAPAR$ y NDVI para soja cultivada con distintos espaciamientos entre surcos. Montico & Di Leo (2002) estimaron la producción primaria neta potencial para el cultivo de soja en Santa Fé, Argentina, empleando una relación lineal entre $fAPAR$ y NDVI.

Sin embargo, inversamente a $fAPAR$, que depende de las condiciones de iluminación, %C es una variable intrínseca del canopy que depende solamente de los atributos estructurales del canopy (principalmente LAI, distribución del ángulo foliar y el agrupamiento) (Bacour *et al.*, 2006). Gitelson *et al.* (2002a) encontraron una relación lineal entre %C de trigo con un índice obtenido a partir de la reflectancia en rojo y verde, en tanto que reportaron una relación en donde el NDVI tiende a permanecer con valores constantes cuando %C es mayor o igual que 50%. Para soja, Gitelson (2004) determinó un comportamiento similar del NDVI cuando el %C era mayor o igual que 60%. Jiang y colaboradores (2006) sostienen que la relación entre NDVI y %C puede ser no lineal dependiendo de los diferentes tipos de suelos, en tanto que Lu *et al.* (2005) informaron diferentes relaciones no lineales entre NDVI y %C para variedades de trigo con hojas horizontales y erectas. Purevdorj & Tateishi (1998) presentaron regresiones de segundo grado para estimar %C de pasturas en función de distintos VI, incluyendo el NDVI.

El porcentaje de cobertura y $fAPAR$, presentan una relación cuasi-lineal con las reflectancias (Weiss & Baret, 1999). Por otra parte, la correlación entre la intercepción de la radiación y %C en muchos cultivos, es lo suficientemente elevada como para que esta última variable pueda ser utilizada como un sustituto de la primera (Gitelson *et al.*, 2002 b).

1.4. Modelos de Transferencia Radiativa

Las limitaciones de dichas relaciones empíricas han sido documentadas ampliamente (Gutman, 1991; Price, 1993) debido a que no existe una única relación entre LAI/fAPAR y los índices de vegetación, que se pueda aplicar en cualquier lugar y cualquier momento. Este comportamiento obedece a que las reflectancias de los canopeos de las plantas dependen de un gran número de otros factores tales como la geometría de medición y la resolución espacial (Combal *et al.*, 2002a; Fensholt *et al.*, 2004), el entorno del suelo (Broge & Mortensen, 2002; Montandon & Small, 2008; Houborg *et al.*, 2009) y el espaciamiento y dirección de los surcos (Maas, 2000). De esta forma las relaciones empíricas son específicas del sitio y del sensor, y son inadecuadas para aplicarlas a grandes áreas o en diferentes estaciones (Gobron *et al.*, 1997). Una alternativa superadora se podría implementar a partir de un modelo basado en la física para describir la propagación de la luz en el canopeo y su uso en la estimación de parámetros biofísicos (Tian *et al.*, 2000). Los procedimientos utilizados con este propósito se basan en el empleo de modelos de transferencia radiativa que describen los procesos físicos de la transferencia radiativa en el sistema suelo – vegetación, relacionando las variables biofísicas del canopeo con la reflectancia del canopeo. Estos métodos, a pesar de ser más complejos, resultan más abarcativos debido a que tienen en cuenta diferentes fuentes de variabilidad (González-Sanpedro *et al.*, 2008).

Las estimaciones de las variables del canopeo (LAI, contenido de clorofila, contenido de agua de las hojas, cobertura, etc.) se utilizan en distintas áreas de la agricultura, para la detección de cambios eco-fisiológicos o en el balance de energía global. Por su parte, la teledetección es útil a esas aplicaciones debido a su capacidad de proveer observaciones en un gran rango de escalas espaciales y temporales (Combal *et al.*, 2002a).

La reflectancia del canopeo está fuertemente relacionada con variables del cultivo, tales como LAI y contenido de clorofila (Myneni *et al.*, 1995; Yoder & Pettigrew-Crosby, 1995; Verstraete & Pinty, 1996). La reflectancia del canopeo también tiene una gran dependencia de las condiciones de medición, como la geometría entre la vista del sensor y el sol, y la longitud de onda (Combal *et al.*, 2002 a y b). La configuración geométrica de las observaciones varía continuamente en función del tiempo y el lugar.

Si bien los modelos de transferencia radiativa tridimensionales son más realistas, su implementación es muy difícil porque requieren de muchas parametrizaciones y son poco eficientes computacionalmente. Los modelos de transferencia radiativa unidimensionales se ejecutan más rápidamente y son más accesibles para la generación de una base de datos (Bacour *et al.*, 2006). El modelo SAIL (*Scattering by Arbitrary Inclined Leaves*) quizás sea el modelo de transferencia radiativa más difundido (Verhoef, 1984, 1985). El éxito de este modelo se basa, además de su código simple y rapidez de cálculo, en que estima convenientemente las reflectancias de cultivos homogéneos. La combinación del modelo PROSPECT de propiedades ópticas de las hojas y el modelo de reflectancia bidireccional de canopy SAIL, denominada en conjunto PROSAIL, se ha empleado en forma generalizada para estudiar la reflectancia espectral y direccional del canopy vegetal. El modelo PROSAIL también se ha utilizado para desarrollar nuevos métodos para estimar parámetros biofísicos de la vegetación (Jacquemoud *et al.*, 2009).

Los parámetros de entrada para el modelo SAIL son el LAI, propiedades ópticas de la hoja, arquitectura del dosel, reflectancia del suelo y la geometría sol-objetivo-sensor. Estos datos de entrada se pueden medir o estimar. La inversión del modelo SAIL, permite predecir LAI cuando se dispone de valores de reflectancia del dosel a partir de mediciones provenientes de la teledetección (Doraiswamy *et al.*, 2005).

La inversión del modelo de transferencia consiste en ajustar el valor de las variables de entrada correspondientes a las características biofísicas del canopy, de modo tal que los factores de reflectancia bidireccional (BRFs) simulados con el modelo de transferencia radiativa concuerden de la mejor manera con los BRFs medidos por el sensor en un rango de direcciones y longitudes de onda. La solución del problema inverso consiste en encontrar un estimador de las variables biofísicas a partir de la radiación medida por el sensor. Sin embargo, el problema inverso está mal definido debido a que la solución no es necesariamente única, además los errores de medición y las incertidumbres del modelo pueden llevar a grandes variaciones en la solución inversa del problema (Combal *et al.*, 2002b).

1.5. Redes Neuronales Artificiales

La inversión tradicional de los modelos de transferencia radiativa del canopy emplea una técnica de optimización (Goel, 1989) para estimar varios parámetros a partir de la minimización de una función de mérito. Para encontrar el estimador óptimo de esos parámetros es necesario un proceso interactivo. En cada paso, es importante determinar la dirección de la interacción y la longitud de la interacción. (Gong *et al.*, 1999). Kimes *et al.* (2000) hicieron una revisión de tres enfoques diferentes empleados en la inversión (algoritmos de optimización, tablas de correspondencia (LUT) y redes neuronales) para estimar los parámetros biofísicos a partir de datos de reflectancia provenientes de satélites analizando las diferentes mejoras que pueden aprovecharse, con respecto a cada uno de ellos. En esa revisión, las LUT y las redes neuronales aparecen como herramientas promisorias para diseñar algoritmos operacionales para la estimación de parámetros biofísicos.

Las redes neuronales son estructuras de neuronas unidas por nodos que transmiten información a otras neuronas, las cuales dan un resultado a través de funciones matemáticas (Hilera & Martínez, 2000). En una red neuronal del tipo *backpropagation* se requiere de un mínimo de tres capas de neuronas: la capa de entrada, la capa oculta y la capa de salida. Las capas de entrada y de salida contienen una cantidad de neuronas que corresponden a las variables de entrada y salida, respectivamente. Los datos se mueven desde la capa de entrada a la capa de salida a través de conexiones ponderadas por pesos.

Las redes neuronales aprenden de la información existente a partir de un entrenamiento, proceso por el cual esos pesos son ajustados, de modo tal que provean de una salida próxima al valor observado. El número de neuronas de la capa oculta determina el número de conexiones entre las neuronas de entrada y de salida. El número de neuronas de la capa oculta puede variar dependiendo del problema específico a solucionar. Durante el aprendizaje, se aplica una función de transferencia a través de una serie de iteraciones. El entrenamiento termina cuando el error entre los valores predichos y los observados es arbitrariamente pequeño. Una vez que la red converge, se desarrolla una función que es utilizada para futuras predicciones. De esta forma, la red adquiere la capacidad de estimar

respuestas correspondientes al mismo fenómeno. Finalmente, la red entrenada se valida a partir de un conjunto de datos independientes.

Para resolver el problema asociado a la mala definición en la inversión del modelo de transferencia radiativa, se emplea por lo general información previa. En este sentido recientemente se comenzaron a utilizar redes bayesianas dado que permiten una incorporación significativa y rigurosa de todos los recursos en la solución del problema inverso (Davis *et al.*, 1995; Combal *et al.*, 2002b; Kalácska, *et al.*, 2005; Qu *et al.*, 2008).

Kallel *et al.* (2007) asumiendo que la vegetación es un medio turbio y que por lo tanto existe una relación uno a uno entre LAI y %C, invirtieron el modelo SAIL para estimar %C a partir de reflectancias observadas, obteniendo mejores resultados que cuando se estimó %C a partir de índices de vegetación clásicos.

Yi *et al.* (2008) invirtieron el modelo SAIL para estimar valores de LAI de trigo a partir de reflectancias de MODIS – AQUA y TERRA de las colecciones 4 y 5 y encontraron que los datos diarios de la colección 5 fueron mejores para la estimación del LAI, y que la precisión mejoraba si se empleaban datos de compuestos de 8 días.

Launay & Guerif (2005) asimilaron imágenes del *Satellite Pour l'Observation de la Terre* (SPOT) y fotografías aéreas con el modelo de cultivo SUCROS acoplado con el modelo de transferencia radiativa SAIL para estimar el rendimiento de remolacha azucarera. Liang *et al.* (2004) asimilaron los productos MODIS LAI y MODIS *enhanced vegetation index* (EVI) con el modelo de cultivo DSSAT para estimar el rendimiento regional de maíz. Wang *et al.* (2005) compararon la firma espectral observada de un cultivo de trigo con una firma simulada que se obtuvo al acoplar el modelo de cultivo DSSAT con el modelo de transferencia radiativa PROSAIL.

Smith (1993) empleó una red neuronal artificial del tipo *backpropagation* entrenada con un modelo simple de dispersión múltiple para estimar el LAI a partir de imágenes de LANDSAT TM que contenían reflectancias próximas al nadir de seis bandas. De manera

similar, Bacour y colaboradores (2006) emplearon un perceptrón multicapa para estimar la fracción de la radiación fotosintéticamente activa absorbida, el porcentaje de cobertura del cultivo, en índice de área foliar y el contenido de clorofila a y b a partir de la información de reflectancia de 11 bandas de sensor *MEdium-spectral Resolution, Imaging Spectrometer* (MERIS) y los tres ángulos que definen la geometría de observación.

Baret y colaboradores (1995) estimaron %C a partir de índices de vegetación y de la inversión del modelo SAIL con una red neuronal *backpropagation*. A tal efecto utilizaron valores de reflectancias correspondientes a bandas roja y NIR obtenidos a partir de espectrómetros manuales sobre parcelas experimentales de remolacha azucarera.

Dada la falta habitual de recursos para realizar medidas de campo de los parámetros biofísicos de los cultivos, se propone en la presente tesis explorar las posibilidades de mejorar las estimaciones de productividad del cultivo de soja a escala de lote, aunando la información provista por la teledetección con la suministrada por los modelos de simulación.

Hipótesis

La hipótesis de esta tesis se basa en que la combinación de datos captados desde el satélite en las bandas del visible e infrarrojo cercano del espectro electromagnético, junto con información meteorológica y de manejo del cultivo, permite que un modelo de cultivo, luego de ser calibrado, estime con precisión diferentes parámetros biofísicos del cultivo de soja en la región central de Córdoba, Argentina.

OBJETIVO GENERAL

El objetivo principal de este estudio fue desarrollar una metodología que permita predecir parámetros biofísicos del cultivo de soja, aprovechando las ventajas del empleo de información proveniente de la teledetección y del uso de un modelo mecanístico de cultivo.

OBJETIVOS ESPECÍFICOS

- Evaluar el potencial de emplear información satelital proveniente del sensor MODIS para estimar los parámetros biofísicos del canopeo del cultivo de soja mediante distintos procedimientos.

- Valorar el desempeño del modelo de cultivo STICS para simular variables agronómicas en el cultivo de soja.

- Evaluar la mejora en las estimaciones del modelo de cultivo cuando es forzado a tomar valores de LAI obtenidos a partir del sensor MODIS.

ESTRUCTURA DE LA TESIS

En el intento de alcanzar los objetivos específicos propuestos, la presente tesis se ha organizado en diferentes capítulos, los cuales serán descriptos sucintamente en este apartado.

En el capítulo 2 se realiza una descripción del área de estudio, considerando la ubicación de los establecimientos donde se efectuaron las mediciones agronómicas, también se detallan las características climáticas, edáficas, fisiográficas y productivas de la región, también se detallan las metodología de medición de los diferentes parámetros biofísicos (índice de área foliar, fracción de la radiación fotosintéticamente activa interceptada, porcentaje de cobertura del cultivo, materia seca de la parte aérea y rendimiento) y la determinación del contenido de humedad del suelo. En este capítulo también se realiza una descripción de los datos satelitales utilizados, del modelo de transferencia radiativa PROSAIL y de la técnica empleada para la generación de una base de datos simulada con este modelo. Asimismo se detalla la metodología de inversión del modelo PROSAIL mediante el empleo de redes neuronales artificiales, a los efectos de estimar el índice de área foliar a partir de la información satelital, las características de la hoja, la geometría del sensor-sol-píxel observado y de un coeficiente que considera la humedad del suelo. Por último, se presenta al modelo de cultivo STICS con sus principales características y datos de entrada requeridos, como así también los estadísticos que se utilizaron para analizar el desempeño predictivo de los distintos modelos.

En el capítulo 3 y 4 se describen y discuten los resultados obtenidos en la determinación de la cobertura del cultivo, y su relación con la $fIPAR$ y LAI. También se relacionan los valores de NDVI de MODIS con los valores de LAI, $fIPAR$, %C y biomasa de la parte aérea, considerando distintas fases fenológicas del cultivo. En otro apartado se analizan los valores de la base de datos generada a partir del modelo PROSAIL y su relación con los valores de reflectancia medidos por MODIS, específicamente en las bandas correspondientes a azul, rojo e infrarrojo cercano y de NDVI. También se analiza la variación de estos parámetros biofísicos para diferentes valores de LAI. Luego se procedió a la inversión de la base de datos sintética generada por PROSAIL con el empleo de redes neuronales artificiales del tipo perceptrón multicapa, evaluando el desempeño de diferentes

arquitecturas con distintas combinaciones de datos de entrada que consideran características de la hoja, de la geometría del sensor-sol-píxel observado y el coeficiente relacionado con la humedad del suelo. A partir de este análisis, se seleccionó por su desempeño un modelo que considera solamente la reflectancia en las bandas azul, rojo y NIR. Con este modelo de redes neuronales artificiales se procedió a estimar el LAI para los distintos lotes sembrados con soja empleados en este estudio, valores que fueron utilizados como dato de entrada del modelo de cultivo STICS.

Previo al empleo del modelo STICS, se procedió a su calibración determinando diferentes parámetros, asociados con la evolución del área foliar, para los cultivos monitoreados. Luego se efectuaron las corridas del modelo comparando los valores observados y estimados de LAI, MS, contenido de humedad del suelo y rendimiento de todos los lotes en estudio, empleando el modelo de cultivo de manera estándar o forzándolo a tomar los valores de LAI estimados a partir del procedimiento previamente descrito.

Finalmente, el capítulo 5 presenta las conclusiones obtenidas en el presente trabajo de tesis y en el capítulo 6 la bibliografía consultada.

MATERIAL y MÉTODOS

2.1. Descripción del área de estudio

Las mediciones de rendimiento y parámetros biofísicos del cultivo de soja se realizaron en la llanura central de la provincia de Córdoba, Argentina. El área de estudio se encuentra comprendida entre los paralelos 31° 30' S y 31° 50' S y entre los meridianos 64° 00' W y 63° 25' W. Está ubicada en la subregión que se conoce con el nombre de plataforma basculada o pampa alta y presenta un relieve de lomas muy suavemente onduladas, desarrolladas sobre material loésico, de textura franco limosa con escasa pendiente hacia el este (Capitanelli, 1979; Jarsún *et al.*, 2003).

La precipitación anual media varía entre 600 y 900 mm y posee una concentración estival por lo que pertenece al régimen de tipo monzónico, donde el 60% o más de las precipitaciones anuales ocurren en el semestre cálido que comprende los meses desde octubre hasta marzo inclusive (Jarsún *et al.*, 2003). El clima del área de estudio se clasifica de acuerdo a Thornthwaite como sub-húmedo seco (Mather, 1965).

Prácticamente toda la vegetación natural ha sido eliminada, siendo reemplazada, en su gran mayoría, por cultivos de ciclo anual. El área está dedicada principalmente a la producción agrícola y ganadera. En ella predominan los cultivos estivales (soja, maíz, sorgo, maní) y en menor grado los cereales de invierno (trigo) debido fundamentalmente a las características climáticas, sobre todo a la distribución estacional de las precipitaciones (Jarsún *et al.*, 2003).

En la fase de calibración del modelo, se monitorearon diez lotes de soja, con una superficie superior a 50 ha, de forma rectangular, cuyo cociente entre base y altura se aproximó a 1, para ajustarse a la resolución espacial del sensor MODIS. Próximas al área de trabajo se encuentran las estaciones meteorológicas de la EEA INTA Manfredi ($31^{\circ} 49' S$; $63^{\circ} 46' W$; 292 msnm) y de Pilar ($31^{\circ} 41' S$; $63^{\circ} 53' W$; 331 msnm) perteneciente al Servicio Meteorológico Nacional, cuyos datos diarios fueron empleados en el modelo de simulación del cultivo. Los establecimientos se localizaron con el empleo del Sistema de Posicionamiento Global (GPS). La Figura 2.1 presenta la ubicación del área de estudio y de los establecimientos agropecuarios de donde se obtuvieron los datos para simular el crecimiento, desarrollo y rendimiento del cultivo de soja.

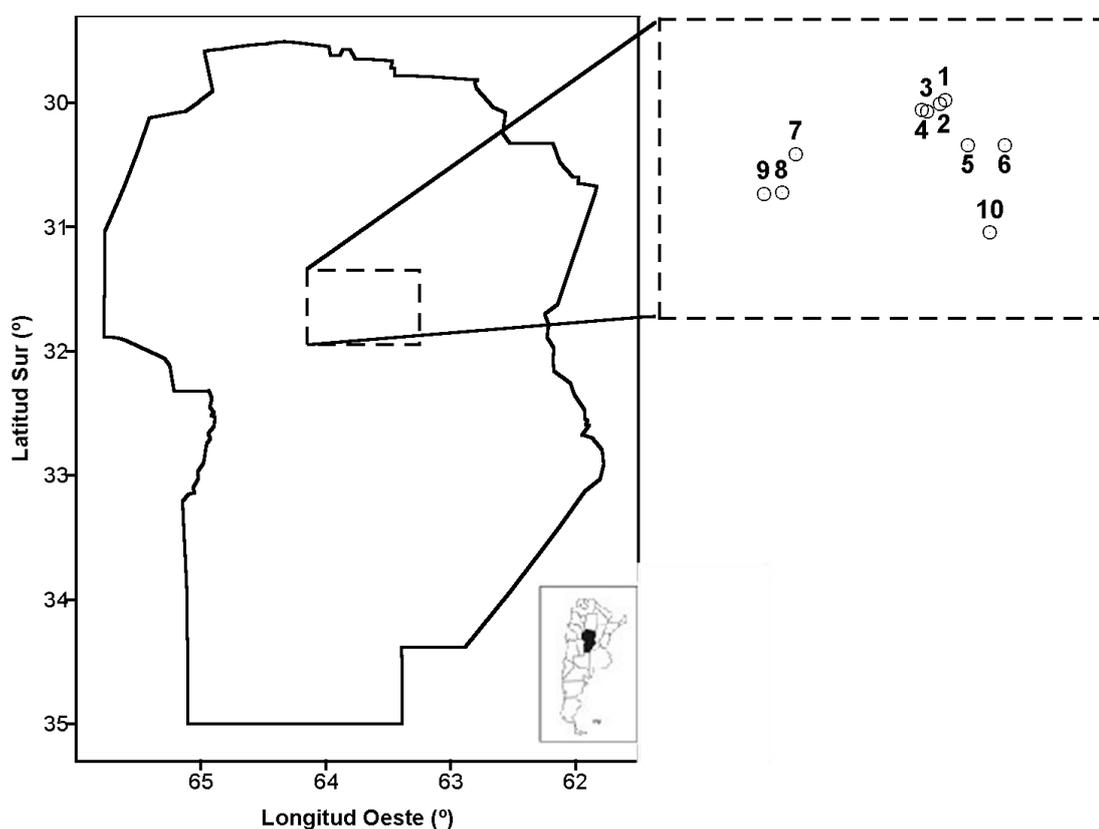


Figura 2.1 Ubicación del área de estudio y de los establecimientos rurales utilizados para simular el crecimiento, desarrollo y rendimiento del cultivo de soja.

2.2. Procedimientos para estimar diferentes parámetros del cultivo de soja.

A modo de resumen, en el siguiente diagrama de flujo (figura 2.2) se muestran los diferentes procesos considerados en el presente trabajo, para la estimación de la humedad del suelo, la materia seca y el rendimiento del cultivo de soja. Posteriormente se describen cada uno de los pasos ejecutados.

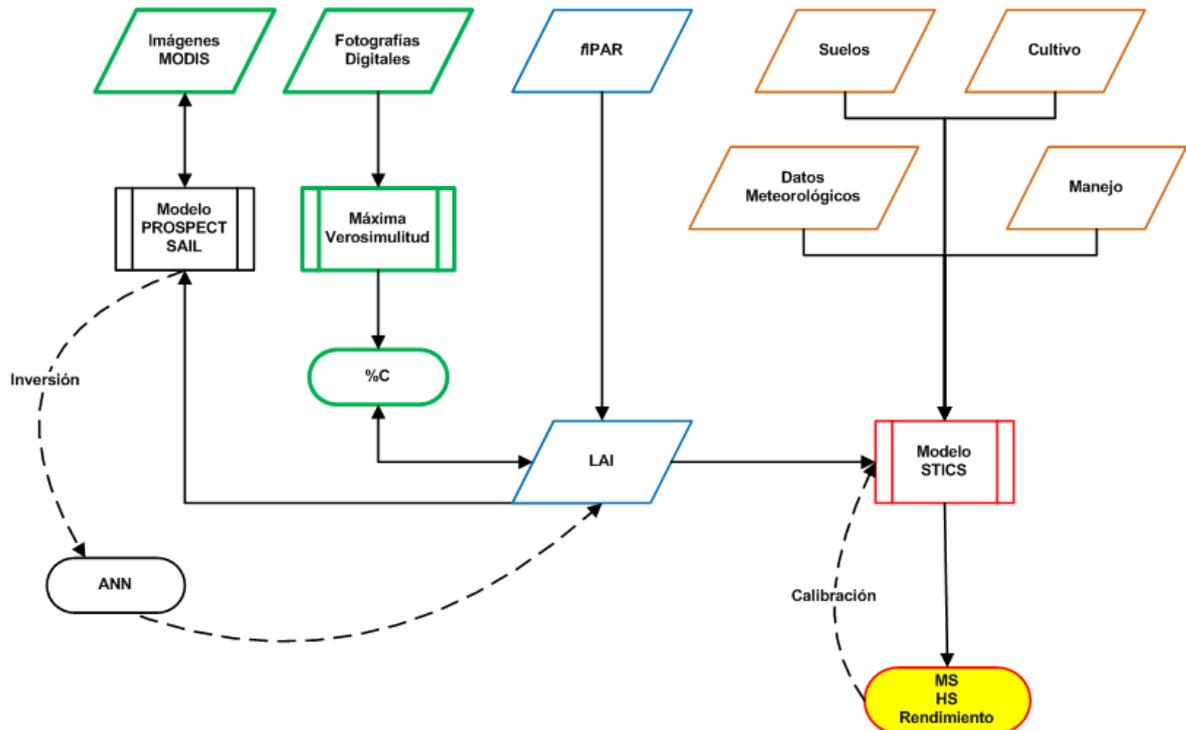


Figura 2.2 Diagrama de flujo de los diferentes procesos empleados para estimar humedad del suelo, materia seca y rendimiento del cultivo de soja.

Referencias:

%C: Porcentaje de cobertura del cultivo

ANN: Redes neuronales artificiales

fPAR: Fracción de radiación fotosintéticamente activa interceptada por la vegetación.

HS: Contenido hídrico del suelo hasta 2m de profundidad

LAI: Índice de área foliar

MS: Materia seca de la parte aérea

PROSPECT: Modelo de propiedades ópticas de las hojas (*Leaf Optical Properties Spectra*)

SAIL: Modelo de transferencia de la radiación del canopy (*Scattering by Arbitrary Inclined Leaves*)

STICS: Modelo de cultivo (*Simulateur multIdisciplinaire pour les Cultures Standard*)

2.3. Caracterización de los suelos de la región

Los suelos de la región se encuentran descriptos en la Carta de Suelo de la Provincia de Córdoba hoja 3163-26 - Villa Del Rosario y hoja 3163-32 – Oncativo (INTA 1987 a y b), entre los cuales resultan más representativos para los distintos lotes la serie Villa del Rosario (Tabla 2.1), la serie Matorrales (Tabla 2.2) y la serie Oncativo (Tabla 2.3).

La serie Villa del Rosario corresponde a un suelo *Haplustol éntico*. Los suelos de esta serie son profundos, de bien a algo excesivamente drenados a partir de sedimentos loessicos de textura franco limosas.

Tabla 2.1 Características de los horizontes de los suelos de la **Serie Villa del Rosario**

Horizonte	Profundidad	Arcilla (%)	Limo (%)	Arena (%)
Ap	0-22	24,5	69,2	6,3
Ac	22-52	24,3	70,6	5,1
Cca	52 a +	22,2	69,2	8,6

La serie Matorrales comprende suelos profundos, moderadamente bien drenados, desarrollados a partir de materiales loésicos, de textura franco limosa, vinculados a un paisaje de planos chatos ligeramente deprimidos.

Tabla 2.2 Características de los horizontes de los suelos de la **Serie Matorrales**

Horizonte	Profundidad	Arcilla (%)	Limo (%)	Arena (%)
Ap	0-21	24,9	69,2	5,9
B2t	21-52	30,3	60,5	9,2
B3	52-76	27,7	65,0	7,3
Cca	76 a +	22,5	69,6	7,9

Los suelos de la serie Oncativo son profundos, bien a algo excesivamente drenados, desarrollados sobre materiales francos limosos que ocupan las lomas muy extendidas, casi planas.

Tabla 2.3 Características de los horizontes de los suelos de la **Serie Oncativo**

Horizonte	Profundidad	Arcilla (%)	Limo (%)	Arena (%)
Ap	0-23	16,7	68,7	14,6
Ac	23-53	12,2	71,1	16,7
Cca	53 a +	10,2	71,9	17,9

Con la información de la textura de los distintos horizontes se generó los valores de capacidad de campo y de punto de marchites permanente mediante el empleo de funciones de pedotransferencia del programa *Soil Water Characteristics V6.02* (Saxton *et al.*, 2006).

2.4. Medición de parámetros biofísicos y del contenido de humedad del suelo

Para ajustar los valores estimados a partir de datos satelitales y calibrar el modelo de simulación del cultivo se obtuvieron, cada tres semanas, registros LAI, *f*IPAR, %C, y MS de tres repeticiones de 1 m² cada una. También se determinó la fase fenológica según la escala de Fehr & Caviness (1977), y el contenido humedad del suelo por gravimetría a 5; 20; 40 y 80 cm de profundidad en cada repetición. La medición del LAI y de *f*IPAR se efectuó con un interceptómetro [PAR/LAI Ceptometer] (Decagon Devices, Pullman, WA, USA) solamente para condiciones del cielo despejado, realizando las lecturas del instrumento dentro del intervalo de una hora aproximadamente en torno al mediodía solar. El LAI se estimó a partir de la medición de *f*IPAR, despejando de la ecuación (1), para lo cual se consideró un coeficiente de extinción para soja de 0,5 (Flenet *et al.*, 1996).

La cobertura se determinó a partir de un procedimiento fotogramétrico basado en la clasificación de imágenes (Ovando *et al.*, 1999; Rodríguez *et al.*, 2000), en tanto que la humedad del suelo y la materia seca de la parte aérea se determinó a partir del peso de las muestras húmedas y del peso seco de las mismas luego de secadas en estufa hasta peso constante. A la madurez del cultivo se determinó el rendimiento del lote.

2.5. Información Satelital

La estimación de los parámetros biofísicos del canopeo se llevó a cabo con información proveniente del sensor MODerate-Resolution Imaging Spectrometer (MODIS) a bordo del satélite AQUA.

El satélite AQUA es del tipo heliosincrónico de órbita polar. Si se considera que el sensor tiene un ancho de barrido de 2330 km y que el periodo orbital del satélite es de casi 100 minutos (por lo que recorre 14,4 órbitas por día), entonces el sensor MODIS requiere menos de dos días para observar toda la superficie de la Tierra.

El sensor MODIS es un barredor óptico que observa a la Tierra a partir de 36 canales, con una resolución espacial que va desde los 250m hasta 1km (Xiong *et al.*, 2003) y se encuentra tanto en el satélite AQUA como en el TERRA. Este sensor brinda la información diaria necesaria para la elaboración de productos integrados. El producto MYD13Q1, incorpora particularmente información de un período de 16 días para producir once parámetros de salida, entre los cuales se encuentran las reflectancias atmosféricamente corregidas en azul (459-479 nm), rojo (620-670 nm), infrarrojo cercano (841-876 nm), infrarrojo medio (1230-1250 nm) y los índices de vegetación (NDVI y EVI), así como sus respectivos datos de control de calidad, todos transformados a una resolución espacial de 250 m. Un análisis más exhaustivo de este producto puede verse en Huete *et al.* (1999).

Se emplearon imágenes del sensor MODIS a bordo del satélite AQUA, en lugar de utilizar las del satélite TERRA, debido a la menor dispersión que presentan sus ópticas, y la mejor respuesta del espejo de barrido respecto del ángulo de barrido (Xiong & Barnes, 2003).

Considerando las falencias del diseño y el funcionamiento de TERRA MODIS, en AQUA MODIS se realizaron mejoras tales como la estabilidad del sistema, la caracterización del *crosstalk*, y la diferencia lateral del espejo. Las diferencias laterales del espejo son extremadamente pequeñas y estables para AQUA MODIS comparadas con TERRA MODIS (Wang *et al.* 2007).

Las imágenes procesadas se obtuvieron a través del sitio *Land Processes Distributed Active Archive Center (LP DAAC) – USGS – EROS Data Center* (<http://lpdaac.usgs.gov/>), georreferenciadas con coordenadas geográficas, para un área con los siguientes límites: 29,85S; 69,23W - 29,89S; 57,50W – 40,04S; 65,05W - 40,0S; 78,32W para los extremos NW, NE, SE y SW, respectivamente (*Escena 12h12v*, Figura 2.3), con proyección sinusoidal.

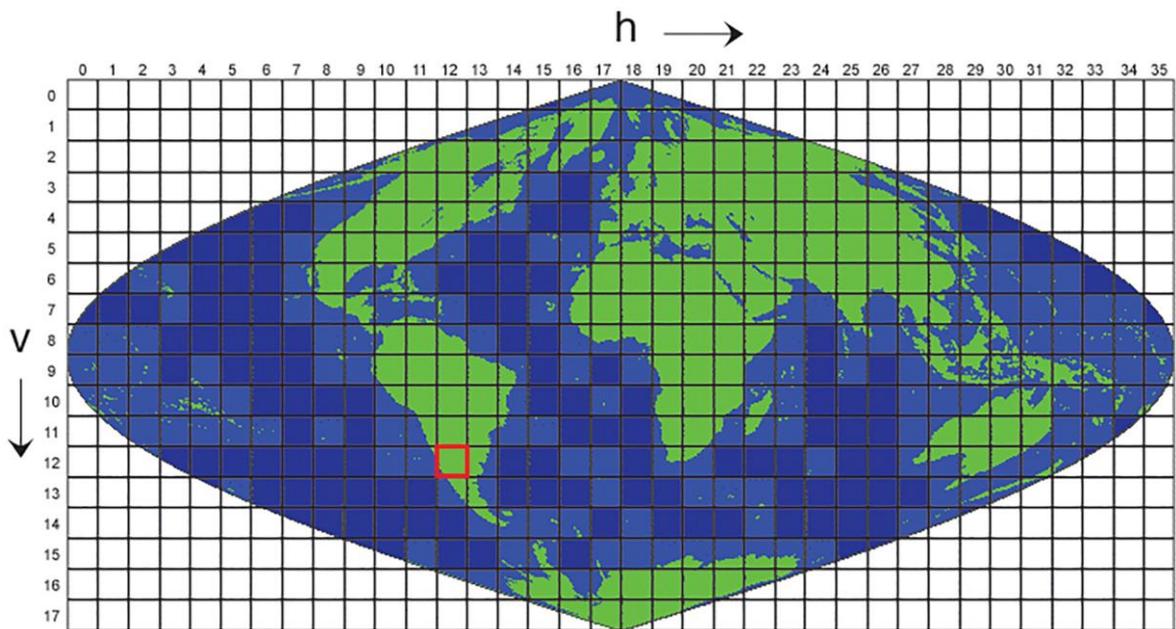


Figura 2.3 Proyección sinusoidal utilizada en las imágenes MODIS/AQUA con horizontales (h) y verticales (v), en el recuadro rojo se muestra la escena v12, h12 que contiene a la zona central de Córdoba.

Se utilizaron un total de 13 imágenes, comprendidas entre las fechas 8/oct/2005 y 30/abr/2006. Estos productos corresponden a la versión 5 cuya precisión ha sido evaluada, validada y aprobada en un amplio conjunto de sitios y períodos de tiempo a través de distintas verdades de campo.

Las mejoras más importantes de la versión 5 están relacionadas con el filtrado de nubes y un método de composición modificado para tratar a las nubes residuales y mal clasificadas. El procedimiento se basa en la metodología del máximo valor compuesto (MVC), donde para cada píxel se selecciona el mayor NDVI dentro del período de 16 días previos hasta la fecha.

Este nuevo método, denominado CV-MVC, se diseñó para limitar las grandes variaciones angulares encontradas por el MVC. El CV-MVC compara los dos valores más grandes del NDVI y selecciona la observación más cercana a la del nadir para representar el valor compuesto de 16 días. En la versión 5, el método CV-MCV utiliza también un criterio contextual para descartar los píxeles vecinos que presentan una importante variación temporal con el fin de aumentar la cohesión espacial de la imagen (García-Mora y Mas, 2011). Estos cambios repercuten positivamente sobre todos los índices de vegetación (Didan & Huete, 2006).

2.6. Modelo de transferencia radiativa PROSPECT + SAIL.

Se generaron valores de reflectancia y transmitancia de las hojas de soja con el modelo PROSAIL V5B (Jacquemoud & Baret, 1990), cuyo código fue traducido a lenguaje IDL (Broadbent, 2010). Este modelo se subdivide los modelos PROSPECT y SAIL que tienen en cuenta las siguientes características como dato de entrada:

2.6.1. Datos de entrada para PROSPECT.

*2.6.1.1. Contenido de clorofila (**Cab**, $\mu\text{g cm}^{-2}$):*

El contenido de clorofila afecta la reflectancia en el visible (400-700 nm) (Jacquemoud *et al.*, 1999; Jacquemoud *et al.*, 2000; Bacour & Jacquemoud, 2001). Los valores de **Cab** en soja varían desde $8 \mu\text{g cm}^{-2}$ para cultivos jóvenes (en las fases VC-V1) (Pinheiro Ferri *et al.*, 2004) creciendo a $34 \mu\text{g cm}^{-2}$ cuando el cultivo alcanza la plenitud

(Jacquemoud & Baret 1990); y se reduce a $6 \mu\text{g cm}^{-2}$ en madurez (fase R7) (Pinheiro Ferri *et al.*, 2004). Asimismo, Chappelle (1992) informó valores de **Cab** en soja de invernadero desde 14,32 a $124,76 \mu\text{g cm}^{-2}$, en tanto que Marengo & Lopes (1994) presentaron valores de **Cab** para soja en invernadero entre $22,3 \mu\text{g cm}^{-2}$ y $39,9 \mu\text{g cm}^{-2}$. Gitelson *et al.* (2005) midieron **Cab** en soja a campo desde 0 a $200 \mu\text{g cm}^{-2}$ en tanto que Gitelson *et al.* (2006) para soja informaron un rango de **Cab** desde 0,244 a $91,8 \mu\text{g cm}^{-2}$.

2.6.1.2. Contenido de carotenoides (**Car**, $\mu\text{g cm}^{-2}$):

Los pigmentos de clorofila a y b absorben fuertemente en las longitudes de onda del rojo y azul, en tanto que los carotenoides lo hacen principalmente en el azul (Baret, 1991). Chappelle (1992) informó valores de **Car** para soja en invernadero desde 5,12 a $20,8 \mu\text{g cm}^{-2}$.

2.6.1.3. Contenido de pigmentos marrones (**Cbrown**, adimensional):

Los pigmentos marrones aparecen con la senescencia de la hoja y absorben con una intensidad decreciente desde el azul al infrarrojo cercano (Baret, 1991).

2.6.1.4. Espesor de agua equivalente de la hoja (**Cw**, g cm^{-2} ó cm):

El contenido de agua de la hoja, se considera que absorbe la radiación principalmente en el infrarrojo medio (1100-2500 nm) (Bacour & Jacquemoud, 2001). Jacquemoud & Baret 1990, informaron valores de **Cw** para soja de 0,0137 cm.

Para la simulación con el modelo PROSPECT este valor fue mantenido constante (0,01 cm) debido a que su efecto no es significativo dentro del intervalo en el cual se realizó la inversión de este modelo de transferencia radiativa (de 400 a 900 nm).

2.6.1.5. Contenido de materia seca por unidad de área (Cm , $g\ cm^{-2}$):

Jacquemoud *et al.* (2000), sostienen que la materia seca presenta características de absorción sólo después de los 950 nm y que existe una absorción de la radiación por parte de la materia seca, casi constante a través del espectro visible (Jacquemoud *et al.*, 1999). Breunig *et al.* (2013) utilizaron PROSAIL para evaluar el impacto de la geometría de adquisición sobre la reflectancia y analizaron dos índices de vegetación en soja considerando un valor de Cm de $0,009\ g\ cm^{-2}$. Por su parte Wang *et al.* (2011) simularon reflectancias con PROSAIL de hojas de soja, utilizando un valor medido de Cm de $0,002\ g\ cm^{-2}$.

Jacquemoud & Baret (1990) encontraron una relación entre el índice de estructura del mesófilo de la hoja (N) y el área específica de la hoja ($cm^2\ mg^{-1}$), es decir la inversa de Cm , por lo que los valores de Cm se pueden calcular con la siguiente ecuación:

$$Cm = \frac{(N - 0,9)}{(0,1 \cdot N + 0,025) \cdot 1000} \quad (4)$$

2.6.1.6. Índice de estructura del mesófilo de la hoja (N , adimensional):

Este índice varía típicamente entre 1 y 2,5 (Bacour & Jacquemoud, 2001). Jacquemoud & Baret (1990) informaron que N varía entre 1 a 1,5 en monocotiledóneas con mesófilo compacto, en tanto que las dicotiledóneas de parénquima esponjoso con cavidades de aire en la cara abaxial, presentan valores de N entre 1,5 y 2,5. Los valores mayores de N se presentan en hojas senescentes con estructura interna desorganizada. En tal sentido, Jacquemoud & Baret (1990) emplearon un valor de N de 1,832 para estimar la reflectancia en soja verde con el modelo PROSPECT, encontrando buena correspondencia con los valores medidos.

Cada simulación con el modelo PRO4SAIL5B produce reflectancias y transmitancias de la hoja cada 1 nm en el intervalo 400-2500 nm, esos datos fueron utilizados como entrada para el modelo SAIL, que además requiere información del canopy, de la geometría sol-sensor-píxel observado y del entorno del suelo que se detallan a continuación:

2.6.2. Datos de entrada para SAIL.

2.6.2.1. Ángulo foliar promedio (*Angl*, °)

La función de densidad del ángulo de inclinación foliar es una propiedad fundamental de la estructura del canopy y es necesaria para calcular la reflectancia bidireccional del canopy para aplicaciones de teledetección (Campbell, 1990).

Las plantas de soja y maíz tienen arquitecturas de canopy contrastantes. Mientras el maíz tiene una distribución de ángulos foliares predominantemente esférica, el cultivo de soja tiene una distribución de ángulos foliares predominantemente planófila/heliotrópica (Nguy-Robertson *et al.*, 2012).

La función de densidad elipsoidal de ángulos foliares ha demostrado ser una buena aproximación a las distribuciones de ángulos foliares en canopies vegetales reales, y además solo requiere de un parámetro para caracterizar completamente la distribución (Campbell, 1986; 1990). De acuerdo a lo anterior esta función de densidad es la que será incorporada al modelo SAIL.

El ángulo de las hojas de soja fue tomado de la bibliografía siguiendo a Goel & Strebel (1984), con datos medidos según se presenta en la Tabla 2.4.

Tabla 2.4 Distribución de frecuencias del ángulo foliar en soja (Tomado de Goel & Strebel, 1984).

Ángulo foliar (°)	Porcentaje de hojas
5	3,49
15	3,60
25	7,50
35	12,94
45	16,74
55	20,85
65	13,87
75	12,26
85	8,75
Promedio 51,8°	

A los efectos de evaluar SAIL, se consideró un canopeo compuesto por una única capa que está conformada solamente por hojas.

2.6.2.2. Índice de Área Foliar (*LAI*, m² de hoja m⁻² suelo)

Se consideraron los valores de LAI que variaron entre 0,01 y 6 m² m⁻², siguiendo una distribución uniforme.

2.6.2.3. Hot Spot (*hspot*, adimensional)

El fenómeno de *hotspot* del canopeo ocurre cuando la fuente de radiación y el observador están alineados de modo que no existe una sombra visible, y por lo tanto la escena aparece con excesivo brillo. La magnitud y comportamiento de este fenómeno, como así también los cambios en las posiciones de iluminación y de vista, proveen información importante sobre la estructura del canopeo, en particular el cambio angular sobre el brillo es una función del tamaño relativo entre el tamaño y el espaciamiento de los objetos que constituyen el canopeo (Jupp & Strahler, 1991).

El *hotspot* aparece en el caso de iluminación unidireccional, y es un efecto de la dispersión simple (Kuusk, 1991).

Para la simulación se consideró un valor constante de *hotspot* de 0,1, concordando con los valores empleados por Atzberger *et al.* (2003) para trigo con el modelo PROSPECT+SAILH, por Doraiswamy *et al.* (2005) que midieron las propiedades espectrales de maíz y soja en las longitudes de ondas equivalentes a las bandas 1 y 2 de MODIS (Roja e infrarroja cercana, respectivamente) y por Vohland *et al.* (2006) quienes también emplearon dicho valor de *hotspot* para estimar el LAI en cebada a partir de la inversión del modelo PROSPECT+SAIL con mediciones a campo de un espectroradiómetro.

2.6.2.4. Geometría del sensor-sol-píxel observado

El fenómeno de reflectancia es la variación de la reflectividad dependiendo de la ubicación del sensor en relación con el objeto a observar en la superficie y la posición del sol (Landis & Aber, 2007).

La reflectancia bidireccional obtenida de la teledetección contiene información valiosa de la condición del cultivo, sin embargo, la interpretación de esos datos requiere de un entendimiento de las características de la respuesta bidireccional en relación con sus propiedades ópticas y morfológicas, considerando las geometrías de iluminación y de vista (Rahman *et al.*, 1999). Dicha configuración puede observarse en la figura 2.4.

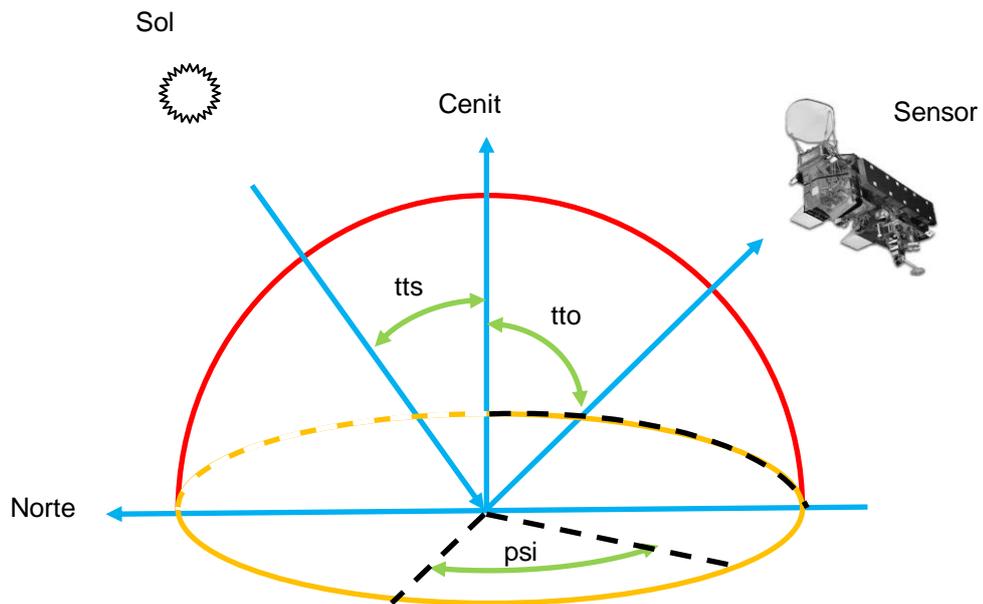


Figura 2.4 Geometría de la radiación incidente y reflejada sobre una superficie. La función de distribución de reflectancia bidireccional (BRDF) queda caracterizada por los ángulos cenitales del sol (tts) y de vista (tto) y por el ángulo acimutal relativo (ψ).

Dado que la influencia de la contaminación atmosférica y de la cobertura nubosa residual se incrementa con la longitud de espesor óptico de la atmósfera el algoritmo que genera el compuesto CV-MVC selecciona los píxeles con vista más próxima al nadir y menor ángulo solar cenital, de manera de tener la menor longitud de espesor óptico posible (Cihlar *et al.*, 1994).

Los valores de ángulos cenitales solar y de vista y acimutal relativo son obtenidos a partir de las imágenes MODIS (producto MYDQ1) para los píxeles correspondientes a los establecimientos del área de estudio y las fechas de las imágenes consideradas. Del análisis de los datos surge que el ángulo cenital solar varía entre 20 y 55 °, el ángulo cenital de vista varía entre 0 y 45° y el ángulo acimutal relativo presenta dos grupos de valores entre -100 y -180° y entre 0 y +80°.

2.6.2.5. Coeficiente de humedad del suelo (*ps_{oil}*, adimensional)

Las propiedades espectrales del suelo en el dominio óptico están relacionadas con el contenido de agua, de minerales y de compuestos orgánicos, y con el tamaño de las partículas y estructura del suelo (Escadafal & Huete, 1992).

La reflectancia del suelo es influenciada por la humedad edáfica junto con otros factores tales como la composición mineral, contenido de materia orgánica y textura (Asner 1998; Ben-Dor *et al.*, 1999). Para un lugar determinado, la reflectancia del suelo esta principalmente determinada por la humedad del suelo, dado que los otros factores varían muy lentamente con el tiempo (Weidong *et al.*, 2002). Baret *et al.* (1993) encontraron que las absorciones debidas a la composición mineral y al material orgánico tenían mayores influencias en las longitudes de ondas del visible, mientras que la humedad del suelo afectaba significativamente la reflectancia en NIR y SWIR (Wang *et al.*, 2008).

Los efectos de la humedad sobre la reflectancia de los suelos han sido estudiados por varios autores que reportaron un mayor oscurecimiento cuando se humedecen (Richter *et al.*, 2008). Lobell & Asner (2002) analizaron la reflectancia en 400–2500 nm de cuatro suelos con distintos contenidos de humedad y encontraron que la reflectancia en SWIR responde a la humedad del suelo en todo el rango de 0,5% a 45% en tanto que VNIR se satura en condiciones intermedias de humedad próxima a 20% (Richter *et al.*, 2008; Wang *et al.*, 2008).

Los efectos del suelo sobre la reflectancia SWIR son mayores con valores de LAI menores que 2, cuando la vegetación no cubre completamente el suelo (Wang *et al.*, 2008).

Generalmente se utiliza un factor de brillo del suelo, que se multiplica por la reflectancia del suelo dentro del espectro analizado (Atzberger *et al.*, 2003). Richter *et al.* (2008) encontraron correlaciones negativas relativamente altas entre el contenido volumétrico de agua del suelo y el factor de brillo del suelo

El modelo PRO4SAIL5B utiliza un factor pSoil que realiza una mezcla lineal entre la reflectancia de un suelo completamente seco y uno completamente húmedo, en función del contenido de humedad actual del suelo con la siguiente ecuación:

$$\rho_{s_\lambda} = p_{soil} \cdot \rho_{d\lambda} + (1 - p_{soil}) \cdot \rho_{w\lambda} \quad (5)$$

Donde:

ρ_{s_λ} = reflectancia del suelo.

p_{soil} = coeficiente del suelo que depende del contenido de humedad y varía entre 0 (suelo completamente húmedo) y 1 (suelo seco)

$\rho_{d\lambda}$ = reflectancia del suelo seco

$\rho_{w\lambda}$ = reflectancia del suelo completamente húmedo

2.6.2.6. *Fracción de radiación solar difusa respecto de la radiación solar incidente (Skyl, adimensional).*

Spitters *et al.* (1986a y b) mostraron la relación entre radiación difusa y global, en función de la relación entre radiación global y radiación astronómica, en valores horarios. Considerando una situación de cielo despejado (condición necesaria para emplear imágenes de MODIS) se presentaron cocientes entre radiación global y radiación astronómica de 0,8, y la fracción entre la radiación difusa respecto de la radiación global de 0,15. Con el cielo completamente cubierto por nubes, la radiación solar entrante es completamente difusa, pero en días completamente despejados, con bajo nivel de aerosoles, la radiación difusa puede ser menor a 10% (Danson, 1998), en tanto que Goel & Deering (1985) consideraron un valor de 0,15 para usar en el modelo PROSPECT+SAIL. Jones (1992), también plantea esta relación con valores similares. Aun en condiciones despejadas, la radiación difusa contribuye entre un 10 y un 30% de la radiación solar total.

En un día despejado, la mayoría de la radiación difusa proviene de la región próxima al sol (debido al *forward scattering*), motivo por el cual a los efectos de la simulación se empleó un valor de 0,1, igual al empleado por Atzberger *et al.* (1995) quienes estimaron el LAI de trigo invirtiendo el modelo PROSPECT+SAIL, asumiendo que la fracción de la radiación solar difusa, era independiente de la longitud de onda e igual a 0,1.

2.7. Obtención de la base de datos del modelo PROSPECT+SAIL

Se realizaron 100.000 simulaciones con el modelo PROSPECT+SAIL, cambiando los valores de los parámetros que se detallan a continuación en la tabla 2.5.

Tabla 2.5 Rango y distribución de las variables que se modificaron en la simulación del modelo PROSPECT+SAIL para obtener el valor de reflectancia.

Variable	Min	Max	Distribución
<i>Cab</i>	40	100	Uniforme
<i>Car</i>	5	20	Uniforme
<i>Cbrown</i>	0	0	Constante
<i>Cw</i>	0,015	0,015	Constante
<i>Cm</i>	Calculada a partir de N		Normal
<i>N</i>	1,0	2,5	Normal truncada Media 1,75 Desvío 0,5
<i>Angl</i>	52°	52°	Constante
<i>LAI</i>	0,01	6,00	Uniforme
<i>Hspot</i>	0,1	0,1	Constante
<i>Psi</i>	-180° 0°	-100° 80°	Bi - Uniforme
<i>Tts</i>	20°	55°	Uniforme
<i>Tto</i>	0°	45°	Uniforme
<i>Psoil</i>	0	1	Uniforme
<i>Skyl</i>	10%	10%	Constante

Referencias:

Cab contenido de clorofila ($\mu\text{g cm}^{-2}$), *Car* contenido de carotenoides ($\mu\text{g cm}^{-2}$), *Cw* espesor de agua equivalente de la hoja (g cm^{-2} ó cm), *Cm* contenido de materia seca por unidad de área (g cm^{-2}), *Cbrown* contenido de pigmentos marrones (adimensional), *N* índice de estructura del mesófilo de la hoja (adimensional), *Angl* ángulo foliar promedio (°), *LAI* índice de área foliar (adimensional), *hspot* Hot Spot (adimensional), Geometría del sensor-sol- píxel observado: *psi* ángulo acimutal relativo (°), *tts* ángulo cenital del sol (°), *tto* ángulo cenital de vista (°), *psoil* coeficiente del suelo (adimensional), *Skyl* fracción de radiación solar difusa respecto de la radiación solar incidente (adimensional).

Los resultados de la simulación fueron los valores de reflectancias en promedio entre los extremos de las bandas azul (459-479 nm), rojo (620-670 nm) e infrarrojo cercano (841-876 nm) para cada una de estas combinaciones de datos de entrada.

2.8. Inversión del Modelo PROSPECT+SAIL mediante el empleo de Redes Neuronales Artificiales

2.8.1. Arquitectura de la Red Neuronal

Para la inversión de la base de datos obtenida con el modelo PROSPECT+SAIL, se empleó un modelo de redes neuronales artificiales (ANN). Las redes neuronales representan una metodología de modelación matemática, formadas por una estructura de neuronas unidas por enlaces que transmiten información (aplicando funciones matemáticas) a otras neuronas para obtener un resultado. Las redes aprenden de la información histórica, adquiriendo así la capacidad de predecir respuestas del mismo fenómeno.

Las redes constan de una capa de entrada, una o varias capas ocultas y una capa de salida. Los datos se presentan en la capa de entrada, la/s capa/s oculta/s realizan el procesamiento de la información y la de salida incluye tantas neuronas como variables se quieran estimar. La relación entre las capas se realiza a través de la aplicación de funciones matemáticas (función escalón, tangente hiperbólica, función sigmoidea, etc.) a las sumas ponderadas por pesos de los valores de las neuronas de la capa anterior. Al llegar a la capa de salida, este proceso interactivo produce el resultado. A través de un proceso de entrenamiento, la red en cada iteración proporciona una salida que se compara con el valor observado de la variable a estimar, obteniéndose así un error. En este proceso se determinan iterativamente los pesos de las conexiones a los efectos de corregir dicho error. El entrenamiento concluye cuando la red es capaz de reproducir las salidas correspondientes a los parámetros de entrada, con un error mínimo arbitrario o después de un número fijo de iteraciones (Hilera & Martínez, 2000).

En este trabajo se emplearon distintas ANN (NeuroSolutions V. 4.31) del tipo perceptrón multicapa, con tres capas de neuronas que propagan la información hacia adelante:

- i) La primera de ellas tiene las neuronas de entrada (E), correspondiente a las variables como: *Cab*, *Car*, *Cm*, *N*, *psi*, *tts*, *tto*, *psoil*, las reflectancias en azul, rojo e infrarrojo cercano y el NDVI.
- ii) La capa de neuronas ocultas (O), cuyo número varió de acuerdo a la arquitectura de red utilizada (Tabla 2.6).
- iii) La capa de salida estuvo constituida por una única neurona de salida (S) para estimar el LAI (Figura 2.5).

Un mayor detalle de las distintas arquitecturas de redes neuronales empleadas se puede observar en la Tabla 2.6.

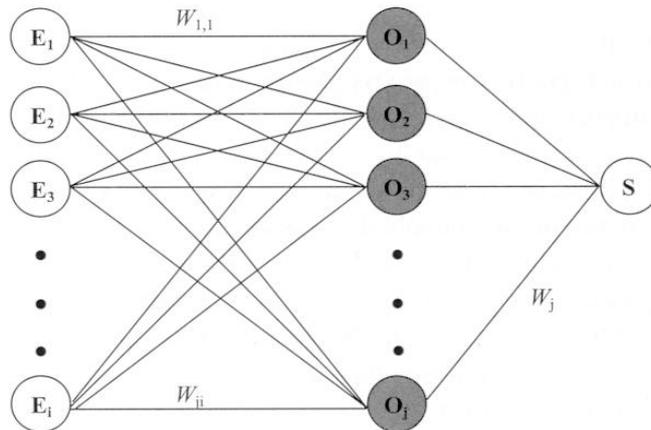


Figura 2.5 Esquema de la red neuronal artificial utilizada para invertir el modelo de transferencia radiativa.

Cada neurona de la capa oculta produce una salida a través de la aplicación de una función tangente hiperbólica a la sumatoria de los productos entre los valores de entrada por los pesos de las conexiones entre las neuronas. La capa de salida produce el resultado del cálculo, con igual procedimiento que en la capa oculta.

Tabla 2.6 Arquitectura de las distintas redes neuronales empleadas en la inversión del modelo PROSPECT+SAIL.

Red	Características de la hoja				Geometría del sensor-sol - píxel observado			Coeficiente de humedad del suelo	Reflectancias			Índice de Vegetación	Número de neuronas de la capa oculta
	Cab	Car	Cm	N	psi	tts	tto	psoil	Azul	Rojo	NIR	NDVI	O _i
A001	✓				✓			✓	✓	✓	✓	✓	6
A002	✗				✓			✓	✓	✓	✓	✓	9
A003	✓				✗			✓	✓	✓	✓	✓	8
A004	✓				✓			✗	✓	✓	✓	✓	6
A005	✗				✗			✓	✓	✓	✓	✗	16
A006	✓				✗			✗	✓	✓	✓	✗	10
A007	✗				✓			✗	✓	✓	✓	✗	11
A008	✗				✗			✗	✓	✓	✓	✗	20
A009	✗				✗			✗	✗	✓	✓	✗	27

2.8.2. Entrenamiento y validación de la Red Neuronal

El entrenamiento de la red se llevó a cabo utilizando el algoritmo de *backpropagation*, en el cual se determinan iterativamente los pesos de las conexiones, w_{ji} que conectan a las neuronas de entrada (E) con las de la capa oculta (O) y w_j para la transferencia entre la capa oculta (O) y la de salida (S). A partir de los datos de entrada la red en cada iteración propaga una salida, a través de las neuronas que la componen, con los pesos y función de transferencia considerados, este resultado se compara con el valor real, obteniéndose así un error. El algoritmo de *backpropagation* consiste básicamente en propagar el error de estimación hacia atrás, desde la capa de salida hasta la de entrada, permitiendo así la adaptación de los pesos de la red con el fin de reducir dicho error (Bocco *et al.*, 2007). El entrenamiento concluye cuando la red es capaz de reproducir las salidas conocidas para los parámetros de entrada, con un error mínimo arbitrario (para este trabajo 0,001) o bien fijando el número de iteraciones (es este estudio se consideraron 1000

iteraciones). A fin de acelerar el proceso de aprendizaje, de acuerdo a Danson *et al.* (2003), se incluyeron coeficientes de aprendizaje igual a 0,1 y de momento igual a 0,9. Para el entrenamiento de la red se utilizó el 50% de los datos, en tanto que para prevenir el sobreentrenamiento se utilizó el 10% de los datos en el proceso de *crossvalidation*, y los restantes fueron empleados para la validación de resultados.

La segunda fase consiste en realizar la validación de la red diseñada con otro conjunto de datos para los cuales se conocen los resultados, a fin de comprobar la eficiencia de la misma.

Una vez entrenada y validada, la red se utilizó para estimar el LAI del cultivo de soja en de los distintos establecimientos del área de estudio, partir de datos de MODIS. Los valores de LAI fueron convertidos a %C y comparados con los valores obtenidos mediante fotografías digitales.

2.9. Modelo STICS para la simulación del cultivo de soja

Actualmente existen numerosos modelos de simulación disponibles, desde modelos multiespecies a colecciones de modelos con características compartidas (Jones *et al.*, 1994). El modelo STICS (*Simulateur multIdisciplinaire pour les Cultures Standard*, Brisson *et al.*, 1998) es un modelo que representa el funcionamiento del dosel y fue desarrollado para simular el crecimiento desarrollo y productividad de un amplio rango de cultivos (trigo, maíz, tomate, banana, soja, entre otros).

El modelo STICS presenta un de paso de tiempo diario, y requiere para su ejecución de un conjunto de variables de entrada que expresan la condiciones atmosféricas, edáficas y culturales del cultivo. Este modelo simula la acumulación de biomasa, componentes del rendimiento, como así también los balances de agua y nitrógeno de un cultivo a lo largo de su ciclo de cultivo (Brisson *et al.*, 2003). Los principales datos de entrada del modelo STICS, discriminados por su naturaleza, son:

- Variables meteorológicas: radiación solar, temperaturas de aire máxima y mínima, precipitaciones, velocidad del viento y humedad relativa.
- Características del suelo: contenido de arcilla y limo, contenido de agua a capacidad de campo y en punto de marchites permanente, contenido de materia orgánica, etc.
- Manejo del cultivo: fecha de siembra, cronograma de riego y fertilización, manejo de residuos, etc.

Las principales variables de estado son la biomasa total de la parte aérea, como así también la biomasa almacenada en cada órgano (hojas, tallos, espigas o frutos), las cantidades de carbono y nitrógeno fijadas por el cultivo y el LAI. La dinámica del LAI es principalmente determinada por la fenología aunque también el estrés de agua y nitrógeno regulan su expansión, como así también por la máxima asignación de biomasa. La acumulación de biomasa es calculada a partir de la intercepción de la radiación solar por el follaje (Ley de Beer) y depende de los índices de estrés estomático y de nitrógeno (Weiss *et al.*, 2001).

Los parámetros del modelo STICS se agrupan en 4 clases: manejo del cultivo, información meteorológica, características del suelo y propiedades relacionadas a la planta. La mayoría de los parámetros fueron mantenidos en sus valores estándar, de acuerdo a la versión JavaSTICS 1.31 del software. A continuación se detallan las modificaciones implementadas en particular.

2.9.1. Información meteorológica empleada:

Se generaron los archivos con la información diaria de radiación solar, temperaturas de aire máxima y mínima y precipitaciones, de los años 2005 y 2006, con la opción para el cálculo de la evapotranspiración de referencia de Priestley y Taylor. Se emplearon datos provenientes de las estaciones meteorológicas de Manfredi de la EEA del INTA y de Pilar pertenecientes al Servicio Meteorológico Nacional.

2.9.2. Características del suelo:

Se modificaron de acuerdo a los valores zonales: el valor del contenido de arcilla en el horizonte superficial (argi, %), el contenido de N orgánico en el horizonte de humificación (Norg, %), la profundidad del horizonte de humificación (profhum, cm), el porcentaje de calcáreo en superficie (calc, %), el potencial Hidrógeno (pH), la proporción de carbono respecto de nitrógeno del humus del suelo (CsurNsol). Además, para cada capa, se modificó: el espesor (epc, cm), la humedad a capacidad de campo (HCCF; %w), la humedad en el punto de marchitez permanente (HMINF, %w), la densidad aparente (DAF, g cm⁻³). A modo de ejemplo, la Figura 2.6 muestra los valores de los parámetros del suelo correspondientes a la serie Oncativo.

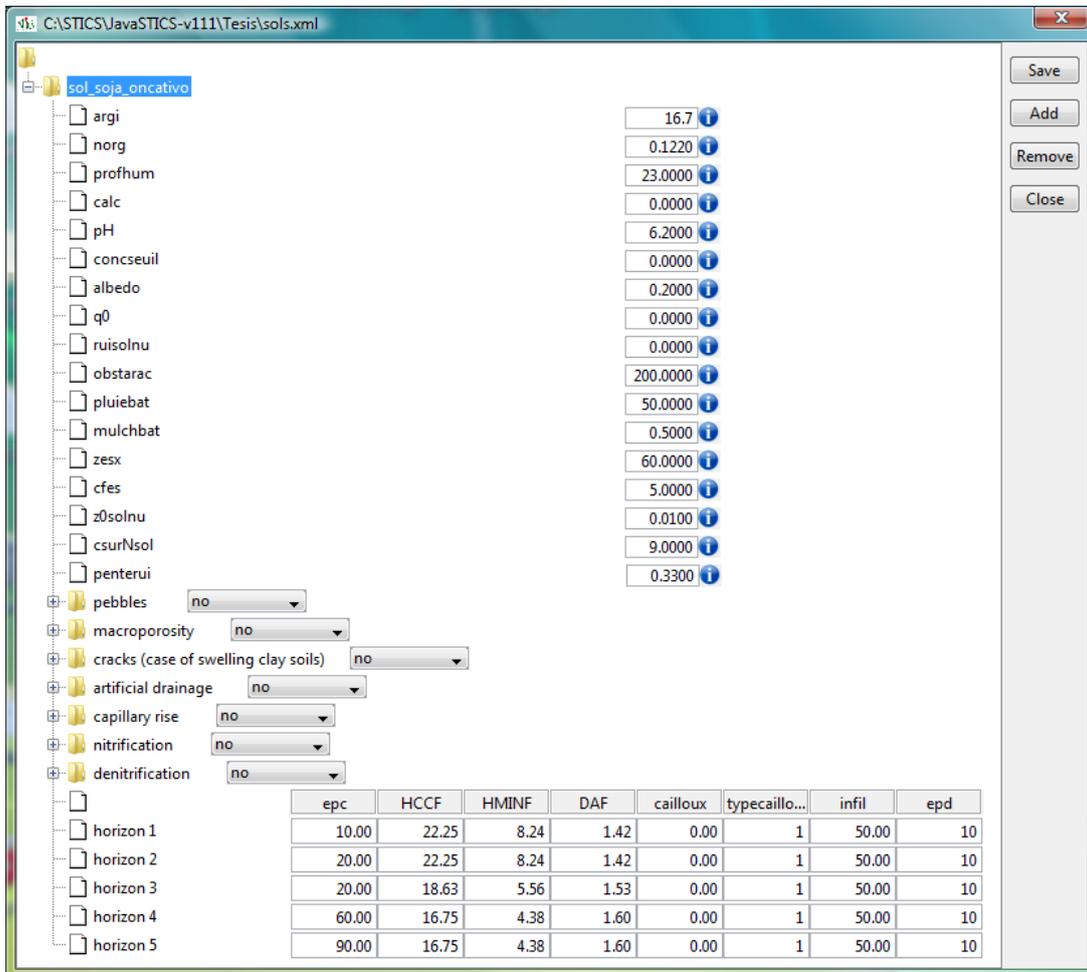


Figura 2.6 Parámetros del suelo de la Serie Oncativo, empleados para la simulación del cultivo de soja.

2.9.3. Manejo del cultivo:

De acuerdo a la información recolectada en la región, se introdujo la información correspondiente a la fecha de comienzo de la simulación, el contenido de agua inicial, la fecha, densidad y profundidad de siembra, para cada lote de cultivo empleado en la simulación.

2.9.4. Características del cultivo:

Como una primera aproximación solo se modificó los parámetros de respuesta fotoperiódica a los efectos de considerar los grupos de madurez utilizados dentro de la región de estudio que van desde III largo a IV. A tal efecto se modificaron los parámetros de fotoperíodo base (phobase, h) y fotoperíodo de saturación (phosat, h) a 18 y 15 h, respectivamente.

2.9.5. Utilización del Índice de Área Foliar en el modelo STICS:

Una de las principales ventajas por la cual se empleó este modelo es que tanto el área foliar como el porcentaje de cobertura del suelo pueden ser variables de estado simuladas o pueden ingresar como datos observados. En este sentido el modelo presenta una rutina (Figura 2.7) a fin de estimar distintos coeficientes que permiten describir el comportamiento del índice de área foliar a lo largo del ciclo del cultivo. A modo de ejemplo se muestra este procedimiento para el Lote 1:

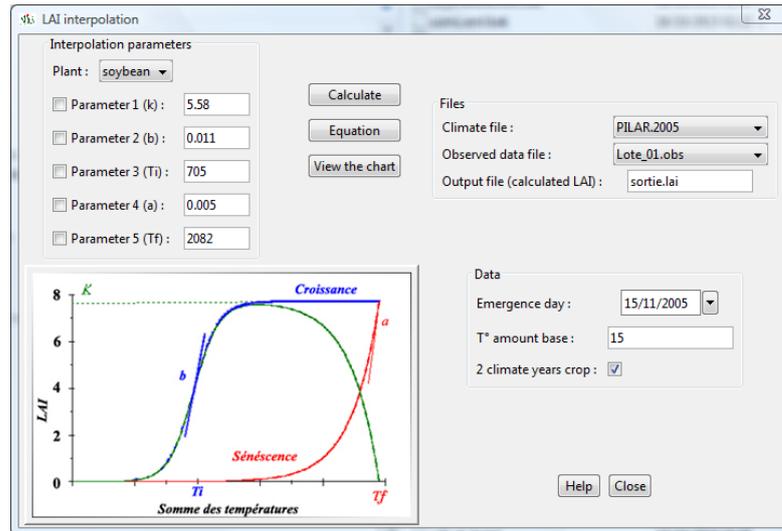


Figura 2.7 Módulo para interpolar en Índice de Área Foliar, a lo largo de todo el ciclo del cultivo, a partir de datos observados.

La interpolación del LAI se lleva a cabo a partir de la siguiente ecuación, destinada a estimar el LAI en función de las sumas térmicas:

$$LAI_{(d)} = K \cdot \left(\frac{1}{1 + e^{-b \cdot (St_{(d)} - Ti)}} \right) - e^{a \cdot (St_{(d)} - Tf)} \quad (6)$$

Donde:

$LAI_{(d)}$ = índice de área foliar en el día d, a partir de la emergencia

K = índice de área foliar máximo

b = máxima tasa de crecimiento del índice de área foliar

T_i = suma de temperatura cuando ocurre la máxima tasa de crecimiento del índice de área foliar

a = máxima tasa de senescencia del índice de área foliar

T_f = suma de temperatura cuando ocurre la máxima tasa de senescencia del índice de área foliar

$St_{(d)}$ = suma de temperatura por el método residual, en el día d, a partir de la emergencia.

2.10. Estimación de parámetros biofísicos de la soja.

Para estimar los parámetros biofísicos a partir de información proveniente de satélites, se emplearon distintas metodologías: modelos estadísticos de regresión a partir de índices de vegetación, y modelos de transferencia radiativa (SAIL) y redes neuronales. Los parámetros biofísicos estimados son LAI y %C.

El desempeño del modelo en la estimación de los parámetros biofísicos del dosel a partir de la información satelital, de la humedad del suelo, fenología y rendimiento se evaluó estadísticamente contrastando las estimaciones con la información correspondiente medida de campo. En el análisis se emplearon los estadísticos R^2 , d , MAE, RMSE, %RMSE y BIAS (Udelhoven *et al.*, 2000; Weiss *et al.*, 2000; Dawson & Wilby, 2001; Doraiswamy *et al.*, 2004), que se calcularon mediante las siguientes ecuaciones:

$$R^2 = \left[\frac{\sum_{i=1}^n (obs_i - \overline{obs})(est_i - \overline{est})}{\sqrt{\sum_{i=1}^n (obs_i - \overline{obs})^2 \sum_{i=1}^n (est_i - \overline{est})^2}} \right]^2 \quad (7)$$

$$d = 1 - \frac{\sum_{i=1}^n (obs_i - est_i)^2}{\sum_{i=1}^n (|est_i - \overline{obs}| + |obs_i - \overline{obs}|)^2} \quad (8)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |est_i - obs_i| \quad (9)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (est_i - obs_i)^2} \quad (10)$$

$$\%RMSE = \frac{\sqrt{\frac{1}{n} \sum_{i=1}^n (est_i - obs_i)^2}}{\overline{obs}} \quad (11)$$

$$BIAS = \frac{1}{n} \sum_{i=1}^n (est_i - obs_i) \quad (12)$$

donde:

R^2 = coeficiente de determinación.

d = índice de concordancia.

MAE = error absoluto promedio.

RMSE = raíz del error cuadrático medio.

%RMSE = raíz del error cuadrático medio relativo.

BIAS = error promedio.

est_i = variable estimada por el modelo.

\overline{est} = promedio de la variable estimada por el modelo.

obs_i = variable observada.

\overline{obs} = promedio de la variable observada.

n = tamaño de la muestra.

RESULTADOS

3.1. Determinación del porcentaje de cobertura de soja

La cobertura del cultivo de soja fue determinada a partir de las fotografías digitales. A modo de ejemplo se muestra la figura 3.1, donde puede observarse la evolución de la fracción de la cobertura de soja a través del ciclo del cultivo para el lote 1, antes y después de aplicar el procedimiento de clasificación. Como se observa, el procedimiento identifica adecuadamente los componentes vegetales y los diferencia del suelo y el rastrojo.

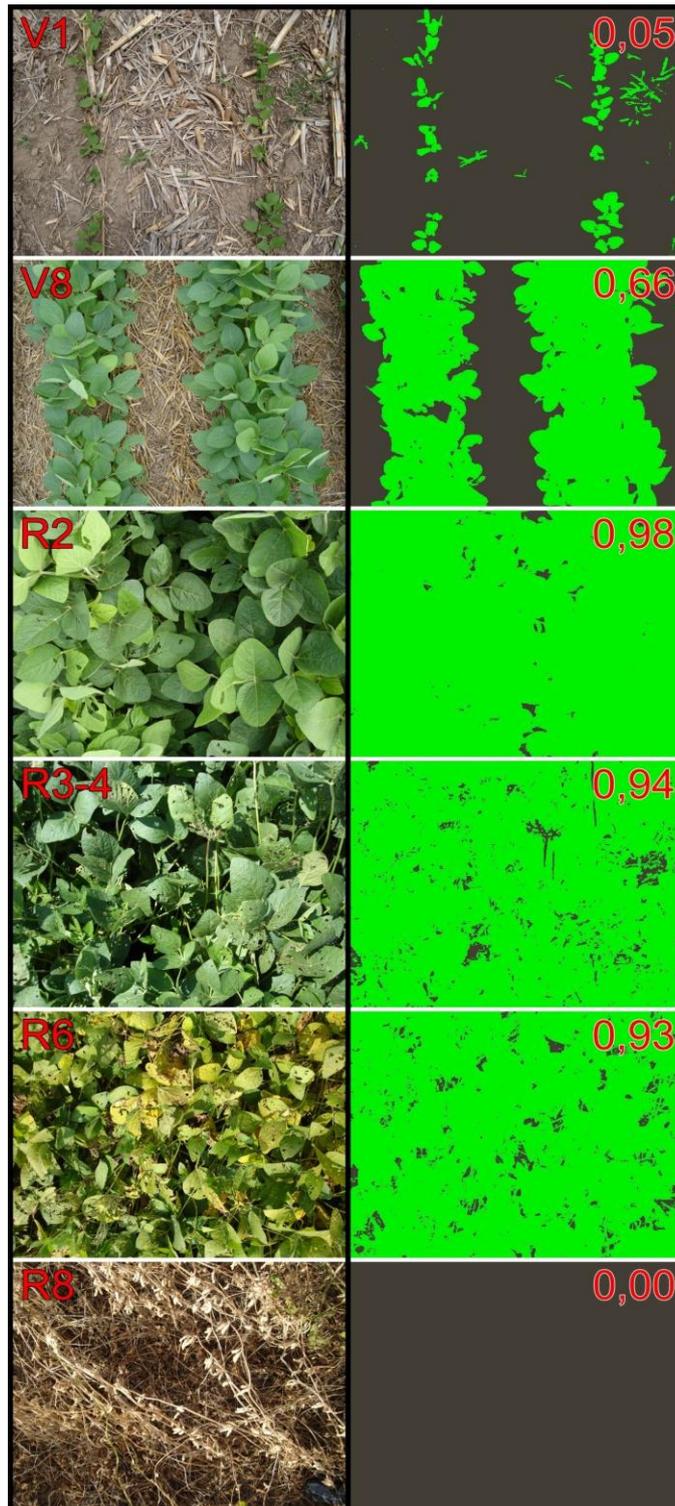


Figura 3.1 Evolución de la cobertura del suelo a lo largo del ciclo del cultivo, calculada a partir de las fotografías digitales (izquierda) clasificadas por el método de máxima verosimilitud en suelo y vegetación (derecha) para el lote 1 del área de estudio. Las fotografías presentan el estado fenológico según escala desarrollada por Fehr *et al.* (1971), en tanto que las imágenes clasificadas muestran los valores de porcentaje de cobertura (%C).

3.2. Relación entre la Fracción de la Radiación Fotosintéticamente Activa Interceptada y la cobertura de soja.

Con los datos del interceptómetro obtenidos en 2005-2006 y 2007-2008 se calculó la $fIPAR$ a lo largo de los dos ciclos del cultivo. Esta información se relacionó con la cobertura del cultivo de soja correspondiente a las fotografías tomadas en los mismos sitios donde se determinó $fIPAR$; obteniendo los resultados que se muestran en la figura 3.2.

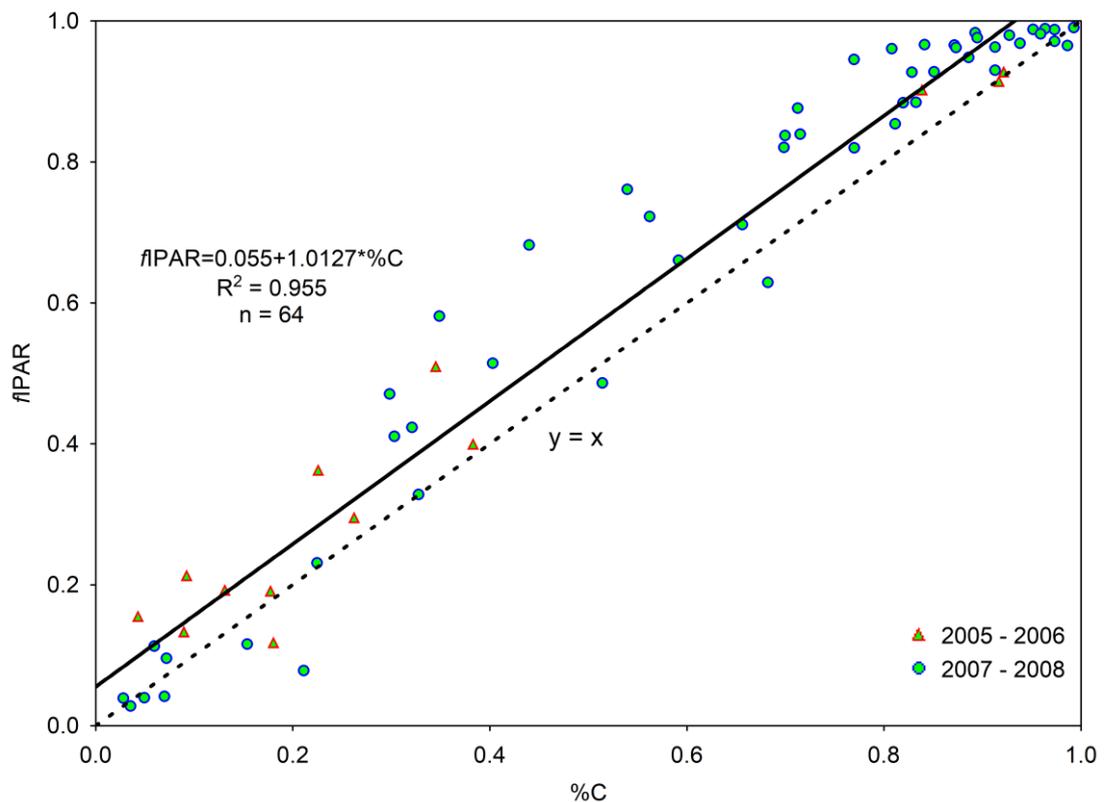


Figura 3.2 Relación entre la fracción de la radiación fotosintéticamente activa interceptada por el canopeo ($fIPAR$) con respecto a la cobertura de soja ($\%C$) para las campañas 2005-2006 y 2007-2008.

Los resultados presentan un ajuste lineal entre $\%C$ y $fIPAR$, con un coeficiente de regresión significativo ($p < 0,01$) próximo a 1 y un R^2 de 0,955, sin embargo la relación se encuentra por encima de la línea 1:1.

3.3. Relación entre índice de área foliar y la cobertura de soja

Con los datos de índice de área foliar (LAI) estimados a partir del interceptómetro mediante la ecuación 1, considerando un valor de K de 0,5 y los valores de la cobertura de soja estimada a partir de fotografías digitales tomadas en los mismos sitios, se procedió a establecer la relación entre ambas variables que se presenta en la Figura 3.3.

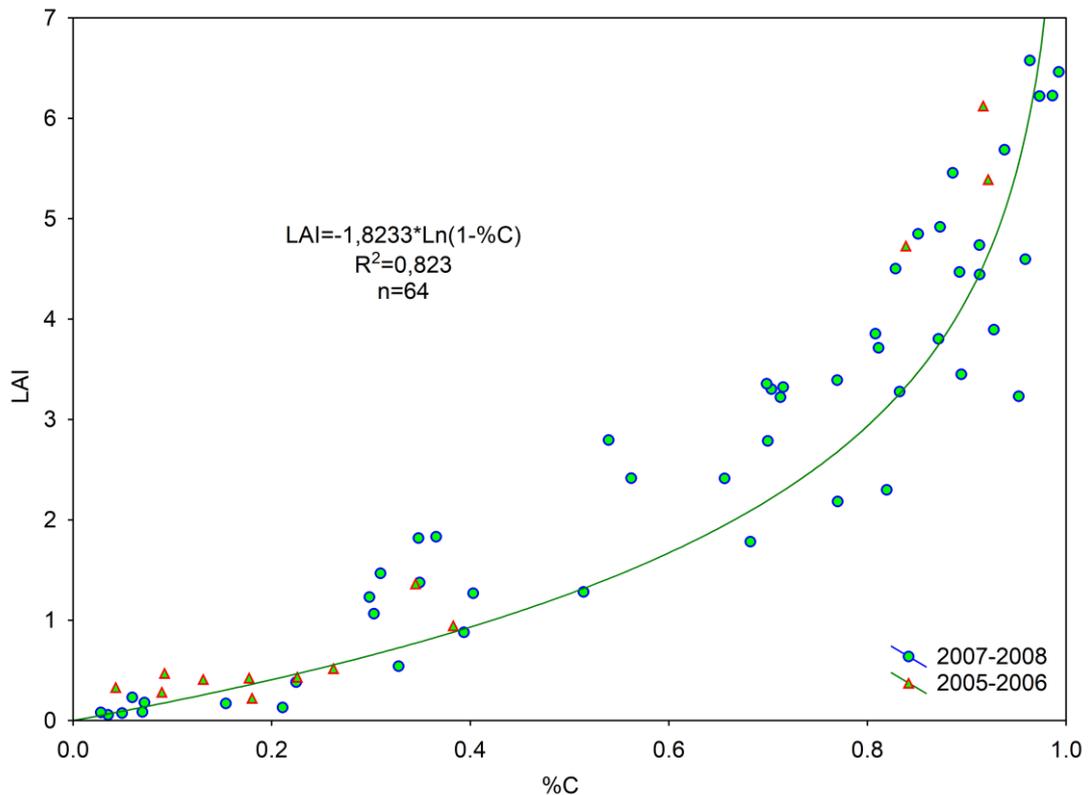


Figura 3.3 Relación entre Índice de Área Foliar (LAI) y la Cobertura de Soja (%C) para las campañas 2005-2006 y 2007-2008.

En ambas campañas 2005–2006 y 2007–2008 se presentó una relación logarítmica entre el LAI y %C, con $R^2=0,823$. Estos resultados permiten estimar el LAI, a partir de %C obtenido mediante el empleo de fotografías digitales tomadas verticalmente sobre el cultivo, metodología que presenta las ventajas: como su simpleza operativa, bajo costo y menores restricciones en las condiciones de iluminación (en la toma de la fotografía), ya que para estimar el LAI con el interceptómetro se debieron realizar las lecturas próximas al mediodía solar y en días completamente despejados. Además, la fotografía digital permite fácilmente efectuar muchas determinaciones de un parámetro biofísico que presenta una gran variación a lo largo del ciclo del cultivo.

3.4. Relación entre el índice de área foliar y el NDVI

Los datos de %C provenientes del área de estudio de la campaña 2005-2006 se utilizaron para estimar el LAI a partir de la relación logarítmica mostrada en la figura 3.3. Estos datos de LAI fueron comparados con los valores de NDVI interpolados para la fecha en que se realizaron los viajes a campo. La relación entre el LAI y el NDVI, puede verse en la figura 3.4.

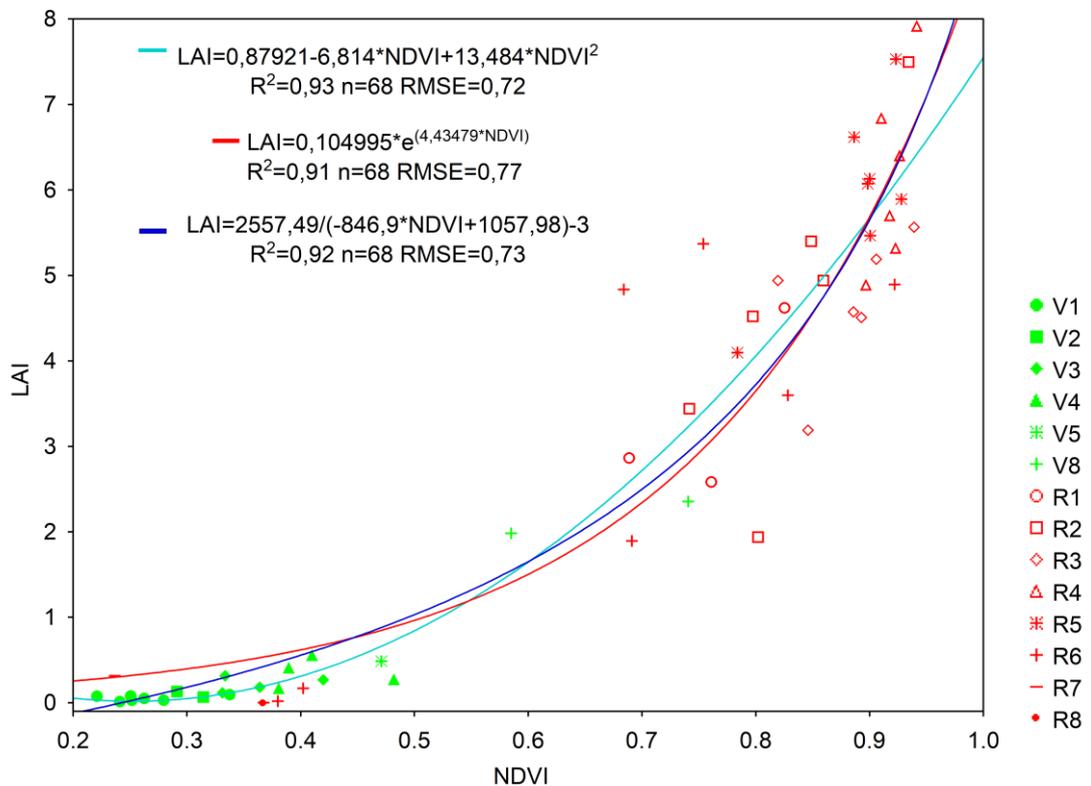


Figura 3.4 Relación entre Índice de Área Foliar (LAI) y el Índice de Vegetación de la Diferencia Normalizada (NDVI) para la campaña 2005-2006, considerando las distintas fases fenológicas según la escala de Fehr *et al.* (1971).

La relación entre LAI y NDVI se muestra claramente no lineal a lo largo del ciclo de cultivo de soja, mostrando una saturación del NDVI con valores de LAI superiores a 4.

3.5. Relación entre el NDVI y $fIPAR$

La fracción de la radiación fotosintéticamente activa interceptada por el cultivo de soja ($fIPAR$), fue estimada a partir del LAI mediante la ecuación (1) y comparada con el NDVI (Figura 3.5).

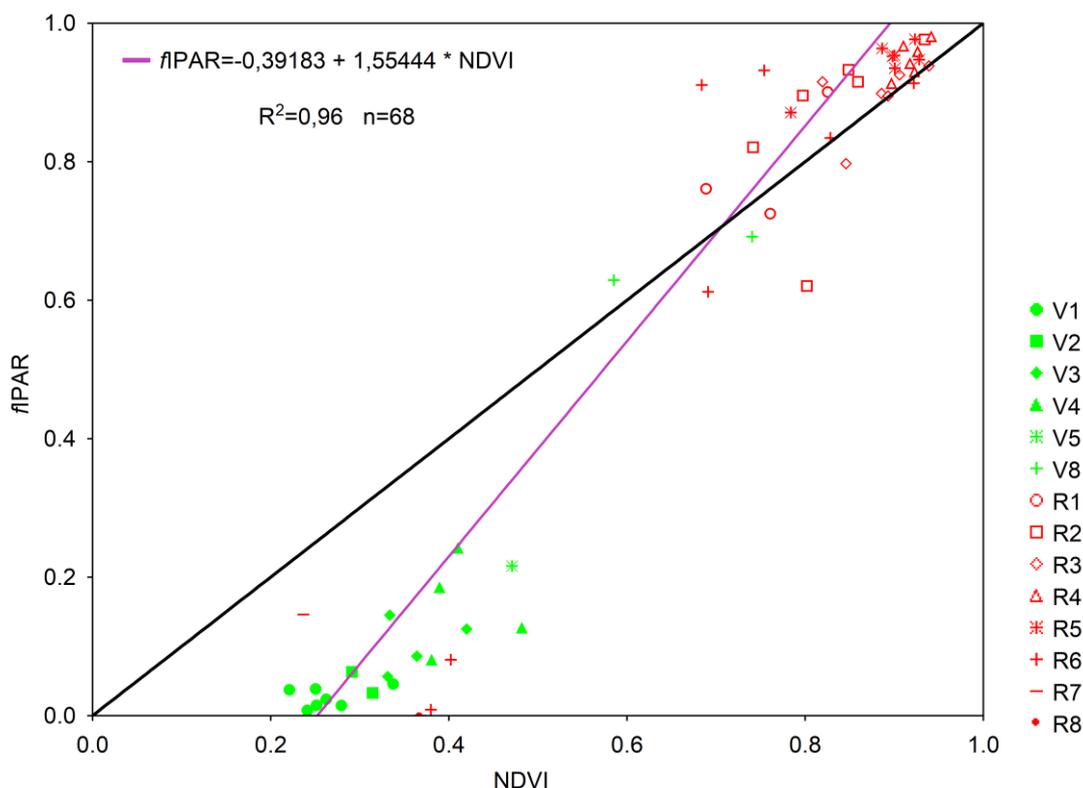


Figura 3.5 Relación entre la fracción de la radiación fotosintéticamente activa interceptada ($fIPAR$) y el Índice de Vegetación de la Diferencia Normalizada (NDVI) para la campaña 2005-2006, considerando las distintas fases fenológicas según la escala de Fehr *et al.* (1971).

La figura 3.5 muestra una relación lineal creciente entre $fIPAR$ y NDVI, con un valor de $R^2=0,96$. Los valores de NDVI se encuentran en el rango 0,2 – 0,9; correspondiendo en general los mayores valores de NDVI (>0.6) a las fases reproductivas entre R1 – R5 y en algunos casos en R6; por el contrario cuando las etapas fenológicas corresponden a las fases reproductivas avanzadas R6-R8, los valores de NDVI disminuyen drásticamente, siendo esta disminución acompañada por una caída en los valores de $fIPAR$.

3.6. Relación entre el NDVI y %C

La relación entre la fracción del suelo cubierto por el cultivo (%C) y el NDVI puede verse en la figura 3.6.

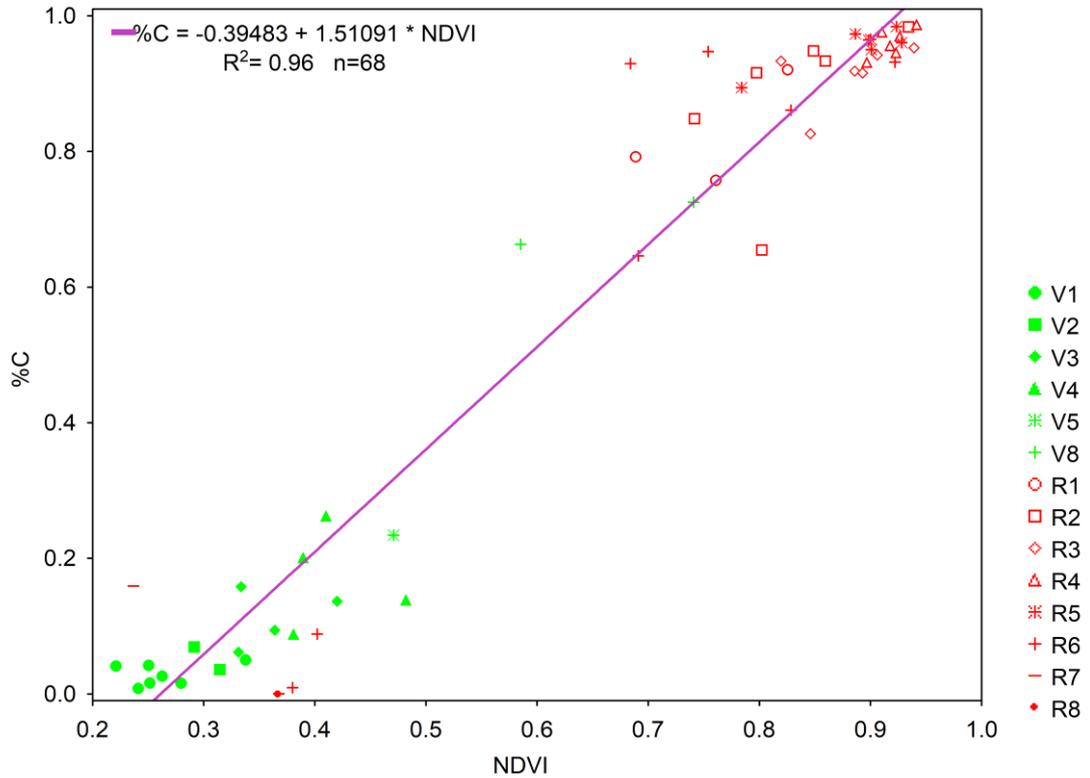


Figura 3.6 Relación entre la fracción del suelo cubierta por el cultivo (%C) y el Índice de Vegetación de la Diferencia Normalizada (NDVI) para la campaña 2005-2006, considerando las distintas fases fenológicas según la escala de Fehr *et al.* (1971)

Como se observa en la figura 3.6 la relación entre %C y NDVI es claramente lineal, con valores elevados de NDVI (>0,6) cuando el cultivo se encuentra en las etapas fenológicas de finales de las etapas vegetativas y la mayoría de las etapas reproductivas. Si se consideran las etapas avanzadas (R6 a R8) en muchos casos los valores de NDVI disminuyen por debajo de 0,4 y los valores de %C, consecuentemente se encuentran por debajo de 0,3.

3.7. Relación entre el NDVI y Biomasa de la parte Aérea

La variación de la biomasa en función del NDVI para distintas fases fenológicas puede verse en la figura 3.7.

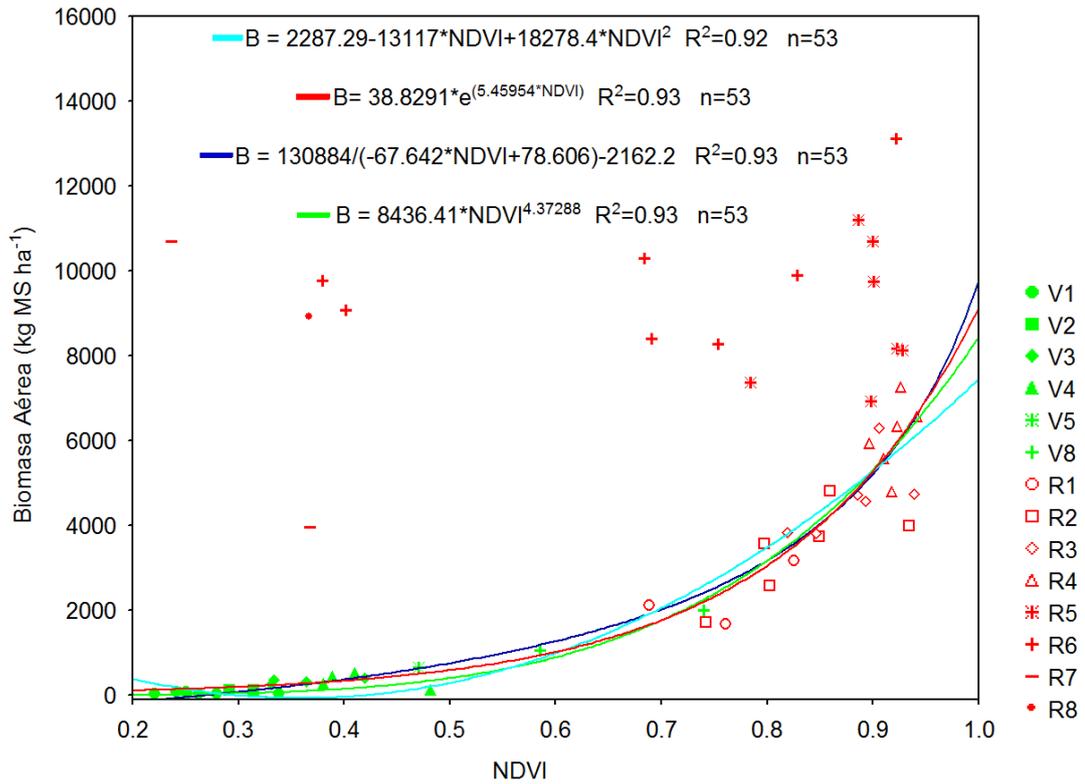


Figura 3.7 Relación entre la Biomasa de la parte aérea y el Índice de Vegetación de la Diferencia Normalizada (NDVI) para la campaña 2005-2006, considerando las distintas fases fenológicas según la escala de Fehr *et al.* (1971).

Como puede verse en la figura 3.7, la biomasa muestra una relación claramente no lineal con el NDVI, hasta la etapa de R4, a partir de la cual se pierde la relación. Con el comienzo de la senescencia de las hojas los valores de NDVI disminuyen marcadamente.

3.8. Modelo de transferencia radiativa PROSAIL.

Se efectuaron simulaciones de la reflectancia del canopeo en las longitudes de onda correspondientes a las bandas de MODIS azul, rojo y NIR utilizando el modelo de transferencia radiativa acoplado PROSPECT + SAIL (PROSAIL), que se ejecutó en modo directo (hacia adelante) utilizando 100.000 juegos de parámetros de entrada elegidos al azar, de acuerdo a las distribuciones de la Tabla 2.5. Las distribuciones de los parámetros de entrada se definieron de acuerdo a la literatura para representar el canopeo de un cultivo de soja.

En la figura 3.8 se muestran las relaciones entre las reflectancias de las distintas bandas estimadas por PROSAIL para 1000 valores de la base de dato tomados al azar y las observadas por MODIS, junto con los valores de NDVI calculados a partir de las reflectancias en rojo y NIR.

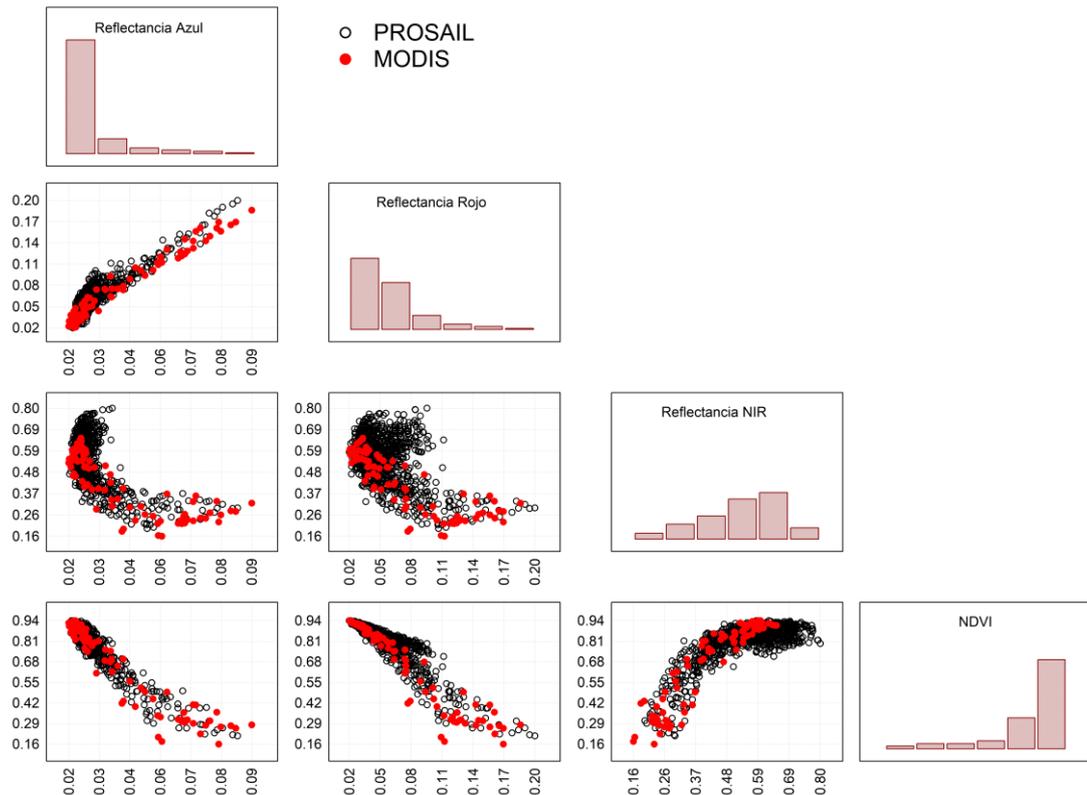


Figura 3.8 Relación entre las reflectancias en las bandas banda azul y rojo e infrarrojo cercano, y NDVI estimados a partir de PROSAIL y los observados por MODIS.

Como se puede observar en la figura 3.8, existe un comportamiento similar entre las distintas bandas estimadas y observadas, al igual que cuando se analiza el NDVI. En el gráfico puede verse que la reflectancia en rojo y el NDVI se saturan a medida que la reflectancia en NIR se incrementa con valores por encima de aproximadamente 40%.

La habilidad del modelo PROSAIL para estimar la reflectancia del cultivo en las bandas correspondientes al sensor MODIS, con distintos valores de LAI, puede verse en las figuras 3.9 a 3.11 para 1000 valores de la base de datos tomados al azar. Los mismos se comparan con los valores de reflectancia observados por MODIS con distintos índices de área foliar estimados a partir de fotografías digitales verticales e interpolados para la fecha en que se obtuvo la imagen satelital.

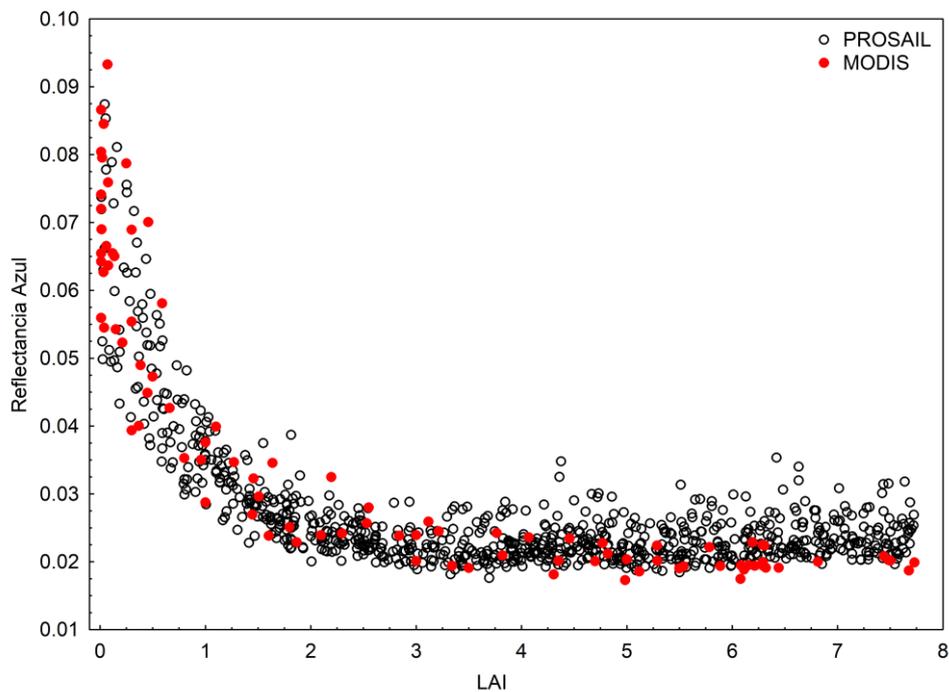


Figura 3.9 Valores de reflectancia en la banda azul estimados por PROSAIL para 1000 valores de la base de datos tomados al azar y los observados por MODIS en todos los lotes con soja (campaña 2005-2006), en función del LAI.

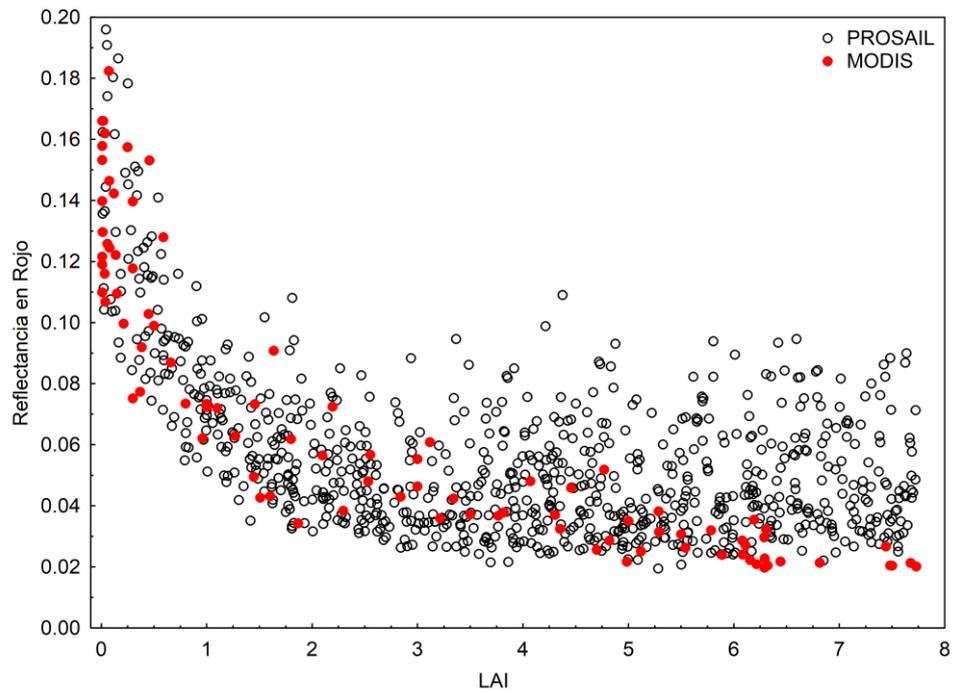


Figura 3.10 Valores de reflectancia en la banda roja estimados por PROSAIL para 1000 valores de la base de datos tomados al azar y los observados por MODIS en todos los lotes con soja (campaña 2005-2006), en función del LAI.

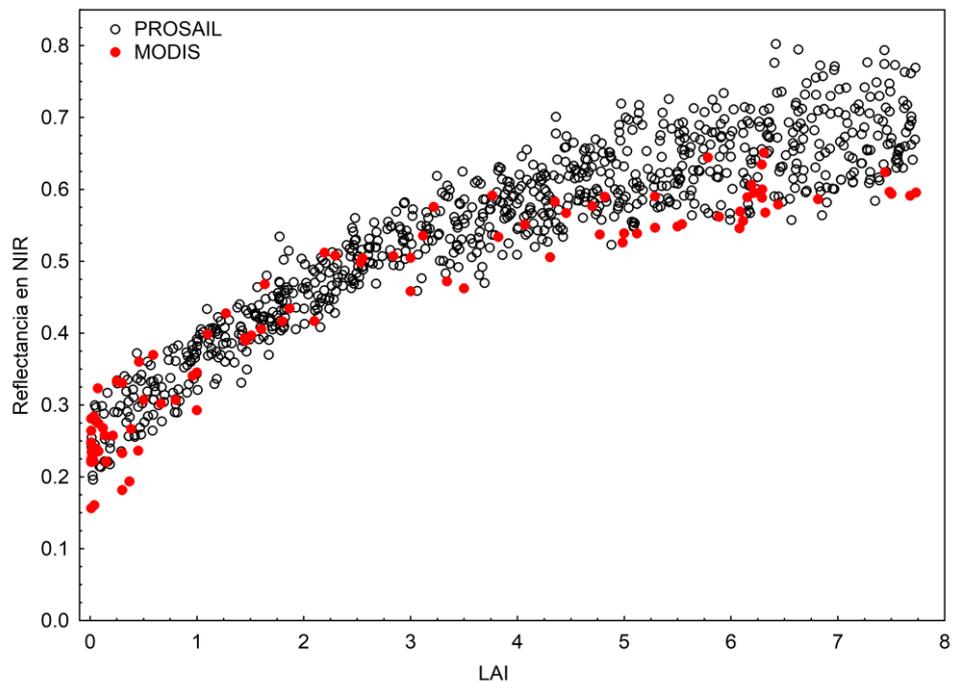


Figura 3.11 Valores de reflectancia en la banda NIR estimados por PROSAIL para 1000 valores de la base de datos tomados al azar y los observados por MODIS en todos los lotes con soja (campaña 2005-2006), en función del LAI.

Como puede advertirse en las figuras 3.9 a 3.11 las reflectancias del canopy simuladas por PROSAIL muestran la evolución típica con el incremento del LAI: un aumento de la absorción en la porción correspondiente al azul y rojo del espectro de radiación y un incremento en la reflectancia en la porción NIR. En estas figuras también se puede observar una estimación consistente de las reflectancias en las bandas azul, rojo e infrarrojo cercano, por parte del modelo PROSAIL al compararlas con las observadas por el sensor MODIS. Se evidencian algunas diferencias, en particular con valores elevados de LAI (superiores a 4) y en las bandas roja e infrarroja.

A partir de las reflectancias estimadas por PROSAIL en rojo y NIR se calculó el valor de NDVI, dichas estimaciones se muestran en la figura 3.12 y se comparan con los valores obtenidos del producto MODIS MYD13Q1 para distintos valores de LAI.

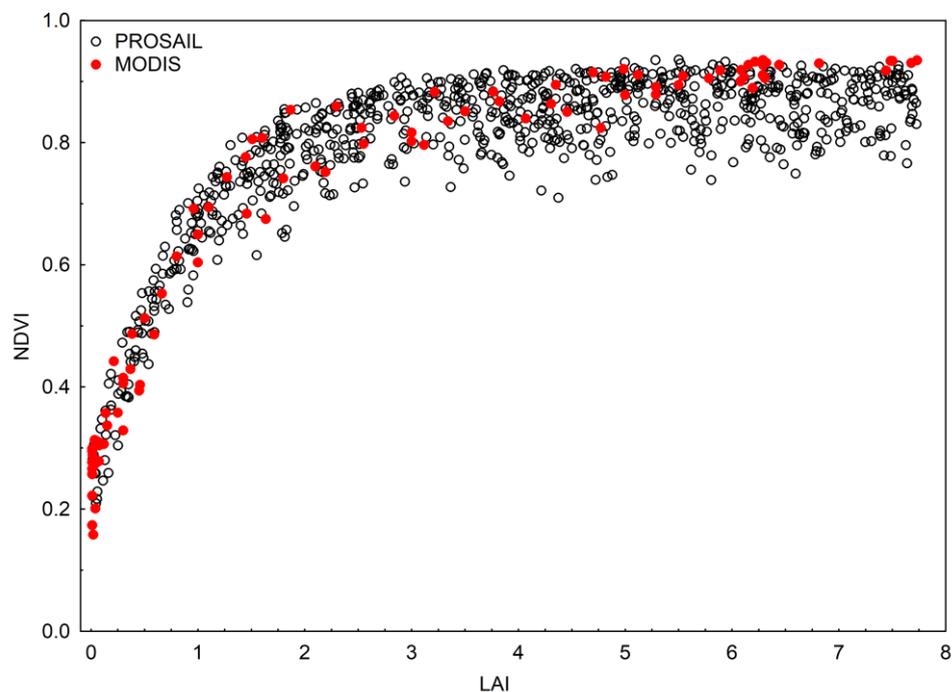


Figura 3.12 Valores de NDVI calculados a partir de PROSAIL para 1000 valores de la base de datos tomados al azar y los obtenidos de MODIS en todos los lotes con soja (campaña 2005-2006), en función del LAI.

Como resultado de las sobrestimaciones de PROSAIL de las reflectancias en rojo y NIR, con valores de LAI superiores a 4, los valores de NDVI calculados a partir de las reflectancias obtenidas de PROSAIL, presentan subestimaciones con respecto a los valores de NDVI obtenidos del producto de MODIS MYD13Q1 para esa condición.

A los efectos de tener una medida del error entre los valores estimados por PROSAIL y los medidos por MODIS, se procedió a calcular las medianas de los valores de reflectancias en azul, rojo y NIR y del NDVI correspondientes a intervalos de LAI tomados cada 0,5. Los resultados se presentan en la figuras 3.13 a 3.16.

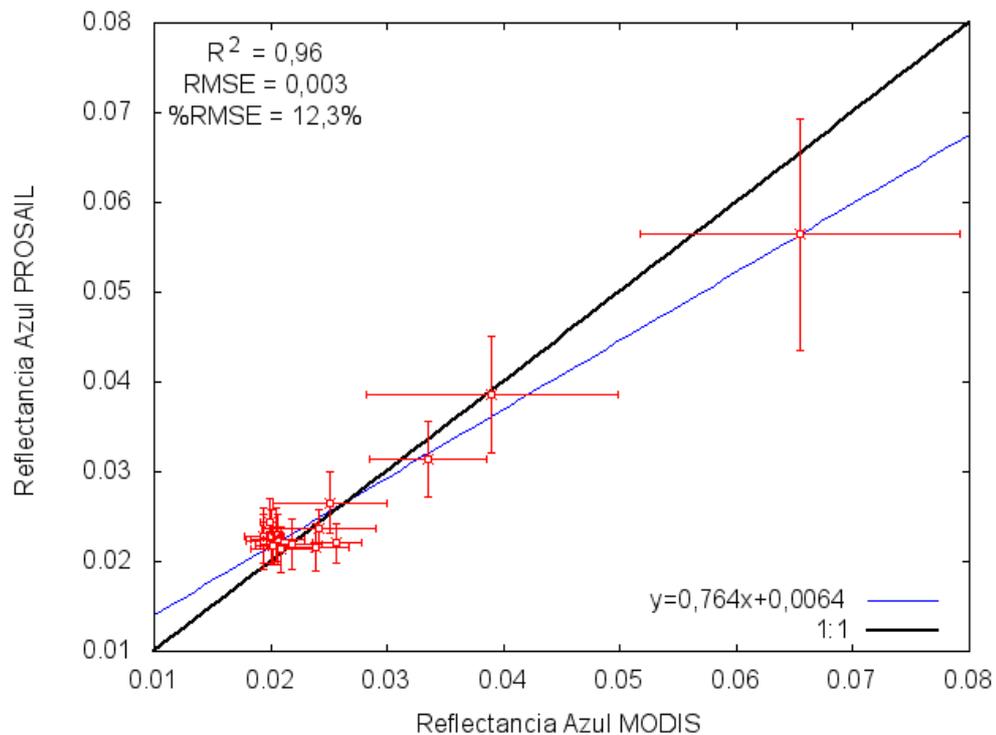


Figura 3.13 Dispersión entre los valores de mediana de reflectancia azul de PROSAIL y las medianas de MODIS MYD13Q1, calculadas con intervalos de 0,5 de LAI.

En la figura 3.13 se observa una subestimación por parte de PROSAIL para valores elevados de reflectancia azul, con respecto a los valores observados por MODIS. Asimismo, estos valores son los que también presentan la mayor variabilidad tanto de los datos simulados, tanto como los observados. Dicha subestimación puede deberse a errores en la elección de las reflectancias del suelo desnudo que, además, varía con los distintos tipos y grado de cobertura de residuos.

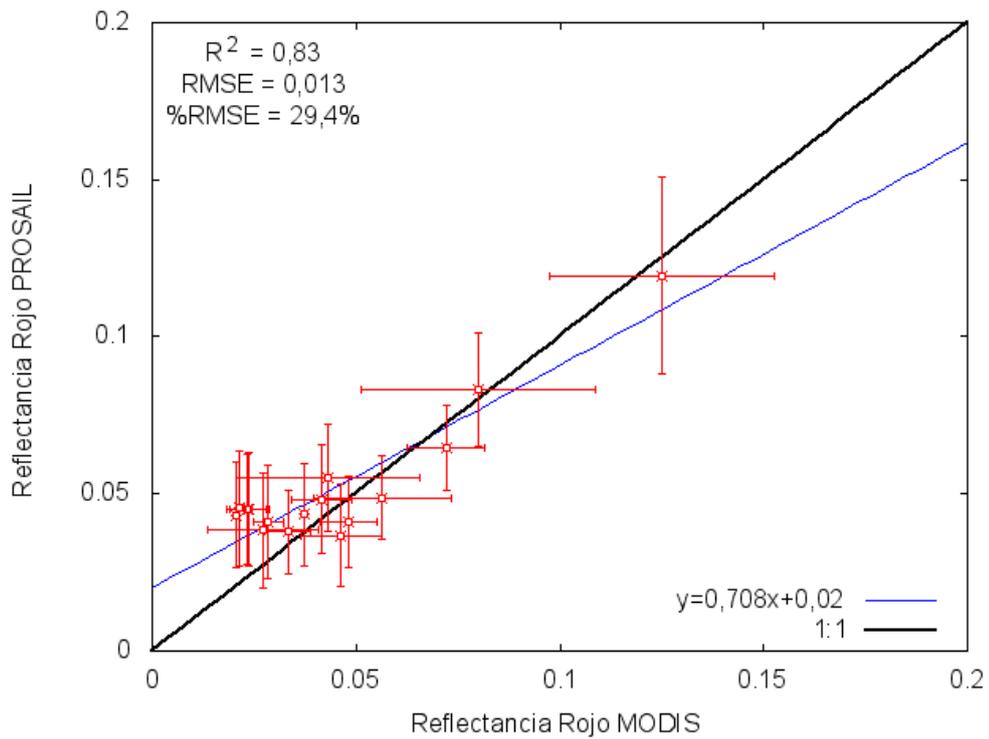


Figura 3.14 Dispersión entre los valores de mediana de reflectancia rojo de PROSAIL y las medianas de MODIS MYD13Q1, calculadas con intervalos de 0,5 de LAI.

Al contrario de la figura 3.13, PROSAIL estima de manera adecuada los valores elevados de reflectancia en rojo (figura 3.14), en tanto que para valores bajos, produce ligeras sobreestimaciones. Por otra parte, la figura 3.15 muestra que los valores de reflectancias en NIR, si bien son sobreestimadas con PROSAIL, presentan un mejor ajuste respecto a la estimación de la reflectancia en rojo en todo el rango de variación.

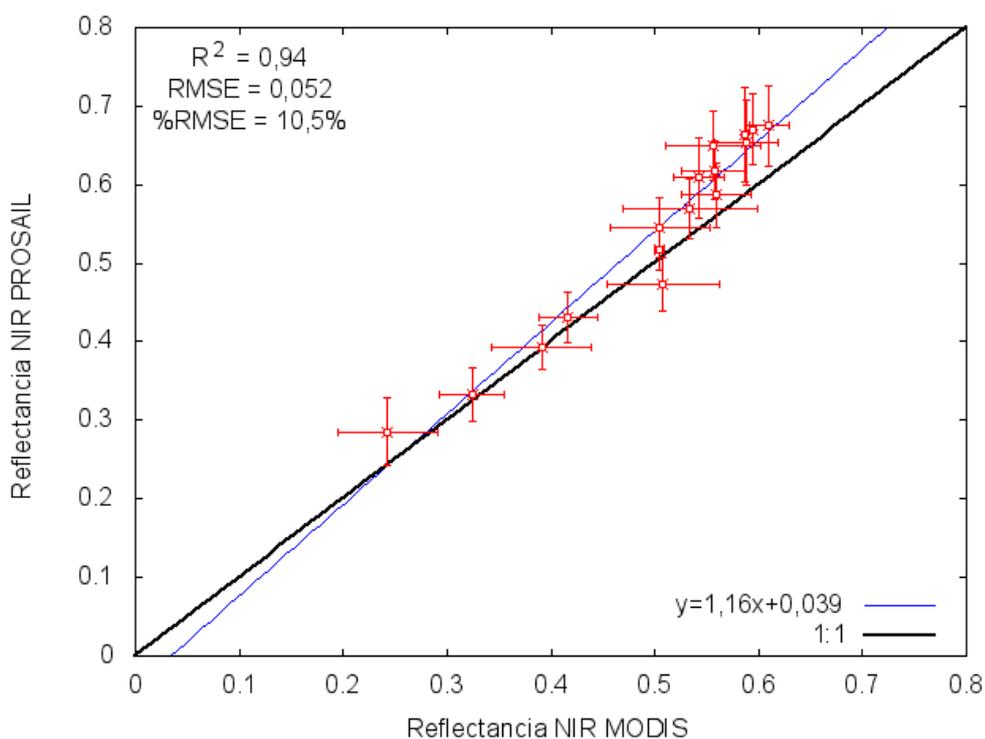


Figura 3.15 Dispersión entre los valores de mediana de reflectancia NIR de PROSAIL y las medianas de MODIS MYD13Q1, calculadas con intervalos de 0,5 de LAI.

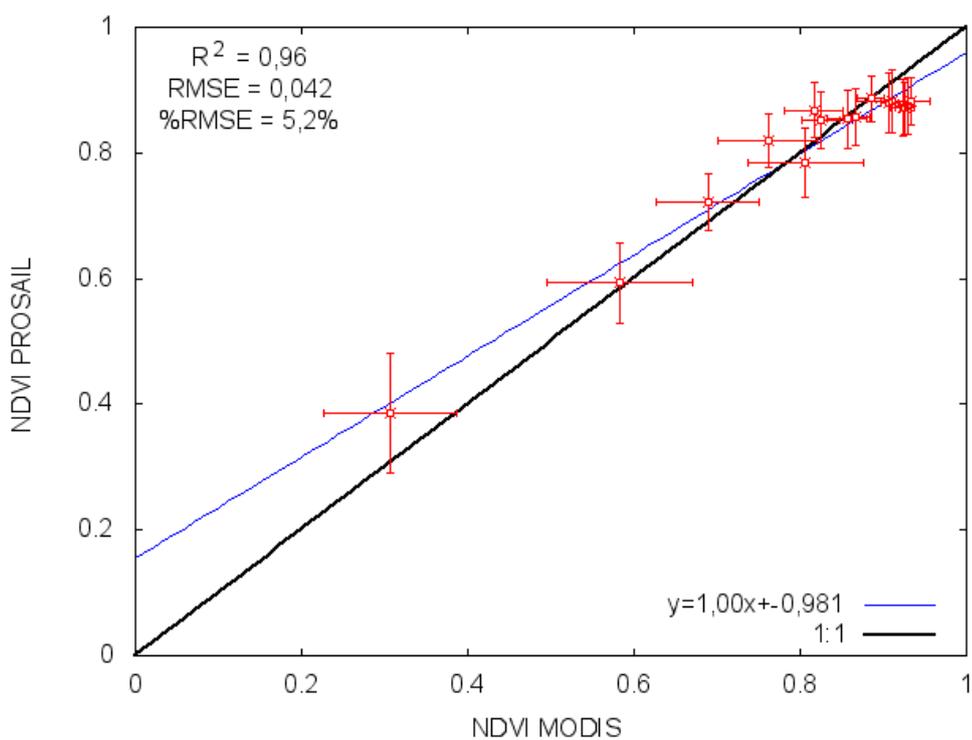


Figura 3.16 Dispersión entre los valores de mediana de NDVI de PROSAIL y las medianas de MODIS MYD13Q1, calculadas con intervalos de 0,5 de LAI.

Por su parte en la figura 3.16, se puede observar que el NDVI estimado por PROSAIL, respecto del observado por MODIS, presenta el mejor desempeño, cuando se lo compara con los errores de cada una de las bandas que intervienen en su cálculo. Con valores bajos de NDVI ($<0,4$) el modelo tiende a sobreestimar, error que puede deberse a la falta de información medida de reflectancia para los distintos tipos de suelos/rastrojo, rugosidad y contenido de humedad en la capa superficial.

3.9. Estimación del LAI a partir de Redes Neuronales Artificiales.

En el ítem anterior se mostraron los resultados de la generación de una base de datos sintética con el modelo físico de transferencia radiativa PROSAIL. Esta base de datos sintética está constituida por un conjunto de reflectancias derivado del modelo físico junto con los correspondientes parámetros de entrada del modelo. Los parámetros del modelo fueron elegidos teniendo en cuenta cubrir el rango posible de valores para el cultivo de soja. El paso siguiente consiste en invertir el modelo de transferencia radiativa para establecer una relación empírica entre los valores de LAI y los valores de los parámetros que definen las características radiativas de las hojas, los correspondientes a la geometría del sensor – sol – píxel observado, el coeficiente de humedad del suelo, las reflectancias y el NDVI (según corresponda) de la base de datos sintética. Para ello se emplearon las redes neuronales con las arquitecturas y procedimientos de entrenamiento y validación que muestra la tabla 2.6.

La validación se efectuó con todos los valores de LAI calculados a partir de su relación con el %C obtenido mediante fotografías digitales verticales, e interpolados para la fecha de obtención de la imagen MODIS, de la cual se utilizaron los valores de reflectancia en azul, rojo y NIR y el NDVI. También se emplearon, dependiendo del modelo de red neuronal, valores de geometría del sensor-sol-píxel observado, provenientes del producto MODIS-MYD13Q1, y valores de parámetros de la hoja (*Cab*, *Car*, *N*) y del suelo (*psoil*) obtenidos al azar según las distribuciones de la tabla 2.5.

El desempeño predictivo de los distintos modelos puede verse en la tabla 3.1.

Tabla 3.1 Valores del coeficiente de determinación y errores de validación de los distintos modelos de redes neuronales empleados para estimar el LAI a partir de la inversión del modelo PROSAIL, respecto de los valores de LAI calculados a partir de su relación con el %C obtenido mediante fotografías digitales verticales.

Modelos	R ²	RMSE	%RMSE
A001	0,953	0,622	21,7
A002	0,947	0,793	27,7
A003	0,935	0,710	24,8
A004	0,955	0,639	22,3
A005	0,935	0,910	31,7
A006	0,951	0,635	22,2
A007	0,952	0,821	28,6
A008	0,940	0,897	31,3
A009	0,928	0,919	32,1

En general todos los modelos de redes neuronales presentan un buen desempeño, con valores de R² entre 0,928 y 0,955, RMSE entre 0,622 y 0,919 y %RMSE entre 21,7 y 32,1%.

Para complementar la elección del modelo de redes neuronales a utilizar en la simulación de los valores de LAI que se emplean luego como dato de entrada al modelo de cultivo STICS, se procedió a analizar los distintos gráficos de dispersión entre los valores de LAI observado a partir de fotografías digitales verticales y posteriormente interpoladas a la fecha de adquisición de la imagen MODIS con respecto a los valores de LAI obtenidos por la inversión del modelo PROSAIL a partir de distintas arquitecturas de redes neuronales. Los resultados pueden observarse en las figuras 3.17 a 3.19.

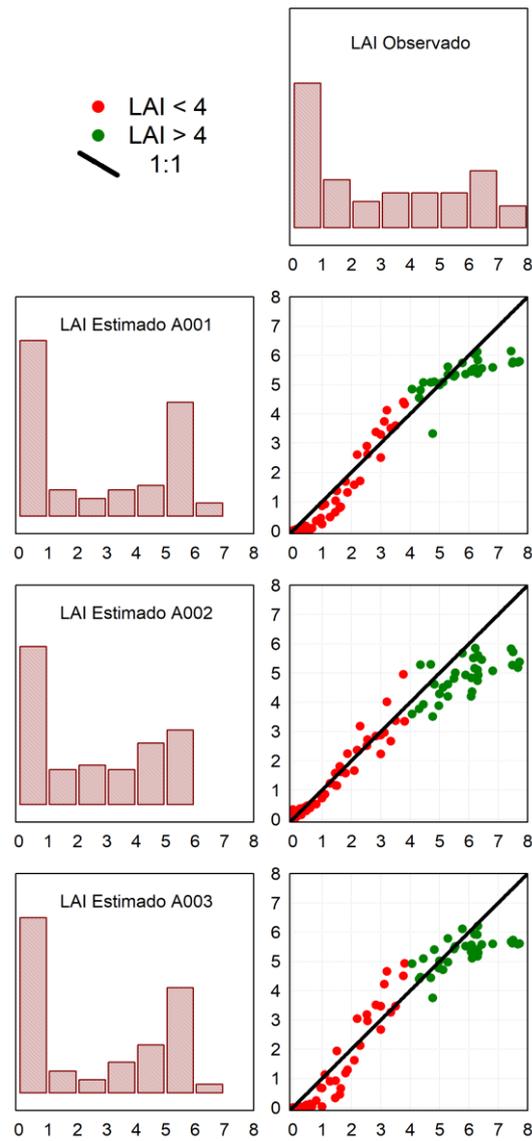


Figura 3.17 Dispersión entre los valores de LAI estimados con los modelos de redes neuronales A001, A002 y A003 con respecto a los valores obtenidos a partir de fotografías digitales verticales en todos los lotes con soja (campaña 2005-2006).

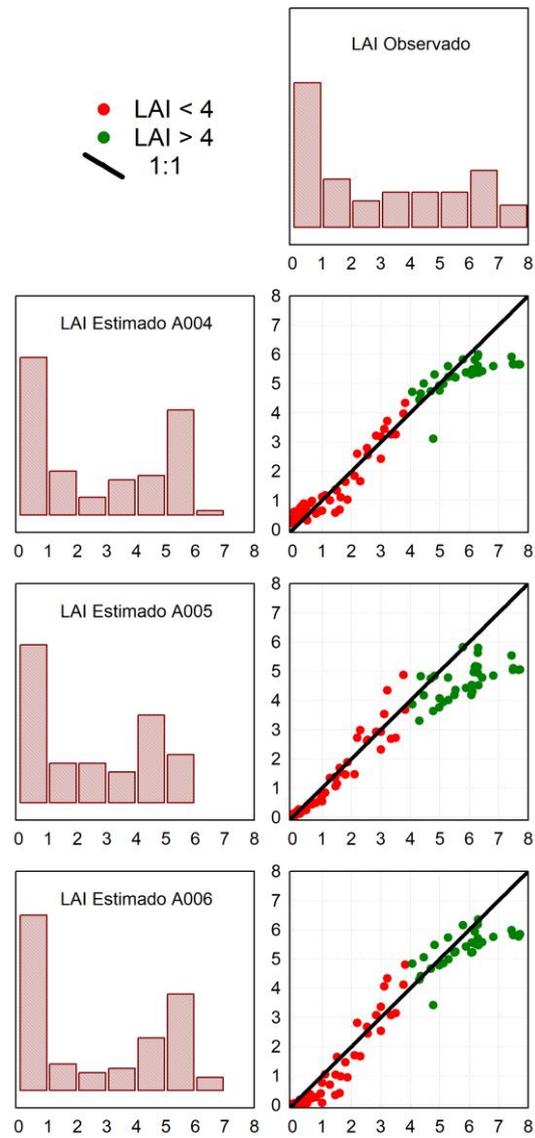


Figura 3.18 Dispersión entre los valores de LAI estimados con los modelos de redes neuronales A004, A005 y A006 con respecto a los valores obtenidos a partir de fotografías digitales verticales en todos los lotes con soja (campaña 2005-2006).

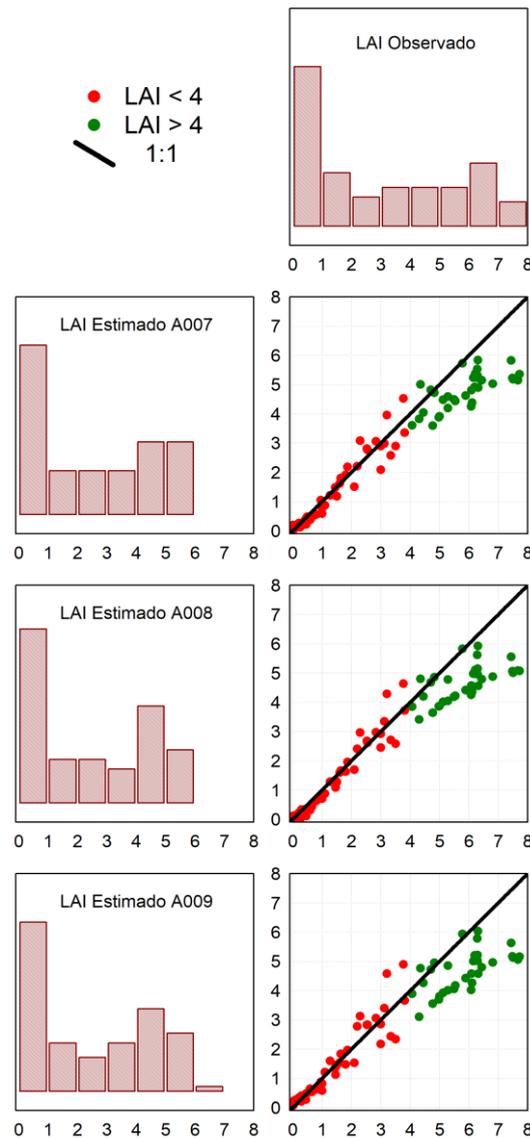


Figura 3.19 Dispersión entre los valores de LAI estimados con los modelos de redes neuronales A007, A008 y A009 con respecto a los valores obtenidos a partir de fotografías digitales verticales en todos los lotes con soja (campaña 2005-2006).

Como se puede observar en la figura 3.17, si bien el modelo A001 es el que mejor desempeño tuvo en cuanto a RMSE y R^2 , presenta sobre y sub estimaciones sistemáticas a lo largo del rango de valores de LAI observado, además de tratarse de la red que más variables de entrada requiere (propiedades de las hojas, psoil, geometría de la observación y reflectancias). Un comportamiento similar presentan los modelos A003, A004 y A006 (figuras 3.17 y 3.18).

El resto de los modelos (figuras 3.17 a 3.19) presentan subestimaciones para valores de LAI observados superiores a 4, posiblemente debido a la influencia que ejercieron los valores de reflectancia en rojo y NIR de la base de datos. Tales imprecisiones en la estimación de LAI para valores superiores a 4 no resultarían de gran importancia dado que su empleo es en modelos de cultivos que basan sus determinaciones en el concepto de eficiencia del uso de la radiación, a partir del valor de la radiación interceptada/absorbida.

En función de lo antes dicho se calcularon los valores de error para los distintos modelos de redes neuronales, pero para estimaciones de LAI menor o igual que 4. Los resultados se muestran en la tabla 3.2. y las diferencias de cada estadístico con respecto al valor original se presentan en la tabla 3.3.

Tabla 3.2 Valores del coeficiente de determinación y errores de validación de los distintos modelos de redes neuronales para valores observados de LAI menores o iguales que 4.

Modelos	R ²	RMSE	%RMSE
A001	0,934	0,403	36,3
A002	0,931	0,318	28,6
A003	0,903	0,518	46,7
A004	0,906	0,373	33,6
A005	0,929	0,338	30,5
A006	0,905	0,454	40,9
A007	0,938	0,301	27,1
A008	0,945	0,300	27,0
A009	0,901	0,389	35,0

Tabla 3.3 Diferencias entre los coeficientes de determinación y los errores de validación de los distintos modelos de redes neuronales para todos los valores observados de LAI y aquellos menores o iguales que 4.

Modelos	R ²	RMSE	%RMSE
A001	0,020	0,219	-14,610
A002	0,017	0,475	-0,976
A003	0,031	0,191	-21,934
A004	0,049	0,266	-11,278
A005	0,006	0,571	1,269
A006	0,046	0,181	-18,731
A007	0,013	0,520	1,574
A008	-0,005	0,598	4,308
A009	0,026	0,530	-2,994

Como puede observarse en las tablas 3.2 y 3.3, al considerar solamente valores de LAI menores o iguales que 4 en la validación de las redes neuronales artificiales, el modelo que mejor desempeño muestra es el A008, con la ventaja adicional de utilizar únicamente reflectancias en azul, rojo y NIR.

Debido a ello es que se decidió realizar un análisis minucioso de la evolución de los valores de R^2 y RMSE del modelo A008 a medida que se incrementaban los valores de LAI. Dicha relación se muestra en la figura 3.20. En ella se puede apreciar un incremento notable de los valores de RMSE a medida que aumentan los valores de LAI observados, en tanto que los valores de R^2 permanecen medianamente constantes y con valores superiores a 0,92.

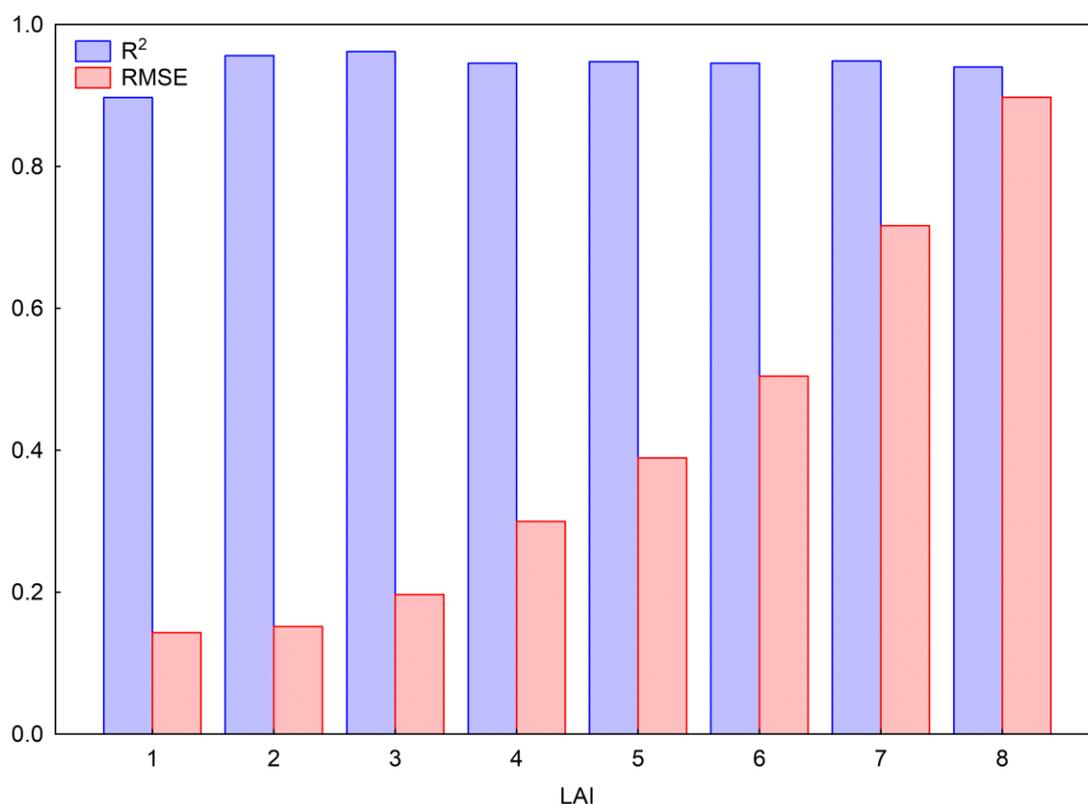


Figura 3.20 Variación de los valores de R^2 y RMSE para distintos intervalos de LAI hasta los que se evaluó el desempeño del modelo de redes neuronales A008 en la fase de validación.

Como resultado de esta evaluación del error, el modelo de cultivo STICS será evaluado con los valores de LAI estimados a partir del modelo de redes neuronales A008.

3.10. Modelo STICS

A los efectos de ajustar los valores de LAI estimados a partir de la inversión del modelo de redes neuronales A008, se modificaron los siguientes parámetros del modelo STICS (Tabla 3.4).

Tabla 3.4 Parámetros del cultivar del modelo STICS calibrados para cada lote.

Lotes	Parámetros del Cultivar					
	stlevamf	stamflax	stlevdrp	stlaxsen	stsenlan	stdrpmat
	°Cd					
1	330	480	900	450	1320	1000
2	400	530	900	450	1320	1000
3	600	330	900	450	1620	1300
4	500	380	1000	550	500	900
5	500	450	900	600	500	900
6	450	500	900	400	400	900
7	450	450	900	650	400	1000
8	300	500	700	500	400	1000
9	500	500	1300	550	500	1000
10	500	400	1000	600	500	1100

Referencias: stlevamf: grados días entre emergencia y la máxima tasa de crecimiento foliar; stamflax: grados días entre la máxima tasa de crecimiento foliar y el máximo índice de área foliar; stlevdrp: grados días entre la emergencia y el comienzo de llenado de granos; stlaxsen: grados días entre el máximo índice de área foliar y la senescencia foliar; stsenlan: grados días entre la senescencia foliar y el índice de área foliar nulo; stdrpmat: grados días entre el comienzo de llenado de granos y la madurez fisiológica.

En la tabla 3.4 se observa que los menores valores asignados a stlevamf para los lotes 1 y 8 que corresponden a variedades con un rápido crecimiento del LAI, y por el contrario, lotes cuyas variedades poseen valores más elevados de stlevamf (P Ej. Lotes 3 y 4) son los que presentan menores valores de stamflax, compensando el tiempo térmico desde emergencia hasta alcanzar el máximo LAI. Particularmente el lote 3 es el que exhibe el cultivar con el ciclo más largo (161 d). La reducción del valor de stamflax, lleva a una estimación más reducida del valor de LAI máximo, en concordancia con lo planteado por Jégo *et al.* (2010). El parámetro stlevdrp, por su parte, se encuentra asociado a la fecha de siembra del cultivar, los mayores valores correspondientes a las variedades presentes en los lotes 4, 9 y 10 que corresponden a las fechas de siembra más tempranas (entre el 25/oct y 1/nov). Los valores de stlaxsen y stsenlan fueron modificados en procura de tener un buen ajuste con la evolución del LAI durante la senescencia y los valores de stdrpmat, concordantes con la fecha madurez y cosecha del cultivo.

El modelo de cultivos STICS en su versión STICS-feuille (STICS-f) presenta la utilidad de “forzar” la actualización de una variable de estado como es el LAI, que requiere de un perfil diario de valores de LAI. Como resulta difícil obtener valores diarios de LAI observados, el software presenta una herramienta para interpolar algunas mediciones de LAI, empleando la ecuación 6. Los coeficientes obtenidos del proceso de ajuste a partir del cual se interpolaron los datos de LAI obtenidos de la inversión del modelo de redes neuronales A008, se muestran en la tabla 3.5.

Tabla 3.5 Coeficientes de ajuste para estimar LAI en STIC-f en los distintos lotes.

Lotes	Coeficientes de Ajuste				
	k	b (°Cd) ⁻¹	Ti °Cd	a (°Cd) ⁻¹	Tf °Cd
1	5,58	0,011	705	0,005	2082
2	5,45	0,053	702	0,005	2122
3	4,90	0,010	800	0,004	2300
4	7,79	0,005	793	0,002	2104
5	5,84	0,008	939	0,005	2073
6	6,01	0,012	754	0,002	2200
7	4,40	0,015	701	0,007	2043
8	6,75	0,007	600	0,002	1963
9	4,37	0,010	900	0,009	2195
10	4,72	0,007	794	0,006	2239

Referencias: k= índice de área foliar máximo

b= máxima tasa de crecimiento del índice de área foliar

T_i= suma de temperatura cuando ocurre la máxima tasa de crecimiento del índice de área foliar

a= máxima tasa de senescencia del índice de área foliar.

T_f= suma de temperatura cuando ocurre la máxima tasa de senescencia del índice de área foliar.

Los coeficientes presentados en la tabla 3.5 ponen en evidencia los diferentes comportamientos de las variedades de soja presentes en los distintos lotes. Los lotes 1; 2; 3 y 5 fueron sembrados el 10/nov/2015 y presentan valores de los coeficientes de ajuste para el LAI similares, las mayores diferencias pueden observarse en las sumas térmicas correspondientes al momento de máxima tasa de crecimiento, siendo las variedades sembradas en los lotes 3 y 5 las que tuvieron mayores requerimientos en sumas térmicas para alcanzar la máxima tasa de crecimiento del LAI. Por su parte el lote 3 que presentó la duración del ciclo más larga (160d) también mostró la mayor suma térmica para alcanzar la máxima tasa de senescencia del LAI. En el caso de los lotes 4 y 10, que fueron sembrados en 1/nov/2015, presentaron aproximadamente la misma suma térmica al momento de alcanzar

la máxima tasa de crecimiento del LAI. Las mayores diferencias entre estos dos lotes se encuentra en el valor del LAI máximo, ya que en el lote 4 fue notablemente superior al del lote 10, diferencia que en parte puede deberse a la distinta densidad de siembra (54 y 32 pl/m², respectivamente). Los lotes 6; 7 y 8 fueron sembrados a fines de noviembre de 2015, sin embargo el lote 7 es el que presenta el menor valor de LAI máximo observado (4,56), lo que se ve reflejado en los valores de k estimados. Por último, el lote 9 es el que presenta la fecha de siembra más temprana (20/oct/2005) y el ciclo más corto (136d), su valor de LAI máximo observado también es bajo (4,85) lo que se evidencia en el valor de k estimado.

Una vez efectuada la calibración del modelo, se procedió a realizar corridas del modelo STICS para cada uno de los lotes monitoreados en el presente estudio de dos maneras: 1) sin forzado del LAI (STICS) y 2) con forzado del LAI (STICS-f).

3.10.1. Índice de Área Foliar

Las simulaciones de LAI obtenidas de los modelos STICS y STICS-f, se compararon con los valores observados mediante diferentes estadísticos que se presentan en la tabla 3.6. Por su parte, la Figura 3.21 presenta el gráfico de dispersión entre los valores de LAI observados y estimados por STICS y STICS-f, para todos los lotes en conjunto. En las Figuras 3.22 y 3.23 se muestra la evolución temporal de los valores de LAI observados y estimados para cada lote con los modelos STICS y STICS-f, respectivamente.

Tabla 3.6 Coeficientes de determinación y errores estadísticos en la estimación del índice de área foliar (LAI) con STICS y STICS-f.

	LAI - STICS	LAI - STICS-f
R ²	0,89	0,98
d	0,97	0,99
MAE	0,48	0,20
RMSE	0,71	0,30
%RMSE	29,2	12,2
BIAS	-0,15	0,02

Referencias: R² coeficiente de determinación, d índice de concordancia, MAE error absoluto promedio, RMSE raíz del error cuadrático medio, %RMSE raíz del error cuadrático medio relativo, BIAS error promedio.

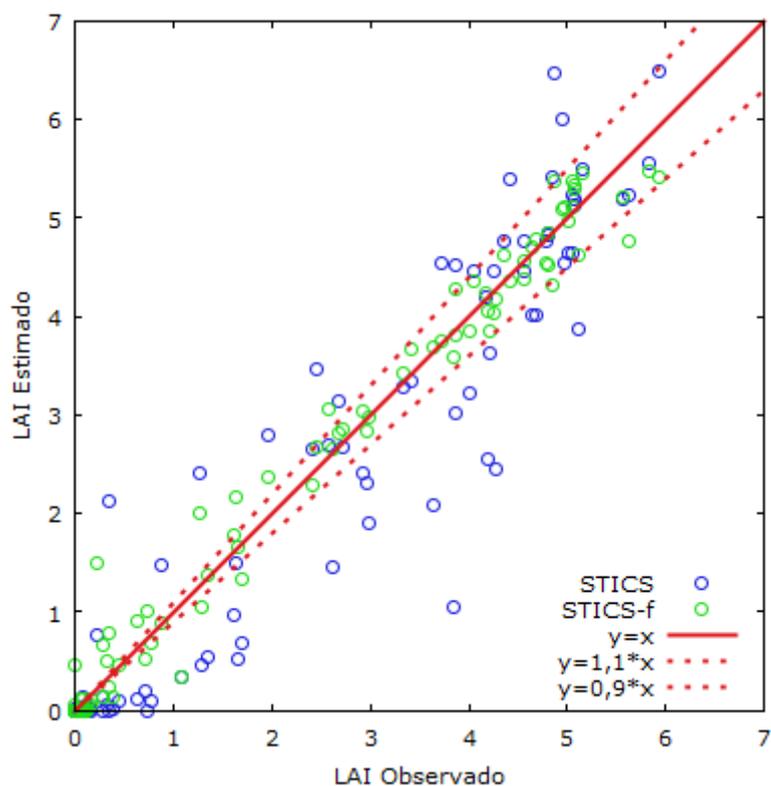


Figura 3.21 Relación entre los valores de índice de área foliar (LAI) observados y estimados por los modelos STICS y STICS-f, campaña 2005-2006.

En la Figura 3.21 se puede observar que la dispersión de los valores de LAI estimados por el modelo STICS respecto de los observados, es un tanto mayor de la que produce STICS-f. Esta menor dispersión en torno de la recta 1:1 posibilita que cuando el LAI observado supera 2,5, el 89% de los valores estimados se encuentre en torno al 10% del valor observado.

Como era de esperar, cuando el modelo es forzado a tomar valores de LAI, los errores de estimación disminuyen, presentando valores de %RMSE para STICS y STICS-f de 29,2% y 12,2%, respectivamente (Tabla 3.6).

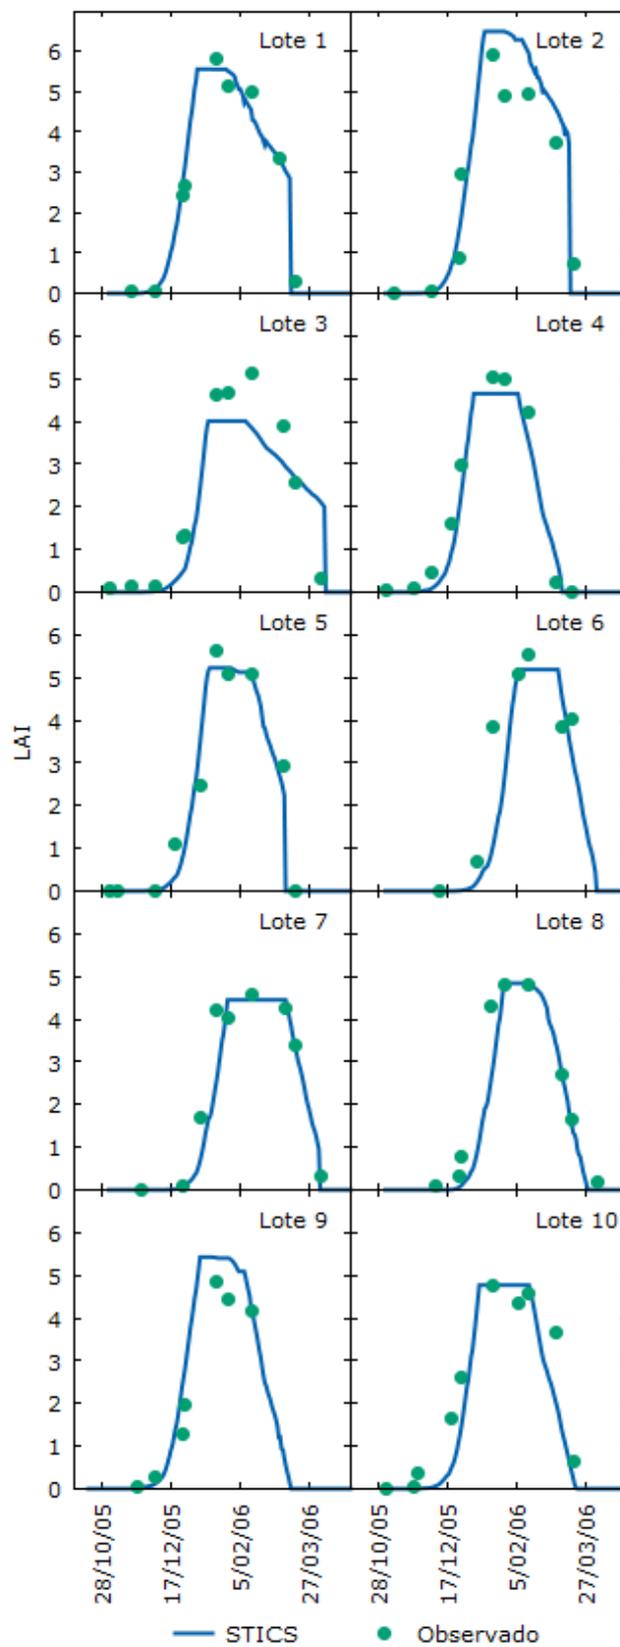


Figura 3.22 Evolución del índice de área foliar (LAI) simulado con STICS y observado en todos los lotes de soja, campaña 2005-2006.

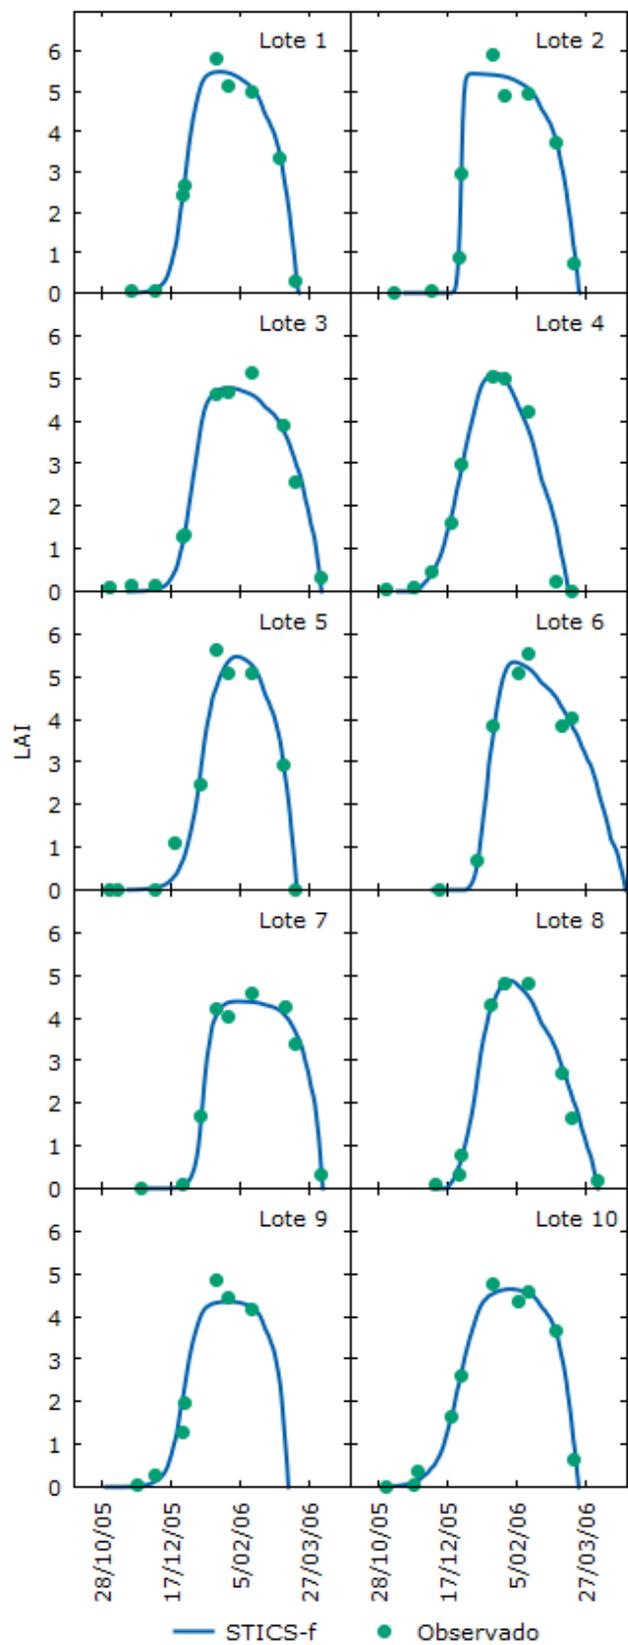


Figura 3.23 Evolución del índice de área foliar (LAI) simulado con STICS-f y observado en todos los lotes de soja, campaña 2005-2006.

El análisis de la serie de tiempo del LAI (Figuras 3.22 y 3.23), confirmó que tanto el modelo STICS como STICS-f fueron capaces de simular en forma adecuada la evolución del LAI de soja en los diferentes lotes en estudio. Particularmente el modelo STICS sobreestima los valores de LAI máximo en los lotes 2 y 9; y por el contrario subestima dicho valor en el lote 3. Por otra parte, los lotes 4; 6; 8 y 10 presentan un desfase en el crecimiento del LAI en las primeras etapas del cultivo y las estimaciones de STICS muestran un retraso. Las estimaciones de LAI realizadas por STICS-f mejoran sustancialmente la descripción de la evolución del canopeo.

Los valores estimados de LAI máximo fueron de 4,0 a 6,5 para STICS en tanto que para STICS-f el LAI máximo varió entre 4,35 y 5,49, mientras que los valores observados tuvieron un rango entre 4,56 y 5,93. El mayor valor de LAI observado fue de 5,93 y correspondió al lote 2, sembrado el 10/nov/2005 con 48 pl/m². Todos los lotes ubicados hacia el este en el área de estudio (lotes 1 a 6) presentaron valores de LAI máximo observado superiores a 5 en tanto que los lotes restantes (7 a 10) presentaron los menores valores de LAI máximo. Los dos menores valores de LAI máximo observado correspondieron a los lotes 7 y 10 (4,56 y 4,78, respectivamente) cuyas densidades de siembra también fueron las más bajas del monitoreo (40 y 32 pl/m², respectivamente).

3.10.2. Materia seca de la parte aérea

En la tabla 3.7 se muestran los estadísticos correspondientes a las simulaciones de biomasa de la parte aérea (MS) y la biomasa vegetativa de la parte aérea (MS-Veg) del modelo STICS y STICS-f, cuando se compararon con los respectivos valores observados. En la Figura 3.24 se presenta el gráfico de dispersión entre los valores de MS observados y estimados y en las Figuras 3.25 y 3.26 la evolución temporal de los valores de MS y MS-Veg observados y estimados para cada lote con los modelos STICS y STICS-f, respectivamente.

Tabla 3.7 Coeficientes de determinación y errores estadísticos en la estimación de materia seca (MS) y materia seca vegetativa (MS-Veg) con STICS y STICS-f.

	MS STICS	MS STICS-f	MS-Veg STICS	MS-Veg STICS-f
R ²	0,89	0,88	0,94	0,93
d	0,92	0,93	0,97	0,97
MAE (Mg/ha)	1,51	1,39	0,79	0,75
RMSE (Mg/ha)	2,69	2,50	1,36	1,32
%RMSE	75,5	70,2	51,2	49,7
BIAS (Mg/ha)	1,18	1,04	0,40	0,38

Referencias: R² coeficiente de determinación, d índice de concordancia, MAE error absoluto promedio, RMSE raíz del error cuadrático medio, %RMSE raíz del error cuadrático medio relativo, BIAS error promedio.

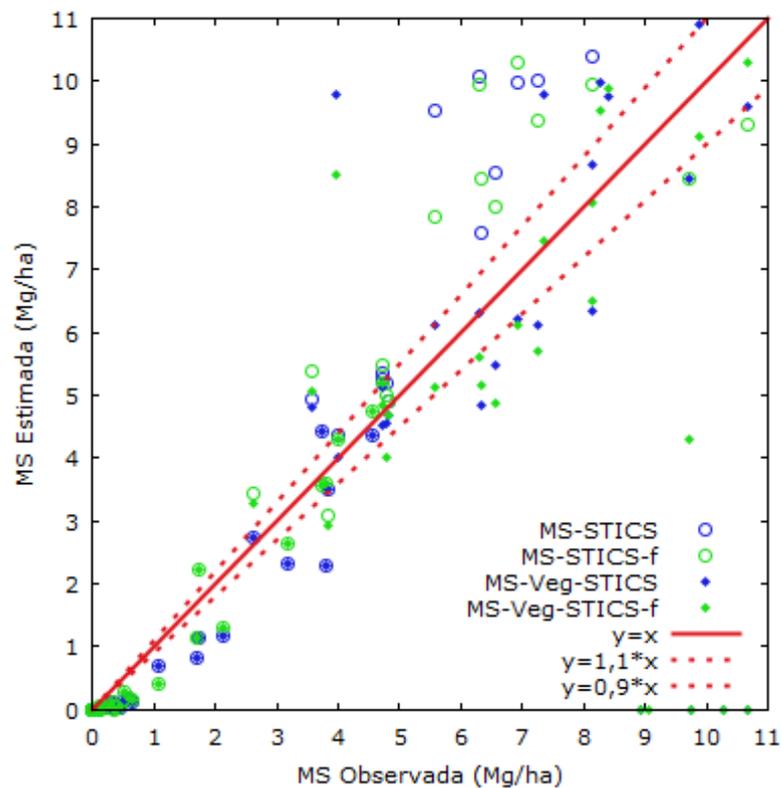


Figura 3.24 Relación entre los valores de la materia seca de la parte aérea (MS) y materia seca de la parte aérea vegetativa (MS-Veg) observados y estimados por los modelos STICS y STICS-f, campaña 2005-2006.

En la Figura 3.24, se aprecia que a partir de aproximadamente 5 Mg/ha de MS observada, tanto el modelo STICS como STICS-f tienden a sobreestimar los valores de MS. Por el contrario, si se consideran los valores de MS-Veg ambos modelos tienden a subestimar.

La evolución de los valores de la biomasa de la parte aérea (MS) y de la biomasa vegetativa de la parte aérea (MS-Veg) en función del tiempo, tanto de las estimaciones de los modelos STICS y STICS-f como de aquellos valores observados para todos los lotes en estudio, se muestran en las Figuras 3.25 y 3.26, respectivamente.

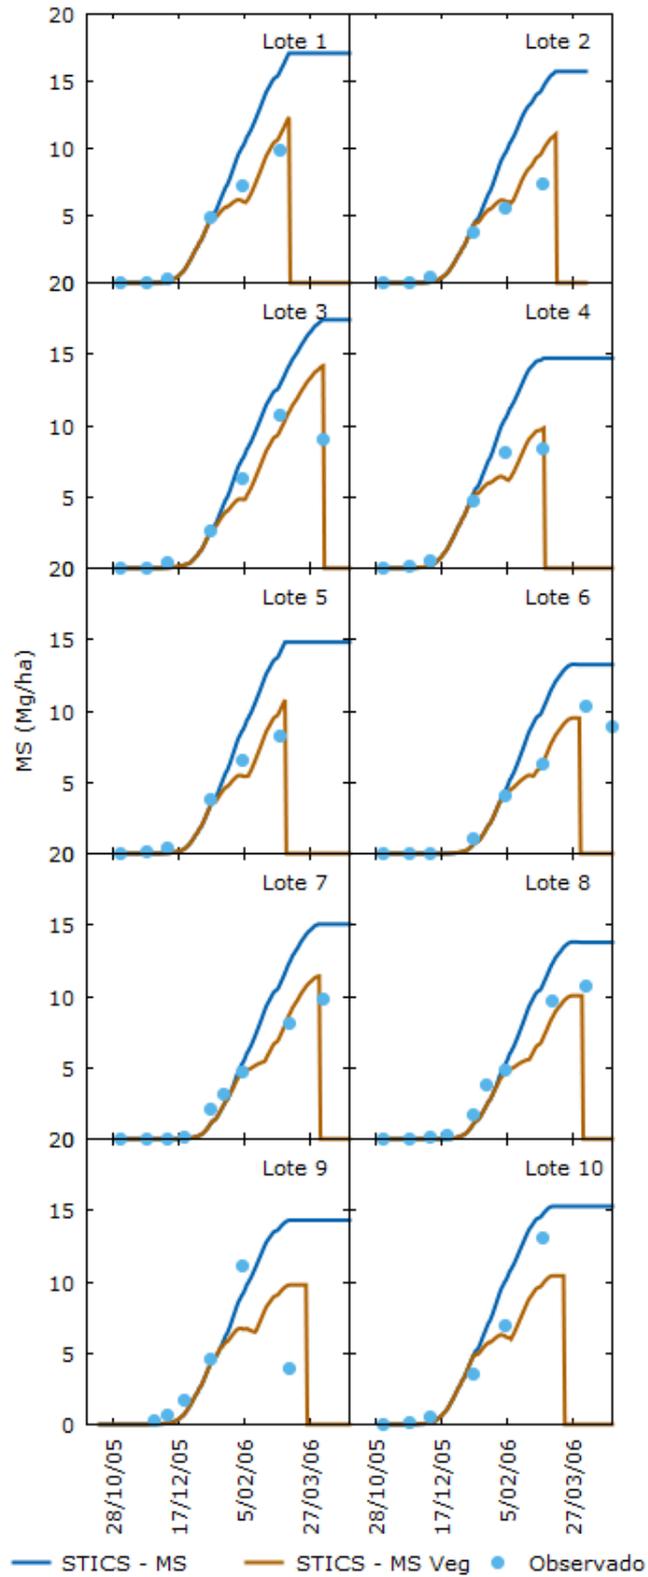


Figura 3.25 Evolución de la materia seca aérea (MS) y la materia seca vegetativa (MS-Veg) simuladas con STICS y la materia seca aérea observada de todos los lotes de soja, campaña 2005-2006.

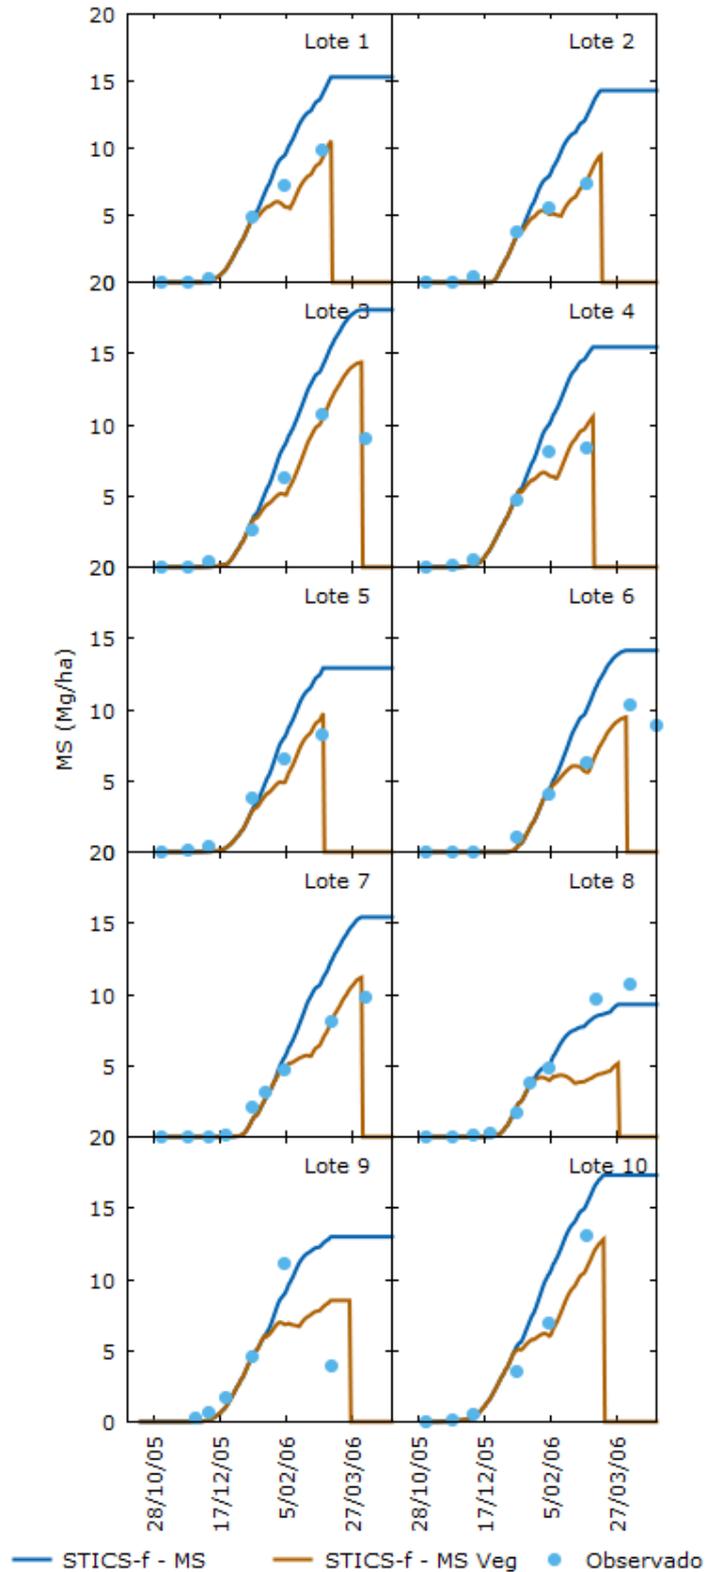


Figura 3.26 Evolución de la materia seca aérea (MS) y la materia seca vegetativa (MS-Veg) simuladas con STICS-f y la materia seca aérea observada de todos los lotes de soja, campaña 2005-2006.

En ambos modelos (Figuras 3.25 y 3.26) se puede observar que aproximadamente a partir del día 2/feb/2006, cuando los lotes presentan un desarrollo fenológico entre R2 y R5, comienza una sobreestimación de la materia seca en relación con los valores observados y, en la mayoría de los lotes, se asemejan a los valores de materia seca vegetativa. Los lotes 8 y 10 muestran un comportamiento diferente, donde los valores estimados de MS no se encuentran muy por encima de los valores observados y, particularmente en el lote 8, el modelo STICS-f tiende a subestimar los valores de materia seca observados. En estos últimos lotes se supera el valor de 5 Mg/ha de MS observado cuando los lotes se encontraban en inicio de formación de granos (R5).

3.10.3. Humedad del suelo

Los estadísticos correspondientes a las simulaciones del modelo STICS y STICS-f del contenido hídrico del suelo hasta 2m de profundidad (HS), cuando se compararon con los valores observados para el conjunto de lotes, se muestran en la tabla 3.8.

Tabla 3.8 Coeficientes de determinación y errores estadísticos en la estimación del contenido hídrico del suelo (HS) con STICS y STICS-f.

	HS - STICS	HS- STICS-f
R ²	0,75	0,81
d	0,93	0,95
MAE (mm)	22,89	19,02
RMSE (mm)	30,99	26,16
%RMSE	11,4	9,6
BIAS (mm)	8,08	1,64

Referencias: R² coeficiente de determinación, d índice de concordancia, MAE error absoluto promedio, RMSE raíz del error cuadrático medio, %RMSE raíz del error cuadrático medio relativo, BIAS error promedio.

En la Figura 3.27 se presenta el gráfico de dispersión entre los valores del contenido hídrico del suelo (HS) observados y estimados por los modelos STICS y STICS-f.

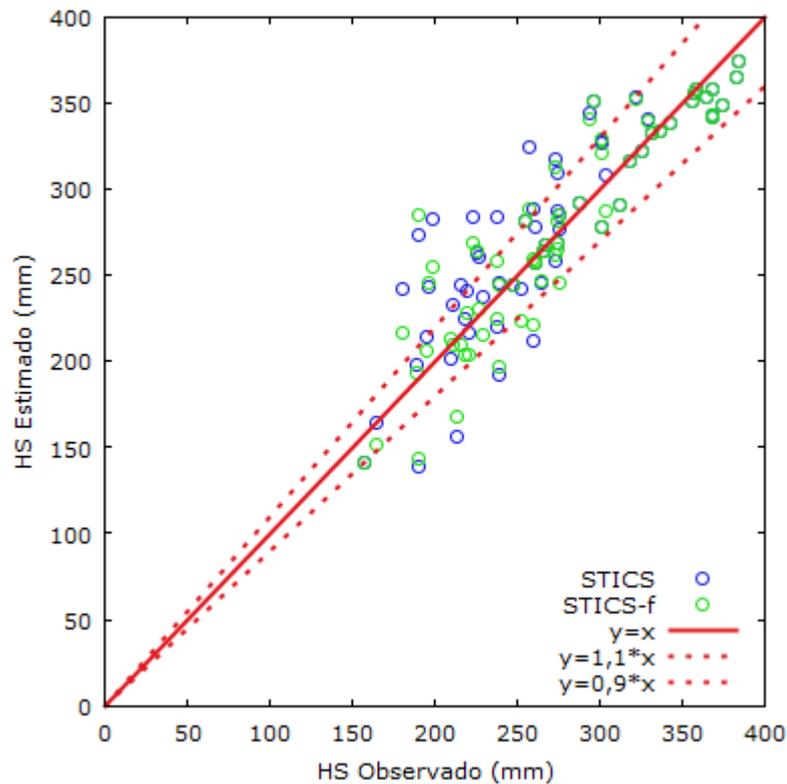


Figura 3.27 Relación entre los valores del contenido hídrico del suelo (HS) observados y estimados por los modelos STICS y STICS-f, campaña 2005-2006.

En la Figura 3.27 puede observarse un mejor desempeño del modelo STICS-f respecto del modelo STICS en la estimación de los valores de HS, que se corrobora con los valores presentados en la tabla 3.8.

La evolución de los valores del contenido hídrico del suelo hasta 2m de profundidad (HS), estimados por el modelo STICS y STICS-f y de los valores observados en los distintos lotes se puede ver en la Figura 3.28 y 3.29, respectivamente.

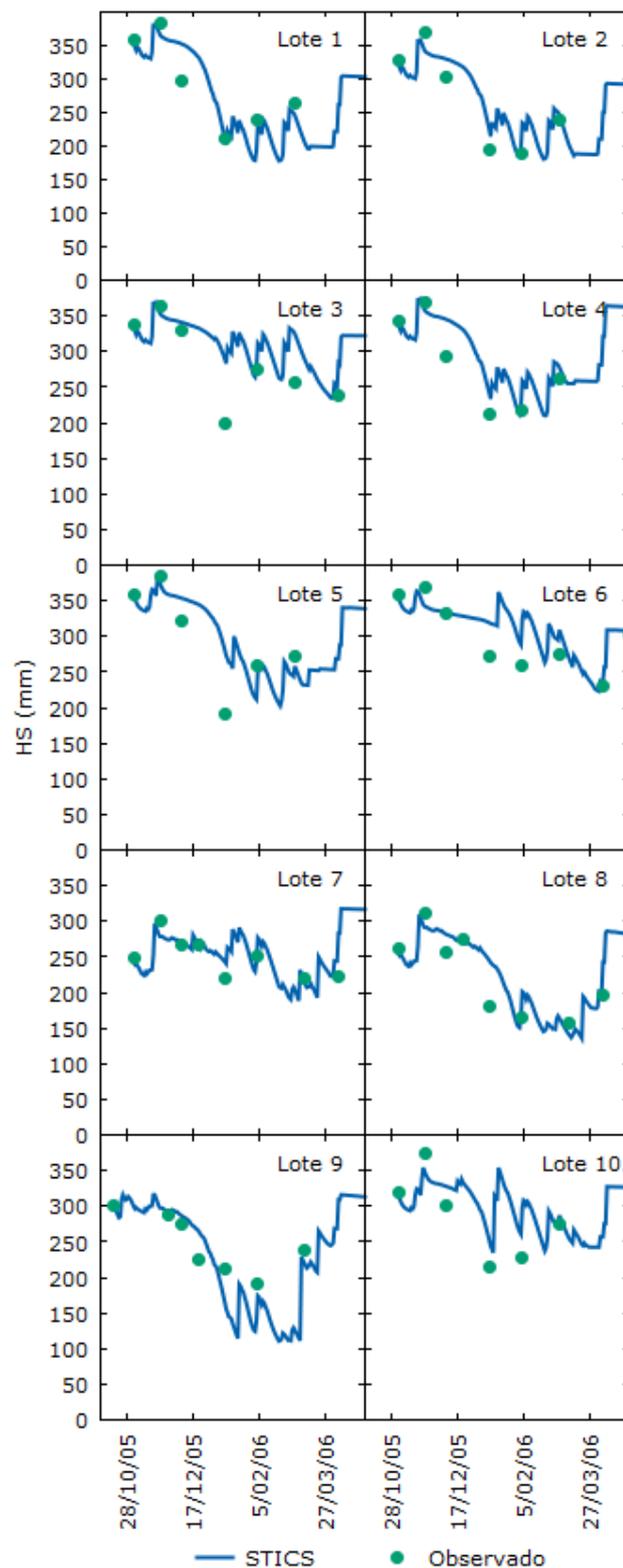


Figura 3.28 Evolución del contenido de humedad del suelo (HS), simulado con STICS y observado de todos los lotes de soja, campaña 2005-2006.

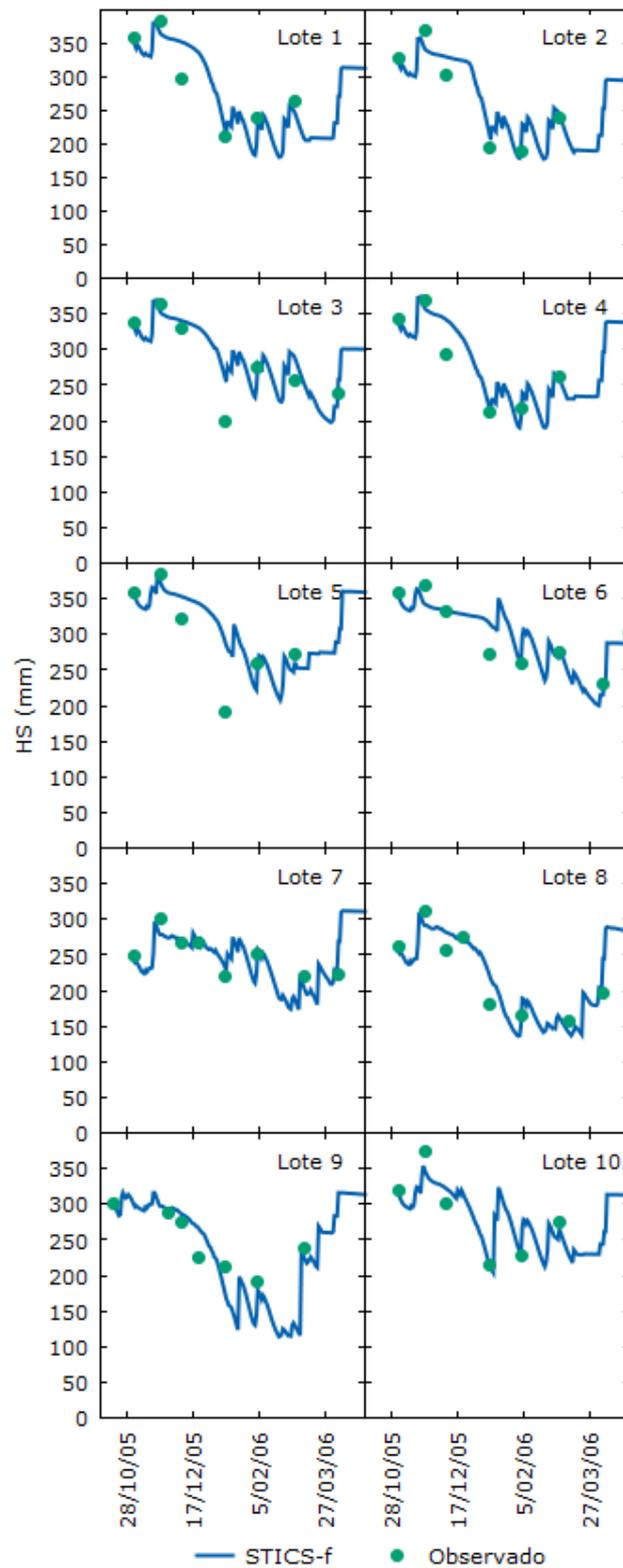


Figura 3.29 Evolución del contenido de humedad del suelo (HS), simulado con STICS-f y observado de todos los lotes de soja, campaña 2005-2006.

El contenido de humedad del suelo en el perfil (Fig. 3.28 y 3.29) fue, en términos generales, adecuadamente simulado por ambos modelos, siguiendo la dinámica del agua en el suelo y representando debidamente los incrementos y disminuciones que ocurren en períodos de recarga del perfil debido a precipitaciones seguidos por la extracción de agua por parte del cultivo en la estación de crecimiento. Si bien el empleo de STICS-f contribuyó a disminuir los errores, en ambos modelos algunos errores persisten. A modo de ejemplo, puede verse en los lotes 3 y 5 que los valores observados se encuentran muy por debajo de los estimados en la fecha 10/ene/2006. Dichos errores pueden deberse en parte al hecho que la simulación se efectúa hasta 2m de profundidad en tanto que por cuestiones operativas las muestras de suelo solo se obtuvieron hasta 80 cm de profundidad.

3.10.4. Rendimiento

Los estadísticos correspondientes a las simulaciones de rendimiento de los modelos STICS y STICS-f, cuando se compararon con los valores observados, se muestran en la tabla 3.9.

Tabla 3.9 Coeficientes de determinación y errores estadísticos en la estimación del rendimiento (RTO) con STICS y STICS-f.

	RTO - STICS	RTO - STICS-f
R^2	0,35	0,55
d	0,73	0,80
MAE (Mg/ha)	0,38	0,31
RMSE (Mg/ha)	0,47	0,41
%RMSE	11,5	9,9
BIAS (Mg/ha)	0,10	0,22

Referencias: R^2 coeficiente de determinación, d índice de concordancia, MAE error absoluto promedio, RMSE raíz del error cuadrático medio, %RMSE raíz del error cuadrático medio relativo, BIAS error promedio.

En la Figura 3.30 se presenta el gráfico de dispersión entre los valores de rendimiento observados y estimados por los modelos STICS y STICS-f.

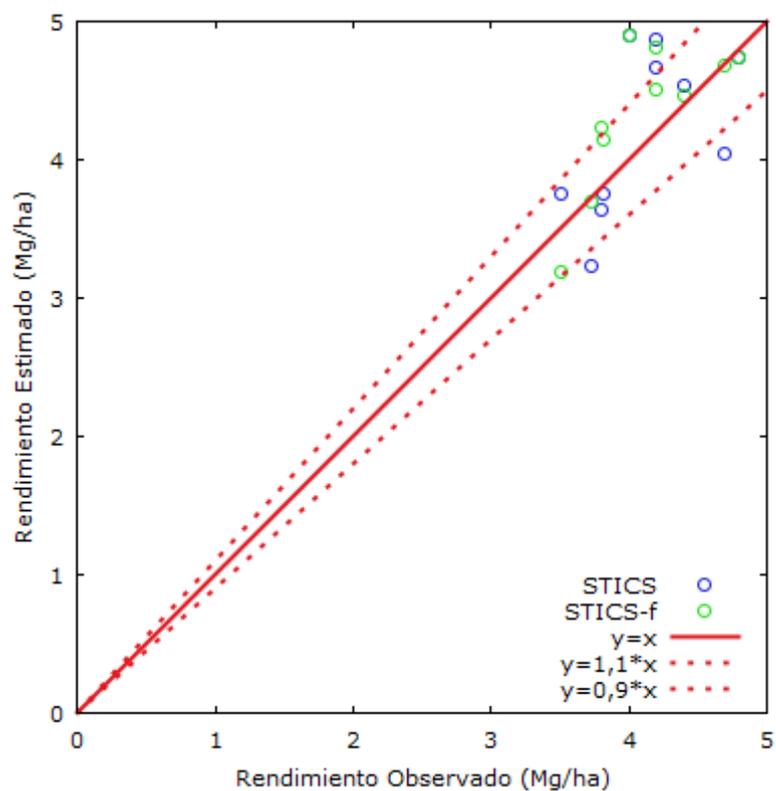


Figura 3.30 Relación entre los valores de rendimientos de soja observados y estimados por los modelos STICS y STICS-f, campaña 2005-2006.

Como puede observarse, STICS-f permitió estimar el rendimiento del cultivo de soja con valores similares de R^2 de 0,35 y 0,55 para STICS y STICS-f, respectivamente y valores de RMSE de 0,47 y 0,41 Mg/ha para STICS y STICS-f, respectivamente.

DISCUSIÓN

4.1. Determinación del porcentaje de cobertura de soja

Las fotografías digitales verticales aparecen con una opción adecuada para emplearse extensivamente en la determinación del porcentaje de cobertura del cultivo a campo; en concordancia con Yang *et al.* (2012) esta metodología presenta la ventaja de estar libre de la subjetividad de la mayoría de los otros métodos empleados a campo (grillas, transectas, sombreo, etc.), presenta alta precisión y buena estabilidad y es fácil de usar.

A pesar que la metodología que permite determinar la cobertura del cultivo de soja a partir de las fotografías digitales identifica adecuadamente los componentes vegetales y los diferencia del suelo y el rastrojo, el método produce algunos errores como cuando confunde las malezas vivas con el cultivo. Asimismo el suelo o cultivo sombreado resultan clases difíciles de separar, como así también cuando el cultivo comienza su senescencia, ya que si bien el procedimiento lo identifica como cobertura verde, su capacidad fotosintética ha disminuido notablemente. La discriminación entre canopeo y suelo resulta más fácil bajo condiciones de luz difusa, situación que a campo se logra con la presencia de nubes, disminuyendo de esta manera el error de clasificar hojas sombreadas como suelo.

4.2. Relación entre la Fracción de la Radiación Fotosintéticamente Activa Interceptada y la cobertura de soja.

El ajuste lineal entre %C y $fIPAR$ que se observa en la figura 3.2, también fue informado por Purcell (2000), quien presentó una relación 1:1 entre %C y $fIPAR$ con $R^2=0,94$ habiendo tomado las fotografías de soja, con 70° de inclinación respecto del horizonte. Gitelson *et al.* (2016) también presentaron una relación lineal entre $fAPAR$ y %C con valores de R^2 de 0,96 al analizar simultáneamente maíz y soja. Campillo *et al.* (2008), también determinaron una relación lineal entre $fAPAR$ y %C para un cultivo de tomate, donde los distintos métodos de estimación de %C presentaron relaciones lineales con pendientes inferiores a 1. De igual manera, Haverkort *et al.* (1991) encontraron una relación lineal entre $fIPAR$ y %C en papa, con valores de la pendiente inferior a 1 y ordenada al origen negativa, a diferencia de los resultados de este trabajo, donde la pendiente es ligeramente superior a 1 y la ordenada al origen es positiva. La $fIPAR$ se presentó marcadamente superior a la relación 1:1 con valores de %C entre aproximadamente 0,3 - 0,7. Un comportamiento similar entre $fAPAR$ y %C fue presentado por Klassen *et al.* (2003) quienes encontraron que plantas de lechuga bajo diferentes condiciones de temperatura exhibían distintas relaciones entre $fAPAR$ y %C. En particular las que crecieron a $30^\circ C$ mostraron valores de $fAPAR$ por encima de la relación 1:1 para valores de %C intermedios. Los autores atribuyeron este comportamiento a que las plantas que crecían en condiciones más cálidas tenían una arquitectura foliar más erecta respecto de aquellas que crecían en un ambiente más frío.

Las diferencias entre los valores de $fIPAR$ y %C pueden deberse a factores tales como la altura del cultivo, la distribución de los ángulos foliares, variaciones en el ángulo solar, en la proporción de radiación difusa respecto de la radiación directa y la orientación de los surcos, como así también por el grado y orientación de la ramificación del cultivo. Además, el estrés hídrico del cultivo podría causar modificaciones tanto en el %C como en la distribución de los ángulos foliares, cambiando la proporción de $fIPAR$. Por otra parte, la fotografía digital, a diferencia del interceptómetro, no considera la transmisión de la radiación por parte de las hojas. También resulta importante tener en cuenta que la determinación de %C mediante fotografía digital integra toda la variabilidad espacial de una superficie, a diferencia de la lectura estrictamente lineal que hace el interceptómetro.

4.3. Relación entre índice de área foliar y la cobertura de soja

La relación entre el LAI y %C presentada en la figura 3.3 también fue publicada por Liu & Pattey (2010) quienes ajustaron una función logarítmica entre la fracción de suelo desnudo ($1 - \%C$) y el LAI de maíz, trigo y soja, y obtuvieron un valor de $R^2 = 0,84$ similar al informado en esta tesis. Baret *et al.* (1993) establecieron una relación exponencial entre la fracción de suelo desnudo de cultivo de trigo y remolacha azucarera obtenidos a partir de fotografías digitales hemisféricas y el índice de área foliar con valores de RMSE y R^2 de 0,082 y 0,91, respectivamente.

Por su parte, España (1997) obtuvo un valor de -2.94 como coeficiente de la relación logarítmica entre LAI y %C para un cultivo de maíz, en tanto que en este trabajo el coeficiente fue -1,8233.

Otros autores (Haverkort *et al.*, 1991; Tei *et al.*, 1996) presentaron para la relación entre %C y LAI funciones bilineales en distintos cultivos hortícolas, utilizando una función lineal creciente hasta un valor de LAI (próximo a 3) en donde se alcanza un valor de %C próximo a 1 (ó 100%), a partir del cual la relación se vuelve constante (%C =1 ó 100%).

De manera similar a otros métodos propuestos por distintos autores (Liu & Pattey, 2010), la cobertura determinada mediante fotografías digitales se encuentra limitada para estimar el LAI cuando el cultivo se encuentra próximo a cubrir completamente el surco.

En tal sentido Ramirez-Garcia *et al.* (2012) para cebada, vicia y colza ajustaron modelos cuadráticos y lineales para la relación entre %C y LAI, con valores de R^2 iguales o mayores que 0,92, reportando un *plateau* en cebada cuando el LAI es mayor que 4.

4.4. Relación entre el índice de área foliar y el NDVI

A pesar que en esta tesis, la relación entre LAI y NDVI se muestra claramente no lineal a lo largo del ciclo de cultivo de soja (figura 3.4), otros autores determinaron una relación lineal entre NDVI y LAI. Entre otros Board *et al.* (2007) que obtuvieron una relación lineal (R^2 entre 0,95 y 0,97) en soja con una cámara multispectral montada sobre un camión, Colombo *et al.* (2003), con imágenes IKONOS ($R^2 = 0.74$) en soja; Lee *et al.* (2004) quienes emplearon AVIRIS y LANDSAT-ETM+ con R^2 de 0,79 y 0,61 para soja y maíz, respectivamente; Young Hong *et al.* (2004) con imágenes IKONOS y cámaras aerotransportadas en soja ($R^2 = 0,67$), si bien en estos dos últimos casos el coeficiente de determinación resulta bastante más bajo que los obtenidos en el presente trabajo (R^2 entre 0,91 y 0,93).

Walthall *et al.* (2004) emplearon los valores de NDVI de Landsat ETM+ para estimar la fracción de cubierta vegetal siguiendo a Choudhury *et al.* (1994), y a partir de este último valor emplearon una función logarítmica para calcular el LAI de maíz y soja, encontrando diferentes valores de R^2 y RMSE entre dos imágenes LANDSAT correspondiente a dos fechas de muestreo (R^2 0,87; RMSE 0,44 y R^2 0,48; RMSE 1,26, respectivamente). Los autores explicaron el peor desempeño de esta metodología para estimar LAI en la segunda fecha, argumentando que la presencia de humo sumada a la fenología del cultivo de maíz en panojamiento pudieron modificar los valores de reflectancia observados por el satélite.

En trigo, Yi *et al.* (2008) mostraron una relación lineal entre el LAI y el NDVI obtenido de MODIS Aqua, con valores de R^2 de 0,66 y 0,67 para NDVI obtenidos de imágenes diarias y compuestas de 8 días, respectivamente.

Jones (2002) empleando fotografías aéreas infrarrojas para determinar el NDVI, encontró correlaciones entre 0,46 y 0,90 entre NDVI y LAI para distintas variedades de soja, en distintos suelos y fases fenológicas, y presentó una relación lineal cuando el LAI

se encuentra por debajo de 3; en tanto que cuando los niveles de LAI superan este umbral, la relación se torna exponencial. Serrano *et al.* (2000) encontraron una respuesta curvilínea entre LAI y NDVI en trigo de invierno, que se satura para valores de LAI superiores a 3. En este trabajo la saturación del NDVI para el cultivo de soja, se encuentra con valores de LAI superiores a 4,0; umbral que permite estimar el LAI durante todo el periodo vegetativo.

Thenkabail *et al.* (2000) presentaron una relación exponencial entre NDVI y LAI de soja con $R^2 = 0,72$. El NDVI fue calculado a partir de reflectancias medidas con un espectro radiómetro para un ancho de banda equivalente a las Landsat TM. Por otra parte, Nguy-Robertson *et al.* (2012) mostraron una relación potencial entre LAI y NDVI para soja con R^2 de 0,92 para valores de LAI desde 0 a 5,5 y encontraron que el NDVI fue más sensible a LAI por debajo de 2.

Para trigo, maíz, girasol y soja Veloso *et al.* (2013) presentaron una relación exponencial entre LAI determinado a partir de fotografías hemisféricas y NDVI de SPOT y FORMOSAT, con valores de R^2 , RMSE y RMSE% de 0,86; 0,39 y 28,9%, respectivamente.

Guindin-García *et al.* (2012) encontraron una función matemática de segundo grado entre NDVI derivado de productos integrados MODIS de 8 ó 16 días con una resolución espacial de 250m y LAI de maíz con un valor de $R^2 = 0,96$. Yao *et al.* (2008) encontraron una relación exponencial entre LAI en maíz y NDVI de un espectroradiómetro, con R^2 0,95. De igual manera, Gutiérrez-Rodríguez *et al.* (2004) muestran una función cuadrática entre LAI en poroto y NDVI calculado a partir de los datos de un radiómetro portátil y obtuvieron valores de R^2 de 0,91 y 0,89 para tratamientos testigo y fertilizado con 200 kg ha^{-1} de nitrógeno. Vargas *et al.* (2002) establecieron una relación exponencial entre el NDVI y el LAI de *Miscanthus sinensis* 'Goliath' con valores de R^2 de 0,82, con un valor máximo de NDVI de 0,85 que comenzó a saturarse con valores de LAI próximos a 3. En todos los casos los valores de R^2 presentados por diferentes investigadores son similares a los encontrados en este trabajo.

Los errores en la estimación del LAI a partir del NDVI, puede deberse a distintos factores como ser, para las primeras etapas del cultivo, los distintos tipos de suelo, la presencia, tipo y cantidad de rastrojo, como así también la condición de humedad superficial del suelo que pueden afectar los valores de NDVI. En etapas más avanzadas, influyen otros factores como los cambios en el contenido de clorofila y la caída de hojas (a partir de R6 aproximadamente). Wahid *et al.* (2003) mostraron una relación exponencial entre LAI y NDVI ($R^2 = 0,56$) en arroz, exhibiendo el NDVI una saturación con valores de LAI mayores que 2 (que coincidió con la fase fenológica de emergencia de la panoja). Además encontraron que las hojas presentaron cambios significativos a lo largo del ciclo del cultivo para distintos tratamientos de fertilización nitrogenada.

4.5. Relación entre el NDVI y *f*IPAR

La fracción de la radiación fotosintéticamente activa interceptada por el cultivo de soja (*f*IPAR), fue estimada a partir del LAI mediante la ecuación (1) y comparada con el NDVI (Figura 3.5) donde puede observarse claramente una relación lineal entre *f*IPAR y NDVI, estos resultados concuerdan con los presentados por Daughtry *et al.* (1992) quienes encontraron una relación lineal entre *f*APAR medidos en cultivos de soja y maíz y el NDVI obtenido de un radiómetro portátil con un valor de $R^2=0,96$, idéntico valor al obtenido en este trabajo.

De manera similar, Di Bella *et al.* (2004) también presentaron una relación lineal entre *f*APAR en pasturas con el NDVI obtenido a partir de un radiómetro y Paz Rodríguez *et al.* (1999) mostraron una relación lineal entre NDVI – *f*APAR para arvejas y lupino con R^2 de 0,86 y 0,80, respectivamente. En el caso de arvejas, el autor separa tramos antes y después del LAI máximo debido a que presentan distintos comportamientos. Serrano *et al.* (2000) evaluaron la relación *f*IPAR – NDVI en trigo de invierno y encontraron una relación lineal con $R^2=0,81$, con mediciones realizadas hasta el comienzo de la senescencia del cultivo.

Morel *et al.* (2014) también presentaron una relación lineal entre $fIPAR$ y NDVI de SPOT 4 y 5 para caña de azúcar, con valores de $R^2=0,90$ y $RMSE = 0,085$, y encontraron que cuando el NDVI se satura ($NDVI=0,85$), el $fIPAR$ puede ser subestimado. Inoue *et al.* (2008) encontraron una relación lineal entre $fAPAR$ y NDVI ($R^2 = 0,628$) para arroz, cuyos valores se alejaron de la recta de ajuste en la etapa fenológica de madurez.

Guillén-Climent *et al.* (2012) presentaron una regresión de segundo grado entre $fIPAR$ medido con un interceptómetro en huertos de olivos y NDVI obtenido de un radiómetro multispectral aerotransportado, con un valor de $R^2 = 0,96$.

Debido a que el NDVI es sensible al contenido de clorofila, resulta razonable encontrar mayor dispersión de los datos de $fIPAR$ en las etapas reproductivas próximas a la senescencia del cultivo, comportamiento que puede observarse en la figura 3.5. Estos resultados concuerdan con los de Viña & Gitelson (2005) y Gitelson *et al.* (2014) que midieron $fAPAR - NDVI$ de hojas verdes y senescentes de maíz y soja, y encontraron para ambos cultivos la misma relación hasta el momento de la senescencia de las hojas. Mientras la disminución en NDVI resulta en una caída significativa de $fAPAR$ en soja, en maíz la disminución es sólo ligera.

4.6. Relación entre el NDVI y %C

En la figura 3.6 se muestra la relación lineal entre %C y NDVI, un comportamiento lineal similar informaron Rundquist *et al.* (2001) para maíz y Kancheva *et al.* (2005) en cebada, con datos de NDVI obtenidos a partir de un espectrómetro portátil, presentando valores de R^2 entre 0,95 y 0,97 para distintos tipos de suelos, valores similares al informado en el presente trabajo ($R^2 0,96$). Johnson & Trout (2012), también encontraron una fuerte una relación lineal entre %C de fotografías digitales y NDVI de LANDSAT 5 ($R^2 = 0.96$, $RMSE = 0,062$) con 18 tipos de cultivos diferentes. Jiménez-Muñoz *et al.* (2009) presentaron una relación lineal entre %C medida mediante fotografías hemisféricas tomadas con lente ojo de pescado en distintos cultivos y el NDVI obtenido a partir de imágenes PROBA/CHRIS con un valor de coeficiente de determinación de 0,83, inferior al obtenido en este trabajo. Zha *et al.* (2003) establecieron una relación lineal entre %C de una pastura con el NDVI obtenido a partir de un radiómetro con un R^2 de 0,74.

Por otra parte Gitelson *et al.* (2002a) muestran una relación no lineal entre NDVI y %C en trigo, siendo menos sensible el NDVI cuando el valor de %C supera el 50%. Purevdorj & Teteishi (1998) presentaron en pasturas, ecuaciones de segundo grado para la relación entre %C y NDVI obtenido de un espectroradiómetro portátil.

4.7. Relación entre el NDVI y Biomasa de la parte Aérea

La variación de la biomasa en función del NDVI para distintas fases fenológicas (figura 3.7.) muestra una relación claramente no lineal con el NDVI, hasta la etapa de R4 ($R^2 = 0,96$), a partir de la cual se pierde la relación. Los resultados obtenidos fueron similares a los presentados por Zhang *et al.* (2005) quienes estimaron biomasa de soja con regresiones exponenciales y potenciales a partir de índices de vegetación del cociente de reflectancias obtenidas de un radiómetro. Encontraron valores de R^2 igual a 0,73 y 0,85, dependiendo de las funciones de regresión utilizadas y bandas empleadas en el cálculo del índice de vegetación. De manera similar, Gutiérrez-Rodríguez *et al.* (2004) presentaron una relación hiperbólica entre biomasa de poroto y NDVI distinta según tratamiento de fertilización nitrogenada, con $R^2 = 0,62$ y 0,81 para 0 y 200 kg ha⁻¹ de N, respectivamente. La reflectancia del dosel se midió en cada caso con un espectroradiómetro portátil. Kancheva *et al.* (2005) mostraron una relación no lineal entre la biomasa de arvejas expresada en términos relativos al máximo, con respecto al NDVI con un valor de R^2 de 0,91. Wahid *et al.* (2003) presentaron una relación exponencial entre biomasa de arroz y NDVI con un R^2 de 0,49.

Esta respuesta no lineal de la MS respecto del NDVI trae aparejado una saturación del NDVI con valores de biomasa entre 6000 y 8000 kg MS ha⁻¹, por lo que aumentos en la MS por encima de este umbral no se ven reflejados en incrementos del NDVI, perdiendo este índice la sensibilidad para estimar la MS. Al considerar además la fenología del cultivo, podemos encontrar que en etapas avanzadas del ciclo del cultivo, se presentan disminuciones de los valores de NDVI para valores elevados de MS.

4.8. Modelo de transferencia radiativa PROSAIL.

Las reflectancias del canopeo simuladas por el modelo de transferencia radiativa PROSAIL en las longitudes de onda en azul, rojo y NIR (figura 3.8), se observa que la reflectancia en rojo y el NDVI se saturan a medida que la reflectancia en NIR se incrementa con valores por encima de aproximadamente 40%. Este comportamiento y con valores similares también fue reportado por Gitelson (2004), para soja, trigo y maíz, empleando un espectroradiómetro portátil.

La habilidad del modelo PROSAIL para simular la reflectancia del cultivo en las bandas correspondientes al sensor MODIS (figuras 3.9 a 3.11) donde se observa un aumento de la absorción en la porción correspondiente al azul y rojo del espectro de radiación y un incremento en la reflectancia en la porción NIR al incrementar los valores de LAI. Los valores simulados concuerdan con aquellos medidos con un espectroradiómetro por Gitelson (2004), quien informó para soja con LAI = 1, valores de reflectancia en rojo y NIR cercanos a 8% y 35%, respectivamente. Viña *et al.* (2011), mostraron valores de reflectancia en rojo y NIR alrededor del 5% y 60%, respectivamente, cuando el cultivo de soja tuvo un LAI cercano a 4.

En estas figuras también se evidencian algunas diferencias, en particular con valores elevados de LAI (superiores a 4) y en las bandas roja e infrarroja. Tales diferencias pueden deberse a inconsistencias en los parámetros de entrada del modelo PROSPECT (particularmente en los valores de *Cab*, *Cm* y *N*), con los valores entrada de SAIL (en especial el LAI), al seleccionarse de manera independiente sin tener en cuenta las correlaciones que se presentan a lo largo del ciclo del cultivo entre LAI y parámetros como *Cab*, *Cm*, *N*, etc.

Badhwar *et al.* 1985 evaluaron estimaciones de PROSAIL que cuando las compararon con mediciones de radiómetros en soja y maíz, presentaron valores de R^2 de 0,76; 0,823 y 0,773 para las bandas azul, roja y NIR correspondientes a las bandas de Landsat-MSS, respectivamente. Por otra parte Homem Antunes *et al.* (1993) compararon

reflectancias observadas con un espectrorradiómetro y estimaciones realizadas con SAIL en un cultivo de soja en Brasil, presentando valores de R^2 de 0,9894 al considerar todas las longitudes de onda, en tanto que cuando al análisis lo realizaron teniendo en cuenta la longitud de onda, encontraron valores de %RMSE entre 20-25% para rojo y entre 10 y 15% para NIR.

Duke *et al.* (1998) determinaron valores de %RMSE en las reflectancias rojo y NIR elevados (entre 10 y 40% aproximadamente) con índices de área foliar menores a 2 para remolacha azucarera. Dichos errores disminuyeron notablemente cuando al modelo SAIL se le agregó la información medida de reflectancia de los distintos tipos de suelo, rugosidad y su estado de humedad en la capa superficial.

El NDVI estimado por PROSAIL, respecto del observado por MODIS (figura 3.16) presenta el mejor desempeño, cuando se lo compara con los errores de cada una de las bandas que intervienen en su cálculo. Con valores bajos de NDVI (<0,4) el modelo tiende a sobreestimar, error que puede deberse a la falta de información medida de reflectancia para los distintos tipos de suelos/rastrojo, rugosidad y contenido de humedad en la capa superficial, en concordancia con los expresado por Atzberger (2010), quien argumentó que para valores bajos de LAI (menores que 4) la reflectancia del suelo tiene relativamente mayor importancia en la reflectancia del dosel.

4.9. Estimación del LAI a partir de Redes Neuronales Artificiales.

Los modelos de redes neuronales presentados en este trabajo presentan valores de R^2 entre 0,928 y 0,955, RMSE entre 0,622 y 0,919 y %RMSE entre 21,7 y 32,1%. Estos resultados, particularmente en R^2 y %RMSE, fueron mejores que los obtenidos por Veloso *et al.* (2013) para trigo, maíz, girasol y soja, que presentaron errores entre el LAI determinado a partir de fotografías hemisféricas y el LAI obtenido a partir de una inversión de PROSAIL mediante redes neuronales con las reflectancias de SPOT y FORMOSAT, alcanzando valores de R^2 , RMSE y RMSE% de 0,86; 0,51 y 31,2%, respectivamente. Si la inversión se comparaba con valores de LAI obtenidas por método destructivo, los errores aumentaban, con valores de R^2 , RMSE y %RMSE de 0,81; 0,75 y 40,5%; respectivamente.

Por otra parte, Walthall *et al.* (2004) estimaron con redes neuronales valores de LAI de maíz y soja a partir de la inversión de un modelo de transferencia radiativa, encontrando diferentes valores de R^2 y RMSE entre dos imágenes LANDSAT TM+ correspondientes a dos fechas de muestreo (1-jul-2002, R^2 0,63 RMSE 0,63 y 8-jul-2002, R^2 0,40 y RMSE 0,70). Los autores explicaron el peor desempeño de esta metodología para estimar LAI en la segunda fecha, argumentando la presencia de humo sumada a que el cultivo de maíz se encontraba en panojamiento. Ambas condiciones modificarían los valores de reflectancia observados por el satélite.

En otros cultivos los resultados fueron similares. Koetz *et al.* (2005) estimaron la variación espacial y temporal del LAI de maíz, a partir de observaciones satelitales multitemporales mediante la inversión de un modelo dinámico de la estructura del canopeo acoplado con un modelo de transferencia radiativa. Al invertir los modelos con distintas técnicas obtuvieron valores de RMSE entre 0,790 y 0,687 con R^2 entre 0,614 y 0,663. Nertan *et al.* (2005) invirtieron el modelo PROSAIL para estimar LAI en maíz a partir de valores de reflectancia tomados con un espectroradiómetro. Cuando lo compararon con valores de LAI observados a partir de fotografías verticales tomadas con lentes “ojos de pez” obtuvieron una precisión de $\pm 0,72$ en el 95% de los casos.

En trigo, Moulin *et al.* (2003) invirtieron el modelo PROSAIL para estimar LAI y *Cab* en parcelas con distintos niveles de fertilización nitrogenada, a partir de información obtenida de un radiómetro. La inversión se realizó con el algoritmo quasi-Newton, obteniendo valores de RMSE de 2,2 con un R^2 de 0,4. Cuando se incorporó información previa a la evaluación, el valor de RMSE mejoró a 2,0; en tanto que Migdall *et al.* (2009) encontraron valores de R^2 de 0,82 cuando correlacionaron valores de LAI estimados invirtiendo un modelo de transferencia radiativa acoplado con un modelo de cultivo, con valores de LAI observados. Qu *et al.* (2008) obtuvieron valores de RMSE de 0,70 y R^2 de 0,67 cuando estimaron el LAI de trigo a partir de la inversión de PROSAIL con redes bayesianas. Recientemente Thorp *et al.* (2012) estimaron LAI para trigo con un %RMSE de 40.7% cuando invirtieron PROSAIL, error que disminuyó a 24,1 % cuando se le acopló el modelo de cultivo DSSAT.

Weiss *et al.* (2000) estimaron LAI invirtiendo PROSAIL con redes neuronales, que utilizaron como dato de entrada los valores del radiómetro aerotransportado POLDER, obteniendo un RMSE de 0,6 cuando se compararon con valores de LAI observados en cultivos de trigo y maíz para un rango de valores de LAI comprendido entre 0 y 4. En un trabajo posterior, Weiss *et al.* (2002) agregaron al análisis información de los cultivos de girasol y alfalfa, mejorando el valor de RMSE a 0,44.

Richter *et al.* (2012) encontraron valores de R^2 y RMSE diferentes dependiendo del tipo de cultivo cuando invirtieron PROSAIL con redes neuronales para estimar LAI, desde R^2 0,84 y RMSE 0,71 para alfalfa, 0,88 y 0,70 para cebolla, hasta 0,01 y 0,12 para ajo, respectivamente. Los autores justificaron los elevados errores en la estimación del LAI del cultivo de ajo en el hecho que presenta un canopeo erectófilo, por lo que el suelo ejerce una fuerte influencia en la reflectancia del dosel, resultando así en un factor crítico en la inversión del modelo.

Si bien el modelo A001 es el que mejor desempeño tuvo en cuanto a RMSE y R^2 , presenta sobre y sub estimaciones sistemáticas a lo largo del rango de valores de LAI observado (figura 3.17), además de tratarse de la red que más variables de entrada requiere (propiedades de las hojas, psoil, geometría de la observación y reflectancias). Un

comportamiento similar presentan los modelos A003, A004 y A006 (figuras 3.17 y 3.18). En tal sentido, Dorigo *et al.* (2009) presentaron resultados parecidos al estimar valores de LAI de pasturas mediante la inversión de PROSAIL, a partir de datos de un radiómetro manual, con valores de RMSE entre 0.832 y 1.355 y %RMSE entre 34.8 % y 56.7% dependiendo de la metodología de inversión. En ambos casos encontraron que valores intermedios de LAI fueron ligeramente sobrestimados, en tanto que para valores elevados de LAI las inversiones mostraron subestimaciones.

El resto de los modelos (figuras 3.17 a 3.19) presentan subestimaciones para valores de LAI observados superiores a 4, posiblemente debido a la influencia que ejercieron los valores de reflectancia en rojo y NIR de la base de datos. Estos resultados coinciden con los de Vohland *et al.* (2006), quienes obtuvieron valores R^2 , RMSE y RMSE% de 0,903; 1,205 y 24,7%, respectivamente cuando estimaron LAI de cebada mediante la inversión de PROSAIL con valores de un espectroradiómetro, en tanto al utilizar imágenes hiperespectrales provenientes de un avión la precisión de la estimación disminuía, con valores de R^2 , RMSE y RMSE% de 0,802; 1,237 y 25,3%, respectivamente. En ambos casos sus modelos presentaron subestimaciones con valores de LAI mayores que 5-6.

En tal sentido Baret *et al.* (2007) encontraron los peores desempeños de redes neuronales en inversión de PROSAIL, al estimar LAI respecto a la obtención de valores de $fAPAR$ y %C, cuando eran comparados con estimaciones del producto CYCLOPES derivado del sensor VEGETATION. Este mal desempeño fue debido principalmente a la reducida sensibilidad de las reflectancias para valores elevados de LAI.

Si se tiene en cuenta que la relación entre la fracción de la radiación fotosintéticamente activa absorbida sigue un modelo exponencial y se considera el trabajo de Daughtry *et al.* (1992), quienes determinaron los coeficientes de dicha relación para un cultivo de soja, aplicando esa fórmula a un cultivo con LAI = 4 la absorción sería aproximadamente el 90% de la radiación incidente, en tanto que para valores de LAI = 8 la absorción sería del 94%, por lo que las diferencias en la estimación de LAI entre 4 y 8 tendrían poco impacto en la estimación de la radiación fotosintéticamente activa interceptada.

Los resultados presentados en la figura 3.20, concuerdan con los informados por Weiss & Baret (1999) quienes mediante la inversión de PROSAIL con redes neuronales, estimaron valores de LAI de una base de datos sintética con valores de RMSE=0,55 y RMSE% = 7,1%. Sus resultados, que mostraron ser muy buenos con valores bajos de LAI, se tornaron menos precisos cuando los valores de LAI se incrementaron. Ellos adjudicaron este comportamiento a que la red neuronal no discrimina canopeos con valores de LAI entre 4 y 8, debido a la saturación de la reflectancia, aun en la banda NIR, con canopeos densos. El RMSE se incremento cuando consideraron intervalos crecientes de LAI.

4.10. Modelo STICS

En la tabla 3.4 se puede observar que los lotes cuyas variedades poseen valores más elevados de stlevamf son los que presentan menores valores de stamflax, compensando el tiempo térmico desde emergencia hasta alcanzar el máximo LAI. La reducción del valor de stamflax, lleva a una estimación más reducida del valor de LAI máximo, en concordancia con lo planteado por Jégo *et al.* (2010).

4.10.1. Índice de Área Foliar

Como era de esperar, cuando el modelo es forzado a tomar valores de LAI, los errores de estimación disminuyen, presentando valores de %RMSE para STICS y STICS-f de 29,2% y 12,2%, respectivamente (Tabla 3.6). Siguiendo a Jamieson *et al.* (1991), la simulación sería clasificada como regular y buena, respectivamente. En tal sentido, Casa *et al.* (2012) realizaron simulaciones con STICS para un cultivo de trigo bajo tres niveles de conocimiento de datos de entrada en lo referente a suelos y prácticas de manejo, y presentaron valores de RMSE y %RMSE en la estimación de LAI de 1,2 (60%), 0,8 (40%) 0,6 (30%), errores que disminuían a medida que aumentaba el nivel de conocimiento de datos de entrada. Cuando el modelo fue forzado a tomar valores de LAI (STICS-f) los errores disminuyeron a 0,3 (20%), similares a los encontrados en este trabajo. Setiyono *et al.* (2008), por su parte, propusieron un modelo robusto con pocas variables de entrada para la simulación del LAI en soja cultivada bajo condiciones óptimas e informaron un valor promedio de RMSE de 0,52 superior al obtenido en este trabajo con STICS-f.

De manera similar, Wang *et al.* (2003b) estimaron LAI en soja con el modelo GROPGRO con valores de RMSE de 0,72 en la calibración del modelo, encontrando diferencias entre años. Jégo *et al.* (2010) estimaron LAI con STICS una vez calibrados 9 parámetros del modelo, para una variedad de soja en Canadá, y obtuvieron valores de BIAS de -0,1 (que implica una subestimación del 3,6 %) y un valor de RMSE de 0,7 (18,9%) con R^2 de 0,84. En este estudio (Tabla 3.6 y Figura 3.21) el modelo STICS presenta una subestimación de 0,15 en tanto que STICS-f muestra una ligera sobreestimación (BIAS = 0,02) y, en ambos casos, los valores de R^2 fueron superiores (0,89 y 0,98, respectivamente).

Claverie *et al.* (2012) presentaron valores de RMSE entre 0,19 y 0,34 al estimar LAI para maíz bajo riego y entre 0,09 y 0,32 para girasol, cuando compararon valores observados de LAI obtenidos a partir de fotografías hemisféricas digitales con valores estimados al acoplar un modelo simple para estimar rendimiento (SAFY) con datos de NDVI de Formosat-2. De manera similar a este trabajo, los valores de LAI fueron estimados a partir de la serie de tiempo LAI calculada a partir de MODIS, y que se utilizó para calibrar los parámetros del modelo STICS.

4.10.2. Materia seca de la parte aérea

En este trabajo, los errores de estimación de la materia seca de la parte aérea disminuyeron al emplear STICS-f en lugar de STICS; sin embargo, resultaron elevados en comparación con la bibliografía analizada. Cuando se considera solamente la materia seca vegetativa los errores disminuyen de manera marcada (Tabla 3.7), lo que permite suponer la existencia de pérdidas de material reproductivo no recolectado. Si se consideran solo las etapas vegetativas y hasta la formación de vainas (R3, hasta alrededor de 70 días después de la siembra), los errores de la estimación del modelo STICS-f disminuyen sensiblemente (RMSE= 0,54 Mg/ha y %RMSE = 34,0%).

Casa *et al.* (2012) estimaron la producción de materia seca de trigo con STICS, encontrando valores de RMSE, %RMSE y d de 2,5 Mg/ha; 40% y 0,8, respectivamente, cuando la información suministrada al modelo tenía carácter general, sin información de manejo y solamente información genérica de las propiedades de los suelos. Incorporando

información detallada del manejo e información general de los suelos, los valores son 1,8 Mg/ha; 30% y 0,9, respectivamente. Finalmente, si además se consideran las propiedades del suelo con precisión y los contenidos de agua y nitrógeno inicial, los estadísticos mejoraron hasta 1,2 Mg/ha; 20% y 1,0, respectivamente.

Setiyono *et al.* (2010) compararon la producción estimada de MS de los modelos CROPGRO-Soybean, Sinclair-Soybean, WOFOST y SoySim con valores observados y obtuvieron valores de R^2 de 0,91; 0,86; 0,86 y 0,94 y de RMSE de 1,16; 2,56; 2,23 y 1,24 Mg/ha, respectivamente. Jégo *et al.* (2010) emplearon el modelo STIC para simular el cultivo de soja en Canadá encontrando errores en la predicción de la biomasa con valores de RMSE de 1,0 a 1,4 Mg/ha, %RMSE entre 21,6% a 27,3% y BIAS desde -0,2 a 0,6 Mg/ha.

En Argentina, Mercau *et al.* (2007) estimaron la biomasa para soja con el modelo CROPGRO-Soybean original y con modificaciones en el balance hidrológico y presentaron valores de RMSE, %RMSE y R^2 de 1,264 Mg/ha, 19% y 0,38 para el modelo original y de 1,054 Mg/ha, 16% y 0,41 para el modelo modificado, respectivamente. Ruíz–Nogueira y colaboradores (2001) también emplearon el modelo CROPGRO – Soybean y estimaron la producción de materia seca de soja en España, en condiciones bajo riego y de secano, obteniendo valores de RMSE de 0,985 Mg/ha (25,5 %).

Valdés-Gómez *et al.* (2014) utilizaron el modelo STICS para simular el crecimiento y rendimiento de tomate con distintos niveles de fertilización nitrogenada, reportando para materia seca de la parte aérea, valores de RMSE entre 0,39 a 0,64 Mg/ha (%RMSE de 19,7 a 26,5%).

4.10.3. Humedad del suelo

Los resultados obtenidos en este trabajo fueron similares a los presentados por Beaudoin *et al.* (2008), quienes estimaron el contenido de agua del suelo con STICS para distintos cultivos y encontraron valores de RMSE entre 52 y 31 mm y valores del estadístico d entre 0,86 y 0,96, para suelos entre 70 y 149 cm de profundidad. Por otra

parte, Liu *et al.* (2013) emplearon el modelo DSSAT para simular el contenido de agua superficial (entre 20 y 30 cm) de la rotación maíz - soja con dos sistemas de labranzas en China y obtuvieron una concordancia con los valores observados entre buena y moderada ($0,81 \leq d \leq 0,91$ y $15,3\% \leq \%RMSE \leq 20,0\%$) en 2009 y 2011, en tanto que en 2010 la simulación resultó entre pobre y moderada ($0,58 \leq d \leq 0,82$ y $24,2\% \leq \%RMSE \leq 41,7\%$). Wei *et al.* (2015) aplicando el modelo de balance de agua SIMDualKc en soja, estimaron el agua disponible del suelo con valores de R^2 , RMSE y d de 0,85; 10,0 mm y 0,96, respectivamente, considerando una profundidad del suelo de 1m. Zhang *et al.* (2016) utilizando el modelo Agricultural Policy/Environmental eXtender (APEX) agro-ecosystem para simular soja de secano, estimaron el contenido de humedad del suelo hasta 1m de profundidad, presentando los valores de los estadísticos d, RMSE y %RMSE de 0,59; 23,56 mm y 7,32%, respectivamente.

4.10.4. Rendimiento

Los estadísticos correspondientes a las simulaciones de rendimiento de los modelos presentados en la tabla 3.9. son similares a los presentados por Setiyono *et al.* (2010) quienes compararon los modelos CROPGRO-Soybean, Sinclair-Soybean, WOFOST y SoySim con 147 rendimientos observados del cultivo de soja y obtuvieron valores de R^2 de 0,20; 0,06; 0,08 y 0,67 y de RMSE de 0,73; 0,91; 1,61 y 0,46 Mg/ha, respectivamente.

Por su parte, Nielsen *et al.* (2002) estimaron el rendimiento de soja para un amplio rango de condiciones edáficas y meteorológicas, obteniendo valores de RMSE de 0,246 Mg/ha con el modelo DSSAT-CROPGRO y de 0,423 Mg/ha con Root Zone Water Quality Model (RZWQM). En un estudio posterior, Ma *et al.* (2005) también obtuvieron un mejor desempeño del modelo DSSAT-CROPGRO respecto de RZWQM en la predicción del rendimiento de soja (RMSE = 0,233 y 0,240 Mg/ha, respectivamente).

Zhang *et al.* (2016) emplearon el modelo Agricultural Policy/Environmental eXtender (APEX) agro-ecosystem, para simular el rendimiento de soja de secano y obtuvieron valores de d de 0,78; RMSE igual a 0,57 Mg/ha y %RMSE de 11,43%. Por otra parte Wei *et al.* (2015) estimaron el rendimiento de soja con el modelo de balance de agua SIMDualKc-Stewart's con valores de RMSE of 0,381 Mg/ha.

A partir del modelo DSSAT, Liu *et al.* (2013) estimaron el rendimiento de soja cultivada en un esquema de rotaciones maíz-soja de ocho años y mostraron valores de %RMSE de 15%; 17% y 22% y BIAS de -0,029; -0,091 y 0,408 Mg/ha, para labranzas convencional, reducida y siembra directa, respectivamente. Mercau *et al.* (2007) simularon a partir de DSSAT rendimientos de soja en Argentina con valores de RMSE de 0,743 Mg/ha y %RMSE de 22,2%; al modificar los procedimientos de cálculo del balance de agua, lograron mejorar los valores de RMSE a 0,584 Mg/ha y %RMSE a 17,4%. Carbone *et al.* (1996) simularon el rendimiento de soja con el modelo Soygro con valores de RMSE y MAE de 0,34 y 0,26 Mg/ha, respectivamente.

Sau *et al.* (1999) estimaron el rendimiento de soja con el modelo CROPGRO-Soybean y presentaron valores de RMSE de 0,940 Mg/ha y un valor de %RMSE de 28%. Al modificar coeficientes del cultivo que consideran las temperaturas que afectan las funciones de fijación de nitrógeno y de fotosíntesis disminuyeron esos errores a 0,333 Mg/ha y 9,9%, respectivamente. De manera similar Ruíz-Nogera *et al.* (2001) utilizaron el modelo CROPGRO-Soybean para estimar el rendimiento en soja de secano y obtuvieron valores de RMSE de 0,56 Mg/ha y un %RMSE igual a 26,3%. Cuando ajustaron los valores de profundidad del suelo, capacidad de retención de agua en el suelo, tasa de elongación de raíces y un coeficiente de aceleración de la madurez inducida por el estrés hídrico, disminuyeron los errores de predicción obteniendo valores de 0,303 Mg/ha y 14,2%, respectivamente.

Wang *et al.* (2003) evaluaron el desempeño del modelo CROPGRO- Soybean para simular el rendimiento de soja en Missouri presentando valores de BIAS 0,661 y RMSE de 0,693 Mg/ha.

CONCLUSIONES

La aplicación de datos de teledetección en modelos de cultivos para estimar el rendimiento de soja es un componente importante del sistema de información de seguridad alimentaria a fin de proveer de pronósticos de producción fidedignos a escala regional. Por tal motivo, los resultados del trabajo avalan la posibilidad de emplear el modelo de cultivo STICS para asimilar valores de LAI en soja estimados a partir de la teledetección, junto con información meteorológica y de manejo del cultivo. A partir de esta tesis, se pueden expresar las siguientes conclusiones:

El empleo de una cámara digital permite obtener información del porcentaje de cobertura del cultivo de soja, valor que se encuentra linealmente relacionado a la fracción de la radiación fotosintéticamente activa interceptada. Las mediciones de %C obtenidas de una cámara digital presentan, respecto de la barra interceptora, las ventajas de independizarse del horario y de la condición de cielo despejado. También se obtuvo una relación logarítmica entre los valores de índice de área foliar estimados a partir de la barra interceptora y el %C de la cámara fotográfica, presentando una cierta tendencia a la saturación con valores de LAI superiores a 3.

Los valores de LAI estimados también presentaron una relación no lineal cuando se los comparó con valores de NDVI de MODIS interpolados para la fecha de muestreo a campo. En tanto que las relaciones entre NDVI con $fIPAR$ y %C fueron lineales.

Los datos de biomasa del cultivo de soja mostraron una relación no lineal con el NDVI de MODIS y además presentaron histéresis relacionada con el desarrollo fenológico del cultivo, exhibiendo un comportamiento diferencial a partir de R4, debido posiblemente a la disminución de la reflectancia en el infrarrojo cercano causada por hojas senescentes.

Las reflectancias del canopy simuladas por PROSAIL mostraron la evolución típica con el incremento del LAI: un aumento de la absorción en la porción correspondiente al azul y rojo del espectro de radiación y un incremento en la reflectancia en la porción NIR. Al comparar dichas reflectancias con las observadas por el sensor MODIS se evidenciaron sobrestimaciones principalmente para valores elevados de LAI (superiores a 4) que en las bandas roja e infrarroja produjeron subestimaciones del NDVI.

A los efectos de invertir el modelo PROSAIL, el modelo de arquitectura de redes neuronales que mostro el mejor desempeño para estimar el LAI, fue aquel que consideró solamente las reflectancias en azul, rojo y NIR como datos de entrada, si bien presentó subestimaciones para valores de LAI superiores a 4.

En la calibración de los coeficientes del cultivo del modelo STICS, para mejorar el ajuste de los valores de LAI obtenidos con la inversión de la red neuronal que mostró el mejor desempeño, se debió considerar las diferentes fechas de siembra y longitud del ciclo de las variedades de soja utilizadas, como así también la densidad de siembra.

Como era de esperar, al forzar el modelo a tomar valores de LAI, pasando del modelo STICS a STICS-f, los errores de estimación del LAI disminuyen.

Los errores de estimación de la materia seca de la parte aérea disminuyeron al emplear STICS-f en lugar de STICS; sin embargo, resultaron elevados en comparación con la bibliografía analizada. Cuando se considera solamente la materia seca vegetativa, los errores disminuyen de manera marcada y se asemejan a los obtenidos en trabajos similares.

El contenido de humedad del suelo hasta 2m de profundidad y el rendimiento del cultivo fueron estimados adecuadamente, tanto con el modelo STICS como con STICS-f, con valores de %RMSE en torno a 10%.

Estos resultados demuestran que los datos obtenidos de la teledetección a partir del sensor MODIS, permiten obtener estimaciones precisas del LAI, que junto con información edáfica, meteorológica y de manejo, acoplados a los modelos mecánicos STICS y STICS-f permiten estimar la evolución de la biomasa, el contenido de humedad del suelo y rendimiento de soja de manera adecuada.

La integración de la teledetección con la disponibilidad de información de bases de datos espacializadas de suelos e información meteorológica permitiría, mediante el empleo de modelos de transferencia radiativa y modelos de cultivo, estimar el rendimiento de soja a escala regional.

BIBLIOGRAFIA CITADA

- Ahmadi, H. 2009. Determination of soya plant population using NDVI in the Dasht-e-Naz Agri-Industry. *Journal of Agricultural Science* 1:112-120.
- Asner G. P., Wessman C. A., Schimel D. S., and Archer S. 1998. Variability in leaf and litter optical properties: Implications for BRDF model inversions using AVHRR, MODIS, and MISR. *Remote sensing of Environment* 63:243-257.
- Asrar G., Fuchs M., Kanemasu E.T. and Hatfield J.L. 1984. Estimating absorbed photosynthetic radiation and leaf area index from spectral reflectance in wheat. *Agronomy Journal* 76:300-306.
- Atzberger C., Guérif M. and Delécolle R. 1995. Accuracy of multitemporal LAI estimates in winter wheat using analytical (PROSPECT+SAIL) and semiempirical reflectance models. Guyot Gerard (Ed.) *Assessment of remote sensing tools for the estimation of photosynthesis and primary production. Present and future potential. Proceeding of the international colloquium on photosynthesis and remote sensing. EARSeL. ISPRS, Montpellier, France.* pp. 423-428.
- Atzberger C., Jarmer T., Schlerf M., Kötz B. and Werner, W. 2003. Retrieval of wheat biophysical attributes from hyperspectral data and SAILH + PROSPECT radiative transfer model. *Proc. 3rd EARSeL workshop on imaging spectroscopy. Herrsching, Germany.* pp. 473-482.
- Bach H. 1998. Yield estimation of corn based on multitemporal LANDSAT-TM data as input for an agrometeorological model. *Pure Appl. Opt.* 7:809-825.
- Bacour C. and Jacquemoud S. 2001. Coupling spectral and bidirectional information to estimate canopy biophysical parameters by model inversion. *Proc. International Workshop on Spectroscopy Application in Precision Farming (IWSAPF), Freising-Weihenstephan, Germany.* pp. 74-77.

- Bacour C., Baret F., Béal D., Weiss M. and Pavageau K. 2006. Neural network estimation of LAI, $fAPAR$, $fCover$ and $LAI \times Cab$, from top of canopy MERIS reflectance data: Principles and validation *Remote Sensing of Environment*. 105:313-325.
- Baret F. 1991. Vegetation canopy reflectance: Factor of Variation and application for agriculture. In *Remote Sensing and Geographical Information Systems for Resource Management in Developing Countries* Alan S. Belward, Carlos R. Valenzuela Eds. Springer, Dordrecht, The Netherlands. pp. 145–167.
- Baret, F. 1991. Vegetation canopy reflectance: Factors of variation and application for agriculture. In: *Physical measurements and signatures in remote sensing*. Ed. Hunt D. Courchevel, France. pp. 145-167.
- Baret F., Jacquemoud S. and Hanocq J. F. 1993. About the soil line concept in remote sensing. *Adv. Space Res.* 13:221-284.
- Baret F., Clevers J.G.P.W. and Steven M.D. 1995. The Robustness of Canopy Gap Fraction Estimates from Red and Near-Infrared Reflectances: A Comparison of Approaches. *Remote Sens. Environ.* 54:141-151.
- Basso, B., Mc Vicar, T.R., Lee, B., Yazdanpanah, H. and Das H.P. 2010. Remote sensing and GIS applications in agrometeorology. Chapter 4 In: *Guide to agricultural meteorological practices*, 3rd edn. WMO 134. World Meteorological Organization Geneva, Switzerland. pp. 4-1 – 4-35.
- Beaudoin N., Launay M., Sauboua E., Ponsardin G. and Mary B. 2008. Evaluation of the soil crop model STICS over 8 years against the “on farm” database of Bruyères catchment. *European Journal of Agronomy* 29:46-57.
- Ben-Dor E., Irons J.R. and Epema G.F. 1999. Soil reflectance, in *Remote Sensing for the Earth Sciences*. In: *Manual of Remote Sensing*. A.N. Rencz ed., John Wiley & Sons, New York, USA. pp. 111-188.
- Bingfng, W. and Chenglin, L. 2000. Crop growth monitor system with coupling of AVHRR and VGT data. *VEGETATION - 2000: 2 years of operation to prepare the future*. International Users Committee of the VEGETATION Programme. Belgirate, Lake Maggiore, Italy.
- Board J. E., Maka V., Price R., Knight D. and Baur M. E. 2007. Development of vegetation indices for identifying insect infestations in soybean. *Agronomy journal* 99:650-656.

- Bocco M., Ovando G., Sayago S. y Willington E. 2007. Modelos de Redes Neuronales para la Clasificación de Cobertura del Suelo a Partir de Imágenes Satelitales. *Agricultura Técnica* 67:414-421.
- Bouman, B.A.M. 1991. Linking X-band radar backscattering and optical reflectance with crop growth models. Ph.D. Thesis, Wageningen Agricultural University, Wageningen, the Netherlands 169 pp.
- Bourdôt G.W., Jamieson P.D. and Hurrell G.A. 1999. Evaluation of a mechanistic model of wheat and weed growth. 52nd Conference Proceedings of The New Zealand Plant Protection Society Incorporated. Auckland, New Zealand. pp. 203- 208.
- Breunig F.M., Galvão L.S., Formaggio A.R. and Epiphanyo J.C.N. 2013. Influence of data acquisition geometry on soybean spectral response simulated by the PROSAIL model. *Eng. Agríc. Jaboticabal* 33:176-187.
- Brisson N., Mary B., Ripoche D., Jeuffroy M.H., Ruget F., Nicoullaud B., Gate P., Devienne-Barret F., Antonioletti R., Durr C., Richard G., Beaudoin G., Recous S., Tayot X., Plenet D., Cellier P., Machet J.M., Meynard J.M. and Delécolle R. 1998. STICS: a generic model for the simulation of crops and their water and nitrogen balance. I Theory and parameterization applied to wheat and corn. *Agronomie* 18:311-346.
- Brisson N., Gary C., Justes E., Roche R., Mary B., Ripoche D., Zimmer D., Sierra J., Bertuzzi P., Burger P., Bussièrre F., Cabidoche Y.M., Cellier P., Debaeke P., Gaudillère J.P., Hénault C., Maraux F., Seguin B. and Sinoquet H. 2003. An overview of the crop model STICS. *Europ. J. Agronomy* 18:309-332.
- Broadbent E. 2010. PROSAIL 5B for IDL. Department of Geography, University of Alabama, 204 Farrah Hall, Tuscaloosa, AL 35487, USA (eben@amazonico.org). http://teledetection.ipgp.jussieu.fr/prosail/PROSAIL_5B_IDL.zip. Activo octubre 2018.
- Broge N.H. and J.V. Mortensen. 2002. Deriving green crop area index and canopy chlorophyll density of winter wheat from spectral reflectance data. *Remote sensing of environment* 81:45-57.
- Busetto L., Meroni M. and Colombo R. 2008. Combining medium and coarse spatial resolution satellite data to improve the estimation of sub-pixel NDVI time series. *Remote Sensing of Environment* 112:118-131.

- Campbell G.S. 1986. Extinction coefficients for radiation in plant canopies calculated using an ellipsoidal inclination angle distribution. *Agricultural and Forest Meteorology* 36:317-321.
- Campbell G.S. 1990. Derivation of an angle density function for canopies with ellipsoidal leaf angle distributions. *Agricultural and Forest Meteorology* 49:173-176.
- Campillo C., Prieto M.H., Daza C., Monino M.J. and Garcia M.I. 2008. Using digital images to characterize canopy coverage and light interception in a processing tomato crop. *Hortscience* 43:1780-1786.
- Capitanelli R.G. 1979. Geomorfología. En: *Geografía física de la Provincia de Córdoba*. Editorial Boldt. Córdoba, Argentina. pp.213-296.
- Carbone G.J., Narurnalani S. and King, M. 1996. Application of remote sensing and technologies with physiological crop models. *Photogrammetric Engineering & Remote Sensing* 62:171-179.
- Casa R., Varella H., Buis S., Guérif M., De Solan B. and Baret F. 2012. Forcing a wheat crop model with LAI data to access agronomic variables: Evaluation of the impact of model and LAI uncertainties and comparison with an empirical approach. *European Journal of Agronomy* 37:1-10.
- Chappelle E.W., Kim M.S. and Mc Murtrey J.E. 1992. Ratio analysis of reflectance spectra (RARS): an algorithm for the remote estimation of the concentrations of chlorophyll a, chlorophyll b, and carotenoids in soybean leaves. *Remote Sensing of Environment* 39:239-247.
- Chen J.M. and Cihlar J. 1996. Retrieving leaf area index of boreal conifer forests using Landsat TM images. *Remote Sensing of Environment* 55:153-162.
- Choudhury B.J., Ahmed N.U., Idso S.B., Reginato R.J. and Daughtry C.S.T. 1994. Relations between evaporation coefficients and vegetation indices studied by model simulations. *Remote Sensing of Environment* 50:1-17.
- Choudhury B.J. 2000. Evaluation of a model adaptable to satellite data for estimating daily gross photosynthesis. *Remote Sensing of Environment* 71:133-140.
- Chuvieco E. 2000. *Fundamentos en teledetección espacial*. Tercera edición. Ed. RIALP s.a., Madrid, España, 565 pp.
- Cihlar J. Manak D. and D'Iorio M. 1994. Evaluation of Compositing Algorithms for AVHRR Data over Land, *IEEE Trans. Geosc. Remote Sens.* 32:427-437.

- Claverie M., Demarez V., Duchemin B., Hagolle O., Ducrot D., Marais-Sicre C., Dejoux J.F., Huc M., Keravec P., Béziat P., Fieuzal R., Ceschia E. and Dedieu G. 2012. Maize and sunflower biomass estimation in southwest France using high spatial and temporal resolution remote sensing data. *Remote Sensing of Environment* 124:844-857.
- Clevers J.G.P.W. 1988. The derivation of a simplified reflectance model for the estimation of Leaf Area Index. *Remote Sens. Environ.* 25:53-69.
- Clevers J.P.G.W., Vonder O.W., Jongschaap R.E.E., Desprats J.F., King C., Prevot L. and Bruguier N. 2002. Using SPOT data for calibrating a wheat growth model under Mediterranean conditions. *Agronomie* 22:687-694.
- Colombo R., Meroni M., Busetto L., Panigada C. e Rossini M. 2003. Stima di variabili biofisiche e biochimiche della vegetazione di pianura mediante misure di terreno e tecniche di telerilevamento satellitare e aereo. 7^a conferenza nazionale delle agenzie ambientali. APAT, ARPA e dalle Agenzie Regionali e Provinciali per la Protezione dell'Ambiente della Lombardia. Milano, Italia.
- Combal B., Baret F. and Weiss M. 2002a. Improving canopy variables estimation from remote sensing data by exploiting ancillary information. Case study on sugar beet canopies. *Agronomie* 22:205-215.
- Combal B., Baret F., Weiss M., Trubuil A., Macé D., Pragnère A., Myneni R., Knyazikhin Y. and Wang L. 2002b. Retrieval of canopy biophysical variables from bidirectional reflectance. Using prior information to solve the ill-posed inverse problem. *Remote Sensing of Environment* 84:1-15.
- Dadhwal, V. K. 2003. Crop growth and productivity monitoring and simulation using remote sensing and GIS. In: *Satellite Remote Sensing and GIS Applications in Agricultural Meteorology*. Ed. Sivakumar M.V.K., Roy P.S., Harmsen K. and Saha S.K. Dehra Dun, India. pp. 263-289.
- Danson F. M. 1998. Teaching the physical principles of vegetation canopy reflectance using the SAIL model. *Photogrammetric engineering and remote sensing* 64:809-812.
- Danson F. M., Rowland C.S. and Baret F. 2003. Training a neural network with a canopy reflectance model to estimate crop leaf area index. *Int. J. Remote Sensing* 24:4891-4905.
- Dawson C.W. and Wilby R.L. 2001. Hydrological modelling using artificial neural networks. *Progress in physical Geography* 25:80-108.

- Daughtry C.S.T., Gallo K.P., Goward S.N., Prince S.D. and Kustas W.P. 1992. Spectral estimates of absorbed radiation and phytomass production in corn and soybean canopies. *Remote Sensing of Environment* 39:141-152.
- Davis D.T., Chen Z., Hwang J. and Tsang L. 1995. Solving inverse problems by Bayesian Iterative Inversion of a forward model with applications to parameter mapping using SMMR remote sensing data. *IEEE Transactions on Geoscience and Remote Sensing* 33:1182-1193.
- Decagon Devices Inc. 2001. Decagon AccuPar Ceptometer Operating Manual. Decagon Devices Inc., Pullman, WA, USA. 142 pp.
- Di Bella C., Faivre R., Ruget F. and Seguin B. 2004. Estimation of pasture production at the national level in France by combining vegetation satellite data and the “STICS” crop model. *Proceeding of the 2nd international VEGETATION user conference*. Antwerp, Belgium. pp.385-390.
- Didan K. and Huete, A. 2006. MODIS vegetation index product series collection 5 change summary. TBRS Lab, The University of Arizona. 17 pp. available at https://landweb.modaps.eosdis.nasa.gov/QA_WWW/forPage/MOD13_VI_C5_Changes_Document_06_28_06.pdf. Last access oct. 2018.
- Doraiswamy P.C. and Cook P.W. 1995. Spring wheat yield assessment using NOAA AVHRR data. *Canadian Journal of Remote Sensing* 21:43-51.
- Doraiswamy P.C., Hatfield J.L., Jackson T.J., Akhmedov B., Prueger J and Stern A. 2004. Crop condition and yield simulation using Landsat and MODIS. *Remote Sensing of Environment* 91:548-559.
- Doraiswamy P.C., Sinclair T.R., Hollinger S., Akhmedov B., Stern A. and Prueger J. 2005. Application of MODIS derived parameters for regional crop yield assessment. *Remote Sensing of Environment* 97:192-202.
- Dourado-Neto D., Teruel D.A., Reichardt K., Nielsen D.R., Frizzone J.A. and Bacchi O.O.S. 1998. Principles of crop modeling and simulation: I. Uses of mathematical models in agricultural science. *Sci. agric., Piracicaba* 55:46-50.
- Duke C. and Guérif M. 1998. Crop reflectance estimate errors from the SAIL Model due to spatial and temporal variability of canopy and soil characteristics. *Remote Sensing of Environment* 66:286–297.

- Escadafal R. and Huete A. 1992. Soil optical properties and environmental applications of remote sensing. *Int. Arch. Photogrammetry and Remote Sensing* 29:709-715.
- España M.L. 1997. Simulation de la variation temporelle, directionnelle et spectrale de la réflectance des cultures de maïs à partir d'un modèle dynamique de la structure 3D du couvert. Ph.D. Thesis. Univ. de Marne-La-Vallée, France. 248 pp.
- Fehr W., Caviness C., Burmood D. and Pennington J. 1971. Stage of development descriptions for soybeans, *Glycine max* (L.) Merrill. *Crop Science* 11:929-931.
- Fehr W.R. and Caviness C.E. 1977. Stages of soybean development. Iowa Coop. Ext. Service, Iowa Agric. Home. Exp. Stn. Spec. Rep. 80. Iowa State Univ. Ames, IA, USA. 12 pp.
- Fensholt R., Sandholt I. and Schultz Rasmussen M. 2004. Evaluation of MODIS LAI, *f*APAR and the relation between *f*APAR and NDVI in a semi-arid environment using in situ measurements. *Remote Sensing of Environment* 91:490-507.
- Flénet F., Kiniry J.R., Board J.E., Westgate M.E. and Reicosky D. C. 1996. Row spacing effects on light extinction coefficients of corn, sorghum, soybean, and sunflower. *Agronomy Journal* 88:185-190.
- Fuqin L. and Guoliang T. 1991. Research on Remote Sensing - Meteorological model for wheat yield estimation. 12th Asian Conference on Remote Sensing. Asian Association of Remote Sensing (AARS). Singapore.
- García-Mora T.J. y Mas J.F. 2011. Modland: los productos de superficie terrestre MODIS. En: Aplicaciones del sensor MODIS para el monitoreo del territorio. Eds. Instituto Nacional de Ecología (INE, Secretaría de Medio Ambiente y Recursos Naturales (Semarnat, Universidad Nacional Autónoma de México (UNAM, Centro de Investigaciones en Geografía Ambiental (CIGA). México D.F., México. 25-69 pp.
- Guindin-Garcia N., Gitelson A.A., Arkebauer T.J., Shanahan J. and Weiss A. 2012. An evaluation of MODIS 8-and 16-day composite products for monitoring maize green leaf area index. *Agricultural and Forest Meteorology* 161:15-25.
- Gitelson A.A., Kaufman Y.J., Stark R. y Rundquist D. 2002a. Novel algorithms for remote estimation of vegetation fraction. *Remote Sensing of Environment* 80:76-87.

- Gitelson A.A., Stark R., Grits U., Rundquist D., Kaufman Y. and Derry D. 2002b. Vegetation and soil lines in visible spectral space: a concept and technique for remote estimation of vegetation fraction. *International Journal of Remote Sensing* 23:2537-2562.
- Gitelson A.A., Viña A., Ciganda V., Rundquist D.C. and Arkebauer T.J. 2005. Remote estimation of canopy chlorophyll content in crops. *Geophysical Research Letters*, Vol. 32(L08403)1-4.
- Gitelson A.A., Viña A., Verma S.B., Rundquist D.C., Arkebauer T.J., Keydan G. and Suyker A.E. 2006. Relationship between gross primary production and chlorophyll content in crops: Implications for the synoptic monitoring of vegetation productivity. *Journal of Geophysical Research: Atmospheres* 111(D8).
- Gitelson A.A., Peng Y. and Huemmrich K.F. 2014. Relationship between fraction of radiation absorbed by photosynthesizing maize and soybean canopies and NDVI from remotely sensed data taken at close range and from MODIS 250m resolution data. *Remote Sensing of Environment* 147:108-120.
- Gitelson A.A. 2016. 15 Remote Sensing Estimation of Crop Biophysical Characteristics at Various Scales. In: *Hyperspectral Remote Sensing of Vegetation*. Eds Thenkabail P.S., Lyon's J. G. and Huete A. Boca Raton, FL, USA. 329-358 pp.
- Glenn E., Huete A., Nagler P.L. and Nelson S.G. 2008. Relationship between remotely-sensed vegetation indices, canopy attributes and plant physiological processes: what vegetation indices can and cannot tell us about the landscape. *Sensors* 8:2136-2160.
- Gobron N., Pinty B. and Verstraete M.M. 1997. Theoretical limits to the estimation of the Leaf Area Index on the basis of visible and near-infrared remote sensing data. *IEEE Trans. Geosci. Remote Sensing* 35:1438-1445.
- Gobron N., Pinty B., Ausedat O., Chen J.M., Cohen W.B., Fensholt R., Gond V., Huemmrich K.F., Lavergne T., Mélin F., Privette J.L., Sandholt I., Taberner M., Turner D.P., Verstraete M.M. and Widlowski, J. 2006. Evaluation of fraction of absorbed photosynthetically active radiation products for different canopy radiation transfer regimes: Methodology and results using Joint Research Center products derived from SeaWiFS against ground-based estimations. *Journal of Geophysical Research: Atmospheres*, 111(D13110).

- Goel N.S. and Strebel D.E. 1984. Simple Beta Distribution Representation of Leaf Orientation in Vegetation Canopies. *Agronomy Journal* 76:800-802.
- Goel N.S. and Deering D.W. 1985. Evaluation of a Canopy Reflectance Model for LAI Estimation Through Its Inversion. *IEEE Transactions On Geoscience and Remote Sensing* 23:674-684.
- Goel N.S. 1989. Inversion of canopy reflectance models for estimation of biophysical parameters from reflectance data. In: *Theory and Applications of Optical Remote Sensing*. G. Asrar, ed. Wiley-Interscience, New York, USA. pp. 205-251.
- Gong P., Wang D.X. and Liang S. 1999. Inverting canopy reflectance model using a neural network. *International Journal of Remote Sensing* 20:111-122.
- González-Sanpedro M. C., Le Toan T., Moreno J., Kergoat L. and Rubio E. 2008. Seasonal variations of leaf area index of agricultural fields retrieved from Landsat data. *Remote Sensing of Environment* 112:810-824.
- Goudriaan J. and Monteith J.L. 1990. A mathematical function for crop growth. *Ann. Bot.* 66:695-701.
- Groten S.M.E. 1993. NDVI-crop monitoring and early yield assessment of Burkina Faso. *International Journal of Remote Sensing* 14:1495-1515.
- Guérif M. and Duke C.L. 2000. Adjustment procedures of a crop model to the site specific characteristics of soil and crop using remote sensing data assimilation. *Agricultural Ecosystems & Environment* 81:57-69.
- Guillén-Climent M.L., Zarco-Tejada P.J. and Villalobos F.J. 2012. Estimating radiation interception in an olive orchard using physical models and multispectral airborne imagery. *Israel Journal of Plant Sciences* 60:107-121.
- Gutiérrez-Rodríguez M., Escalante-Estrada J.A., Rodríguez-González M.T. y Reynolds, M.P. 2004. Índices de reflectancia y rendimiento del frijol con aplicaciones de nitrógeno. *Terra Latinoamericana* 22:409-416.
- Gutman G.G. 1991. Vegetation indices from AVHRR: An update and future prospects. *Remote Sens. Environ.* 35:121-136.
- Hadria R., Duchemin B., Lahrouni A., Khabba S., Er-Raki S., Dedieu G., Chehbouni A. and Olioso A. 2006. Monitoring of irrigated wheat in a semi-arid climate using crop modelling and remote sensing data: Impact of satellite revisit time frequency. *International Journal of Remote Sensing*. 27:1093-1117.

- Hatfield J.L., Gitelson A.A., Schepers J.S. and Walthall C.L. 2008. Application of spectral remote sensing for agronomic decisions. *Agronomy Journal* 100:17-31.
- Haverkort A.J., Uenk D., Veroude H. and Van de Waart M. 1991. Relationships between ground cover, intercepted solar radiation, leaf area index and infrared reflectance of potato crops. *Potato Research* 34:113-121.
- Hilera J. y Martínez V. 2000. *Redes neuronales artificiales. Fundamentos, modelos y aplicaciones*. Alfaomega grupo editor. México, D.F, México, 390 pp.
- Hochheim K.P. and Barber D.G. 1998. Spring Wheat Yield Estimation for Western Canada Using NOAA NDVI Data. *Canadian Journal of Remote Sensing* 24:17-27.
- Holben, B.N. 1986. Characterization of maximum value composites from temporal AVHRR data. *Int. J. Remote Sensing* 7:1417-1434.
- Hong S.Y., Sudduth K.A., Kitchen N.R., Fraisse C.W., Palm H.L. and Wiebold W.J. 2004. Comparison of remote sensing and crop growth models for estimating within-field LAI variability. *Korean Journal of Remote Sensing* 20:175-188.
- Hoogenboom G. 2000. Contribution of agrometeorology to the simulation of crop production and its applications. *Agricultural and Forest Meteorology* 103:137-157.
- Houborg R., Anderson M. and Daughtry C. 2009. Utility of an image-based canopy reflectance modeling tool for remote estimation of LAI and leaf chlorophyll content at the field scale. *Remote Sensing of Environment* 113:259-274.
- Huete A., Justice C. and van Leeuwen W. 1999. MODIS Vegetation Index (Mod 13) Algorithm Theoretical Basis Document. Version 3. pp. 131. Available at http://modis.gsfc.nasa.gov/data/atbd/atbd_mod13.pdf. Activo al 8/10/2018
- Inoue Y., Peñuelas J., Miyata A. and Mano M. 2008. Normalized difference spectral indices for estimating photosynthetic efficiency and capacity at a canopy scale derived from hyperspectral and CO₂ flux measurements in rice. *Remote Sensing of Environment* 112:156-172.
- INTA. 1987a. Instituto Nacional de Tecnología Agropecuaria. Buenos Aires. Carta De Suelos De La República Argentina: hoja Villa del Rosario 3163-26. Editorial Fundación Banco de la Provincia de Córdoba. Argentina
- INTA. 1987b. Instituto Nacional de Tecnología Agropecuaria. INTA. Buenos Aires. Carta De Suelos De La República Argentina: hoja 3163-32. Editorial Fundación Banco de la Provincia de Córdoba. Argentina

- Jacquemoud S. and Baret F. 1990. PROSPECT: A model of leaf optical properties spectra. *Remote Sensing of Environment*. 34:75-91.
- Jacquemoud S., Bacour C., Poilvé H. and Frangi J.P. 1999. Inversion de modèles de transfert radiatif pour estimer les caractéristiques d' un couvert végétal à partir de données de télédétection dans le domaine optique. In: Colloque international sur la télédétection optique et radar en la géomatique pour la gestion des problèmes environnementaux. Ed. Bannari A. Ottawa, Canada. pp. 113-125.
- Jacquemoud S., Bacour C., Poilvé H. and Frangi J.P: 2000. Comparison of four Radiative Transfer Models to simulate plant canopies reflectance: Direct and Inverse mode. *Remote Sensing of Environment* 74:471-481.
- Jacquemoud S., Verhoef W., Baret F., Bacour C., Zarco-Tejada P.J., Asner G.P., François, C. and Ustin S.L. 2009. PROSPECT+ SAIL models: A review of use for vegetation characterization. *Remote Sensing of Environment* 113:S56-S66.
- Jamieson P.D., Porter J. and Wilson D.R. 1991. A test of computer simulation model ARC-WHEAT1 on wheat crops grown in New Zealand. *Field Crops Research* 27:337-350.
- Jarsún B., Gorgas J.A., Zamora E., Bosnero E., Lovera E., Ravelo A. y Tassile J.L. 2003. Recursos Naturales De La Provincia De Córdoba: Los Suelos. Córdoba: Agencia Córdoba. Dirección de Ambiente, Instituto Nacional de Tecnología Agropecuaria, Manfredi.
- Jégo G., Pattey E., Bourgeois G., Morrison M.J., Drury C.F., Tremblay N. and Tremblay G. 2010. Calibration and performance evaluation of soybean and spring wheat cultivars using the STICS crop model in Eastern Canada. *Field Crops Research* 117:183-196.
- Jiang Z., Huete A.R., Chen J., Chen Y., Li J., Yan G. and Zhang X. 2006. Analysis of NDVI and scaled difference vegetation index retrievals of vegetation fraction. *Remote Sensing of Environment* 101:366-378.
- Jiménez-Muñoz J.C., Sobrino J.A., Plaza A., Guanter L., Moreno J. and Martínez P. 2009. Comparison between Fractional Vegetation Cover Retrievals from Vegetation Indices and Spectral Mixture Analysis: Case Study of PROBA/CHRIS Data over an Agricultural Area. *Sensors* 9:768-793.
- Jones H.G. 1992. *Plants and microclimate: a quantitative approach to environmental plant physiology*. Cambridge university press, New York, USA. 428 pp.

- Jones G., Thornton P. and Hill P. 1994. Agro-meteorological models: Crop growth and stress indices. Centro Internacional de Agricultura Tropical (CIAT), Cali, Colombia. 25 pp.
- Jones J.W., Keating B.A., Porter C.H. 2001. Approaches to modular model development. *Agricultural Systems* 70:421-443.
- Jones B.P. 2002. Determination and Manipulation of Leaf Area Index to Facilitate Site-Specific Management of Double-Crop Soybean in the Mid-Atlantic, USA. Master of Science Thesis. Faculty of the Virginia Polytechnic Institute and State University. Blacksburg, Virginia, EE. UU. 169 pp.
- Johnson L.F. and Trout T.J. 2012. Satellite NDVI assisted monitoring of vegetable crop evapotranspiration in California's San Joaquin Valley. *Remote Sensing* 4:439-455.
- Jupp D.L. and Strahler A.H. 1991. A hotspot model for leaf canopies. *Remote Sensing of Environment* 38:193-210.
- Kalácska M., Sánchez-Azofeifa A., Caelli T., Rivard B. and Boerlage B. 2005. Estimating leaf area index from satellite imagery using Bayesian networks. *IEEE Transactions on Geoscience and Remote Sensing* 43:1866-1873.
- Kallel A., Le Hégarat-Masclé S., Ottlé C. and Hubert-Moy L. 2007. Determination of vegetation cover fraction by inversion of a four-parameter model based on isoline parametrization. *Remote Sensing of Environment* 111:553-566.
- Kancheva R., Borisova D. and Georgiev G. 2005. Spectral models for crop state assessment considering soil and anthropogenic impacts. 31st Int. Symp. *Remote Sensing of the Environment*. St. Petersburg, Russia. pp. 20-24.
- Kastens J.H., Kastens T.L., Kastens D.L.A., Price K.P., Martinko E.A. and Lee R.Y. 2005. Image masking for crop yield forecasting using AVHRR NDVI time series imagery. *Remote Sensing of Environment* 99:341-356.
- Kimes D., Knyazikhin Y., Tian Y., Zhang Y., Wang Y. and Myneni R. 2000. Inversion methods for physically-based models. *Remote Sensing Reviews* 18:381-439.
- Klassen S.P., Ritchie G., Frantz J.M., Pinnock D. and Bugbee B. 2003. Real-time imaging of ground cover: Relationships with radiation capture, canopy photosynthesis, and daily growth rate. In: *Digital imaging and spectral techniques: applications to precision agriculture and crop physiology, (digitalimaginga)*. Eds. Schepers J. and Van Toai T. Madison, WI., USA. pp. 3-14.

- Kuusk A. 1991. The hot spot effect in plant canopy reflectance. In: Photon-vegetation interactions: applications in optical remote sensing and plant ecology. Eds Myneni R.B. and Ross J. Springer Berlin Heidelberg, pp. 139-159.
- Landis B. and Aber J.S. 2007. Low-cost field goniometer for multiangular reflectance measurements. *Emporia State Research Studies* 44:1-6.
- Launay M. and Guerif M. 2005. Assimilating remote sensing data into a crop model to improve predictive performance for spatial applications. *Agriculture Ecosystems & Environment* 111:321-339.
- Lee K.S., Cohen W.B., Kennedy R.E., Maersperger T.K. and Gower S.T. 2004. Hyperspectral versus multispectral data for estimating leaf area index in four different biomes. *Remote Sensing of Environment* 91:508-520.
- Liang S., Fang H., Hoogenboom G., Teasdale J. and Cavigelli M. 2004. Estimation of crop yield at the regional scale from MODIS observations. *Proceedings 2004 of the International Geoscience and Remote Sensing Symposium (IGARSS)*, New York, USA. pp. 1625-1628.
- Liu J. and Pattey E. 2010. Retrieval of leaf area index from top-of-canopy digital photography over agricultural crops. *Agricultural and Forest Meteorology* 150:1485-1490.
- Liu S., Yang J.Y., Zhang X.Y., Drury C.F., Reynolds W.D. and Hoogenboom G. 2013. Modelling crop yield, soil water content and soil temperature for a soybean–maize rotation under conventional and conservation tillage systems in Northeast China. *Agricultural water management* 123:32-44.
- Lobell D.B. and Asner G.P. 2002. Moisture Effects on Soil Reflectance. *Soil Sci. Soc. Am. J.* 66:722-727.
- Lobell D.B., Asner G.P., Ortiz Monasterio J.I. and Benning T.L. 2003. Remote sensing of regional crop production in the Yaqui Valley, Mexico: estimates and uncertainties. *Agriculture Ecosystems & Environment* 94:205-220.
- Lobell D.B. and Asner G.P. 2004. Cropland distributions from temporal unmixing of MODIS data. *Remote sensing of Environment*. 93:412-422.

- Lu S., Lu X., Zhao W., Liu Y., Wang Z. and Omasa K. 2015. Comparing vegetation indices for remote chlorophyll measurement of white poplar and Chinese elm leaves with different adaxial and abaxial surfaces. *Journal of experimental botany*. 66:5625-5637.
- Ma B.L., Dwier L.M., Costa C., Cober E. and Morrison M. 2001. Early prediction of soybean yield from canopy reflectance measurements. *Agronomy Journal* 93:1227-1234.
- Ma, L., Hoogenboom G., Ahuja L.R., Nielsen D.C. and Ascough J.C. 2005. Development and evaluation of the RZWQM-CROPGRO hybrid model for soybean production. *Agronomy Journal* 97:1172-1182.
- Maas S.J. 1988. Using satellite data to improve model estimates of crop yield. *Agronomy Journal* 80:655-662.
- Maas S.J. 1993. Parameterized model of gramineous crop growth: II. Within-season simulation calibration. *Agronomy Journal* 85:354-358.
- Maas S.J. 2000. Linear mixture modeling approach for estimation cotton canopy ground cover using satellite multispectral imagery. *Remote Sensing of Environment* 72:304-308.
- Maas S.J. and Rajan N. 2008. Estimating Ground Cover of Field Crops Using Medium-Resolution Multispectral Satellite Imagery. *Agronomy Journal* 100:320-327.
- Makela A., Landsberg J., Ek A.R., Burk T.E., Ter Mikaelian M., Agren G.I., Oliver C. and Puttonen P. 2000. Process-based models for forest ecosystem management: current state of the art and challenges for practical implementation. *Tree Physiology* 20:289-298.
- Maracchi G., Pérarnaud V. and Kleschenko A.D. 2000. Applications of geographical information systems and remote sensing in agrometeorology. *Agricultural and Forest Meteorology* 103:119-136.
- Marenco R.A. and Lopes N. 1994. Leaf chlorophyll concentration and nitrogen content in soybean plants treated with herbicides. *Revista Brasileira de Fisiologia Vegetal* 6:7-13.
- Mather J.R. 1965. Average climatic water balance data of the continents. Part VIII. South America. *Publications in Climatology*. Laboratory of Climatology, Centerton, New Jersey, USA. XVIII (2) pp.293-426.
- McNairn H. and Brown R.J. 1999. Remote Sensing in Support of Crop Management. United Nations/China/European Space Agency (ESA) Conference on Space Application for Promoting Sustainable Agriculture. Beijing, China. pp. 1-7.

- Mercau J.L., Dardanelli J.L., Collino D.J., Andriani J.M., Irigoyen, A. and Satorre E.H. 2007. Predicting on-farm soybean yields in the pampas using CROPGRO-soybean. *Field Crops Research* 100:200-209.
- MAGyP 2016. Ministerio de Agroindustria – Presidencia de la Nación Datos Abiertos Agroindustria. <https://datos.magyp.gob.ar/reportes.php?reporte=Estimaciones>. Activo al 20/05/2015.
- Mohren G. and Burkhardt H.E. 1994. Contrast between biologically-based process models and management-oriented growth and yield models. *Forest Ecology and Management* 69:1-5.
- Monteith J.L. 1977. Climate and the efficiency of crop production in Britain. *Philos. Trans. R. Soc. Lond. B.* 281:277-294.
- Monteith J.L. 2000. Fundamental equations for growth in uniform stands of vegetation. *Agricultural and Forest Meteorology* 104:5-11.
- Montandon L.M. and Small E.E. 2008. The impact of soil reflectance on the quantification of the green vegetation fraction from NDVI. *Remote Sensing of Environment* 112:1835-1845.
- Montico S. y Di Leo N. 2002. Producción primaria neta potencial en unidades de tierra de una cuenca rural de Santa Fe, Argentina. *Cien. Inv. Agr.* 29:45-52.
- Morel J., Bégué A., Todoroff P., Martiné J.F., Lebourgeois V. and Petit, M. 2014. Coupling a sugarcane crop model with the remotely sensed time series of $fIPAR$ to optimise the yield estimation. *European Journal of Agronomy* 61:60-68.
- Myneni R.B, Hall F.G., Sellers P.J. and Marshak A.L. 1995. The interpretation of spectral vegetation indexes. *Transactions on geoscience and remote sensing* 33:481-496.
- Myneni R.B., Hoffman S., Knyazikhin Y., Privette J.L., Glassy J., Tian Y., Wang Y., Song X., Zhang Y., Smith G.R., Lotsch A., Friedl M., Morisette J.T., Votava P., Nemani R.R. and Running S.W. 2002. Global products of vegetation leaf area and fraction absorbed PAR from year one of MODIS data. *Remote Sensing of Environment* 83:214-231.
- Nguy-Robertson A., Gitelson A., Peng Y., Viña A., Arkebauer T. and Rundquist, D. 2012. Green leaf area index estimation in maize and soybean: Combining vegetation indices to achieve maximal sensitivity. *Agronomy Journal* 104:1336-1347.
- Nielsen D., Ma L., Ahuja L. and Hoogenboom G. 2002. Simulating soybean water stress effects with RZWQM and CROPGRO models. *Agronomy Journal* 94:1234-1243.

- Ovando G., de la Casa A.C., Rodríguez A.R., Accietto R.H. y Bressanini L. 1999. Determinación fotogramétrica del área foliar en papa (*Solanum tuberosum*, cv spunta) usando una técnica estándar de interpretación de imágenes de satélites. XI Congresso Brasileiro de Agrometeorología e II Reunião Latino-Americana de Agrometeorología. Florianópolis, Brasil. pp. 121-127.
- Paz Rodríguez J.L., López Cedrón F. J. y Sau F. 1999. Comparación de diferentes índices de vegetación para estimar parámetros ecofisiológicos: fracción de radiación interceptada e índice de área foliar. En: Teledetección. Avances y aplicaciones. Editorial Santiago y Quintanilla. España. pp. 47-50.
- Pickett-Heaps C.A., Canadell J.G., Briggs P.R., Gobron N., Haverd V., Paget M.J., Pinty B. and Raupach M.R. 2014. Evaluation of six satellite-derived Fraction of Absorbed Photosynthetic Active Radiation (FAPAR) products across the Australian continent. *Remote Sensing of Environment*. 140:241-256.
- Pinheiro Ferri C., Formaggio A.R. and Schiavinato M.A. 2004. Narrow band spectral indexes for chlorophyll determination in soybean canopies [*Glicine max* (L.) Merrill]. *Braz. J. Plan Physiol.* 16:131-136.
- Potter C., Klooster S., Myneni R., Genovese V., Tan P. and Kumar V. 2003. Continental-scale comparisons of terrestrial carbon sinks estimated from satellite data and ecosystem modeling 1982–1998. *Global and Planetary Change* 39:201-213.
- Povkh V., Shljakhova L., Garbuzov G. and Vorobeychik E. 2005. Operational monitoring of the agricultural production based on the observational MODIS data as a support for improving regional planning. 31st International Symposium on Remote Sensing of Environment – IRSE. 20-24 June 2005. Saint Petersburg, Russia. pp. 421–424.
- Purevdorj T. and Tateishi R. 1998. The assessment of green vegetation coverage of grasslands using AVHRR data. In *Geoscience and Remote Sensing Symposium Proceedings, 1998. IGARSS'98 - IEEE International*. Seattle, USA. Vol. 3, pp. 1283-1285.
- Prasad A. K., Chai L., Singh R. P. and Kafatos, M. 2006. Crop yield estimation model for Iowa using remote sensing and surface parameters. *International Journal of Applied Earth Observation and Geoinformation* 8:26-33.
- Price J.C. 1993. Estimating Leaf Area Index from Satellite Data. *IEEE Transactions on geoscience and remote sensing* 31:727-734.

- Prusinkiewicz P. 2004. Modeling plant growth and development. *Current Opinion in Plant Biology* 7(1)79–83.
- Purcell L.C. 2000. Soybean canopy coverage and light interception measurements using digital imagery. *Crop Science* 40(3)834-837.
- Qu Y., Wang J., Wan H., Li X. and Zhou G. 2008 A Bayesian network algorithm for retrieving the characterization of land surface vegetation. *Remote Sensing of Environment* 112:613-622.
- Rahman H., Quadir D.A., Zahedul Islam A.Z.M. and Dutta, S. 1999. Viewing Angle Effect on the Remote Sensing Monitoring of Wheat and Rice Crops. *GeoCarto International* 14(1)74-79.
- Ramírez García J., Almendros García P. and Quemada Saenz-Badillos M. 2012. Ground cover and leaf area index relationship in a grass, legume and crucifer crop. *Plant, Soil and Environment* 58:385-390.
- Ravelo A., Planchuelo A. y Cherlet M. 2003. Estimación de los rendimientos de soja en Argentina utilizando índices de vegetación obtenidos de imágenes satelitales. XIII Congresso Brasileiro de Agrometeorología. Santa María, Brasil.
- Ren J., Chen Z., Zhou Q. and Tang, H. 2008. Regional yield estimation for winter wheat with MODIS-NDVI data in Shandong, China. *International Journal of Applied Earth Observation and Geoinformation* 10:403-413.
- Richter K., Rischbeck P., Eitzinger J., Schneider W., Suppan F. and Weihs P. 2008. Plant growth monitoring and potential drought risk assessment by means of Earth observation data. *International Journal of Remote Sensing* 29:4943-4960.
- Rizzi R. e Rudorff B.F.T. 2005. Estimativa da produtividade de soja por meio de um modelo agrometeorológico-espectral: estudo de caso no Rio Grande do Sul. *Anais XII Simpósio Brasileiro de Sensoriamento Remoto*. Goiânia, Brasil. pp. 237-244.
- Rodríguez A., de la Casa A.C., Bressanini L., Accietto R. y Ovando G. 2000. Determinación del área foliar en papa (*Solanum tuberosum* L., var. Spunta) por medio de fotografías digitales conociendo la relación entre el número de píxeles y la altura de adquisición. *Rev. Brasileira de Agrometeorologia* 8:215-221.
- Rosenthal W.D., Hammer G.L. and Butler D. 1998. Predicting regional grain sorghum production in Australia using spatial data and crop simulation modeling. *Agricultural and Forest Meteorology* 91:263-274.

- Rundquist D., Gitelson A., Derry D., Ramirez J., Stark R. and Keydan G. 2001. Remote estimation of vegetation fraction in corn canopies. Proceeding, Third European Conference on Precision Agriculture. Montpellier, France. Vol. 1 pp. 301-306.
- Running, S.W. and Gower S.T. 1991. FOREST-BGC, A general model of forest ecosystem processes for regional applications. II. Dynamic carbon allocation and nitrogen budgets. *Tree Physiology* 9:147-160.
- Saxton K.E. and Rawls W.J. 2006. Soil water characteristic estimates by texture and organic matter for hydrologic solutions. *Soil science society of America Journal* 70(5) 1569-1578.
- Sau F., Boote K.J. and Ruíz-Nogueira B. 1999. Evaluation and improvement of CROPGRO-soybean model for a cool environment in Galicia, northwest Spain. *Field Crops Research* 61:273-291.
- Secretaría de Agricultura (SAGPyA). 2008. Estimaciones agrícolas mensuales cifras oficiales. <http://www.sagpya.gov.ar/> Activo al 10/5/2009
- Seiler R.A., Kogan F., Wei G. and Vinocur M. 2007. Seasonal and interannual responses of the vegetation and production of crops in Cordoba – Argentina assessed by AVHRR derived vegetation indices. *Advances in Space Research* 39:88-94.
- Serrano L., Filella I. and Pañuelas J. 2000. Remote sensing of biomass and yield of winter wheat under different nitrogen supplies. *Crop Science* 40:723-731.
- Solorio Elizalde N., Paz Pellat F., Odi Lara M. y Bolaños González M.A. 2009. Modelo expo-lineal del crecimiento y equivalencia de la productividad de un tomate cultivado en invernadero. *Terra Latinoamericana*. 27(2):143-151.
- Ruíz-Nogueira B., Boote K.J. and Sau, F. 2001. Calibration and use of CROPGRO-soybean model for improving soybean management under rainfed conditions. *Agricultural Systems* 68:151-173.
- Setiyono T.D., Weiss A., Specht J.E., Cassman K.G. and Dobermann, A. 2008. Leaf area index simulation in soybean grown under near-optimal conditions. *Field Crops Research* 108:82-92.
- Setiyono T.D., Cassman K.G., Specht J.E., Dobermann A., Weiss A., Yang H., Conley S.P., Robinson A.P., Pedersen P. and De Bruin J.L. 2010. Simulation of soybean growth and yield in near-optimal growth conditions. *Field Crops Research* 119:161-174.

- Shanahan J.F., Schepers J.S., Francis D.D., Varvel G.E., Wilhelm W.W., Tringe J.M., Schlemmer M.R. and Major D.J. 2001. Use of remote sensing imagery to estimate corn grain yield. *Agronomy Journal* 95:583-589.
- Smith J.A. 1993. LAI Inversion Using a Back-Propagation Neural Network Trained with a Multiple Scattering Model. *IEEE Transactions On Geoscience And Remote Sensing* 31:1102-1106.
- Spitters C.J.T., Toussaint H.A.J.M. and Goudriaan J. 1986a. Separating the diffuse and direct component of global radiation and its implications for modeling canopy photosynthesis. Part I. Components of incoming radiation. *Agricultural and Forest Meteorology*. 38:217-229.
- Spitters C.J.T., Toussaint H.A.J.M. and Goudriaan J. 1986b. Separating the diffuse and direct component of global radiation and its implications for modeling canopy photosynthesis. Part II. Calculation of canopy photosynthesis. *Agricultural and Forest Meteorology* 38:231-242.
- Tei F., Scaife A. and Aikman D.P. 1996. Growth of lettuce, onion, and red beet. 1. Growth analysis, light interception, and radiation use efficiency. *Annals of Botany* 78:633-643.
- Tharakan P.J., Nowak C.A. and Abrahamson L.P. 2000. Modeling Growth and biomass production in willow plantations in the Northeastern and Mid-Atlantic United States. *Proceedings of Bioenergy 2000: Moving Technology into the marketplace*. New York, USA. 11 pp.
- Thenkabail P.S., Smith R.B. and De Pauw E. 2000. Hyperspectral vegetation indices and their relationships with agricultural crop characteristics. *Remote sensing of Environment* 71:158-182.
- Tian Y., Zhang Y., Knyazikhin Y., Myneni R.B., Glassy J.M., Dedieu G. and Running S.W. 2000. Prototyping of MODIS LAI and FPAR algorithm with LASUR and LANDSAT data. *IEEE transactions on geoscience and remote sensing* 38:2387-2401.
- Udelhoven T., Atzberger C. and Hill J. 2000. Retrieving structural and biochemical forest characteristics using artificial neural networks and physically based reflectance models. *Proceeding of the 20th EARSeL Symposium*. Dresden, Germany. pp. 205-211.
- Valdés-Gómez H., Gary C., Brisson N. and Matus F. 2014. Modelling indeterminate development, dry matter partitioning and the effect of nitrogen supply in tomato with the generic STICS crop–soil model. *Scientia Horticulturae* 175:44-56.

- Vargas L.A., Andersen M.N., Jensen C.R. and Jørgensen U. 2002. Estimation of leaf area index, light interception and biomass accumulation of *Miscanthus sinensis* ‘Goliath’ from radiation measurements. *Biomass and Bioenergy* 22:1-14.
- Veloso A., Demarez V. and Ceschia E. 2013. Retrieving crops Green Area Index from high temporal and spatial resolution remote sensing data. *Anais XVI Simpósio Brasileiro de Sensoriamento Remoto – SBSR*. Foz do Iguaçu, Brasil. pp.6425-6432.
- Verhoef W. 1984. Light scattering by leaf layers with application to canopy reflectance modeling: The SAIL model. *Remote Sensing of Environment* 16:125-141.
- Verhoef W. 1985. Earth observation modeling based on layer scattering matrices. *Remote Sensing of Environment* 17:165-178.
- Verstraete M.M. and Pinty B. 1996. Designing optimal spectral indexes for remote sensing applications. *IEEE Trans. Geosci. Remote Sens.* 34:1254-1265.
- Viña A. and Gitelson A.A. 2005. New developments in the remote estimation of the fraction of absorbed photosynthetically active radiation in crops. *Geophysical Research Letters* 32(17).
- Vohland M., Jarmer T. and Mader S. 2006. Assessment of the leaf area index for summer barley from field spectroradiometer and HyMap image data using the PROSPECT + SAIL models. *Proceedings of the 2nd Workshop of the EARSeL Special Interest Group on Land Use and Land Cover*. Bonn, Germany. pp. 28-30.
- Wahid D., Ishiguro E., Shimotashiro T., Hirayama S. and Ueda K. 2003. Study on relationships among LAI, DW, fPAR and spectral reflectance in paddy rice. *Journal of Agricultural Meteorology* 59:13-21.
- Walthall C., Dulaney W., Anderson M., Norman J., Fang H. and Liang S. 2004. A comparison of empirical and neural network approaches for estimating corn and soybean leaf area index from Landsat ETM+ imagery. *Remote Sensing of Environment* 92:465-474.
- Wang F., Fraisse C.W., Kitchen N.R. and Sudduth, K. A. 2003. Site-specific evaluation of the CROPGRO-soybean model on Missouri claypan soils. *Agricultural Systems* 76:985-1005.
- Wang Z., Wang J., Du K., Gao Y. and Xie D. 2005. A Model Coupling Radiative Transfer Models and Crop Growth Models. *IGARSS. 2005. Conference: Geoscience and Remote Sensing Symposium - IEEE International*. Seoul, South Korea. Vol. 5 pp. 3044-3046.

- Wang Y., Li X., Nashed Z., Zhao F., Yang H., Guan Y. and Zhang H. 2007. Regularized kernel-based BRDF model inversion method for ill-posed land surface parameter retrieval. *Remote Sensing of Environment* 111:36-50.
- Wang L., Qu J.J., Hao X. and Zhu Q. 2008. Sensitivity studies of the moisture effects on MODIS SWIR reflectance and vegetation water indices. *International Journal of Remote Sensing* 29:7065-7075.
- Wang L., Hunt E.R., Qu J.J., Hao X. and Daughtry C.S. 2011. Towards estimation of canopy foliar biomass with spectral reflectance measurements. *Remote Sensing of Environment* 115:836-840.
- Wei Z., Paredes P., Liu Y., Chi W.W. and Pereira L.S. 2015. Modelling transpiration, soil evaporation and yield prediction of soybean in North China Plain. *Agricultural Water Management* 147:43-53.
- Weidong L., Baret F., Xingfa G., Qingxi T., Lanfen Z. and Bing, Z. 2002. Relating soil surface moisture to reflectance. *Remote sensing of environment*, 81: 238-246.
- Weiss M. and Baret F. 1999. Evaluation of canopy biophysical variable retrieval performances from the accumulation of large swath satellite data. *Remote sensing of environment* 70:293-306.
- Weiss M., Baret F., Myneni R.B., Pragnère A. and Knyazikhin Y. 2000. Investigation of a model inversion technique to estimate canopy biophysical variables from spectral and directional reflectance data. *Agronomie* 20:3-22.
- Weiss M., Troufleau D., Baret F., Chauki H., Prévot L., Olioso A., Bruguier N. and Brisson N. 2001. Coupling canopy functioning and radiative transfer models for remote sensing data assimilation. *Agricultural and Forest Meteorology* 108:113-128.
- Xiong X. and Barnes W. 2003. Early On-orbit Calibration Results from Aqua MODIS Proceedings of SPIE - Sensors, Systems, and Next-Generation Satellites. Agia Pelagia, Crete. Vol. 4881 pp. 327-336.
- Xiong X., Sun J., Esposito J., Guenther B., Barnes W. 2003. MODIS reflective solar bands calibration algorithm and on-orbit performance. Proceedings of. SPIE - Optical Remote Sensing of the Atmosphere and Clouds III. Hangzhou, China. Vol. 4891 pp. 95-105.
- Yao Y., Liu Q., Liu Q. and Li X. 2008. LAI retrieval and uncertainty evaluations for typical row-planted crops at different growth stages. *Remote Sensing of Environment* 112:94-106.

- Yan G., Mu X. and Liu Y. 2012. Fractional Vegetation Cover. In *Advanced remote sensing: terrestrial information extraction and applications*. Liang, S., Li, X., & Wang, J. (Eds.). Academic Press. Academic Press Oxford, UK, pp. 416-435.
- Yi Y., Yang D., Huang J. and Chen D. 2008. Evaluation of MODIS surface reflectance products for wheat leaf area index (LAI) retrieval. *ISPRS Journal of Photogrammetry & Remote Sensing* 63:661-677.
- Yoder B.J. and Pettigrew-Crosby R.E. 1995. Predicting nitrogen and chlorophyll content and concentrations from reflectance spectra (400–2500 nm) at leaf and canopy scales. *Remote Sens. Environ.* 53:199-211.
- Zha Y., Gao J., Ni S., Liu Y., Jiang J. and Wei Y. 2003. A spectral reflectance-based approach to quantification of grassland cover from Landsat TM imagery. *Remote Sensing of Environment* 87:371-375.
- Zhang B., Song K., Zhang Y., Li F. and Wang Z. 2005. Study on the relationship between hyperspectral reflectance and soybean LAI, aboveground biomass. *Proceedings IEEE International Geoscience and Remote Sensing Symposium IGARSS'05*. Seoul, South Korea. Vol. 5, pp. 3583-3586.
- Zhang B., Feng G., Read J.J., Kong X., Ouyang Y., Adeli A. and Jenkins J.N. 2016. Simulating soybean productivity under rainfed conditions for major soil types using APEX model in East Central Mississippi. *Agricultural Water Management* 177:379-391.
- Zhou G., Liu X., Zhao S., Liu M. and Wu L. 2017. Estimating FAPAR of rice growth period using radiation transfer model coupled with the WOFOST model for analyzing heavy metal stress. *Remote Sensing*. 9(5)424.