

UNIVERSIDAD DE LA REPÚBLICA
FACULTAD DE AGRONOMÍA

**EVALUACIÓN DE DIFERENTES METODOLOGÍAS PARA ESTIMAR
EL RENDIMIENTO DE TRIGO UTILIZANDO INFORMACIÓN
PROVENIENTE DE SENSORAMIENTO REMOTO**

por

Deborah Viviana GASO MELGAR

TESIS presentada como uno de los
requisitos para obtener el título de
Magíster en Ciencias Agrarias
opción Ciencias Vegetales

MONTEVIDEO
URUGUAY
Diciembre 2015

Deborah Viviana Gaso Melgar, Ingeniera Agrónoma

Tesis dirigida por

Ing. Agr. Andrés Berger (PhD) _____

Instituto Nacional de Investigación Agropecuaria – INIA

Ing. Agr. Santiago Dogliotti (PhD) _____

Facultad de Agronomía, Universidad de la República

Aprobada el 16 de diciembre de 2015 por:

Ing. Agr. Verónica Ciganda (PhD) _____

Instituto Nacional de Investigación Agropecuaria - INIA

Ing. Agr. Alvaro Otero (PhD) _____

Instituto Nacional de Investigación Agropecuaria - INIA

Lic. Marcel Achkar (Dr) _____

Facultad de Ciencias, Universidad de la República

AGRADECIMIENTOS

Mis agradecimientos al Ing. Agr. PhD. Andrés Berger quien fue mi tutor de tesis, por contribuir en mi formación profesional y por su apoyo y direccionamiento que ha sido fundamental para el desarrollo de este trabajo.

Al equipo de Ecofisiología de Cultivos de INIA La Estanzuela por su asistencia en el trabajo de campo.

A las empresas que colaboraron en el desarrollo del trabajo brindando los sitios y la información recolectada en los monitores de rendimiento.

A la Agencia Nacional de Investigación e Innovación por el apoyo en mi formación con una beca de maestría.

TABLA DE CONTENIDO

	Página
PÁGINA DE APROBACIÓN.....	II
AGRADECIMIENTOS.....	III
RESUMEN.....	VII
SUMMARY.....	VIII
1. <u>INTRODUCCIÓN</u>	1
2. <u>ANTECEDENTES</u>	7
2.1. BASES CONCEPTUALES DEL SENSORAMIENTO	
REMOTO	7
2.1.1. <u>Evolución de la teledetección</u>	7
2.1.2. <u>Tipo de sensores</u>	7
2.1.3. <u>Espectro electromagnético</u>	8
2.1.4. <u>Procesos de la radiación en la atmósfera</u>	10
2.1.4.1. <u>Dispersión</u>	10
2.1.4.2. <u>Absorción</u>	11
2.1.4.3. <u>Reflectancia</u>	12
2.1.5. <u>Resolución de la imagen</u>	14
2.1.6. <u>Correcciones atmosféricas de las imágenes</u>	14

2.2. MODELOS DE CULTIVOS.....	19
2.2.1. <u>Modelos de cultivos integrados</u>	
<u>a sensoramiento remoto.....</u>	23
2.2.2. <u>Integración de modelos de cultivos.....</u>	26
2.3. UTILIZACIÓN DE LOS DATOS DE SENSORAMIENTO	
REMOTO EN LA AGRICULTURA.....	27
2.3.1. <u>Reflectancia de la cubierta vegetal.....</u>	27
2.3.2. <u>Índices de vegetación: aplicación en la agricultura.....</u>	28
2.3.3. <u>Complementariedad de los datos de sensoramiento</u>	
<u>remoto y los modelos de cultivos.....</u>	32
2.3.4. <u>Métodos para estimar características de la canopia</u>	
<u>desde observaciones de sensoramiento remoto.....</u>	36
3. <u>EVALUACIÓN DE DOS METODOLOGÍAS PARA ESTIMAR EL RENDIMIENTO DE</u>	
<u>TRIGO UTILIZANDO DATOS DE SENSORAMIENTO</u>	
<u>REMOTO.....</u>	39
3.1. RESUMEN.....	39
3.2. INTRODUCCIÓN.....	40
3.3. MATERIALES Y MÉTODOS	

3.3.1. <u>Localización de los sitios de estudio y determinaciones en el cultivo</u>	43
3.3.2. <u>Datos satelitales y correcciones atmosféricas de las imágenes</u>	44
3.3.3. <u>Predicción del rendimiento del cultivo: metodologías utilizadas</u>	45
3.3.4. <u>Índices de vegetación para predecir IAF</u>	46
3.3.5. <u>Descripción del modelo</u>	46
3.3.6. <u>Evaluación del desempeño de los métodos (I y II)</u>	49
3.4. RESULTADOS Y DISCUSIÓN	
3.4.1. <u>Correlación entre el área foliar observada y los índices de vegetación provenientes de las imágenes Landsat</u>	50
3.4.2. <u>Estimación del rendimiento utilizando el Método 1</u>	52
3.4.3. <u>Estimación del rendimiento utilizando el Método 2</u>	58
3.5. CONCLUSIONES	61
3.6. REFERENCIAS	62
4. <u>DISCUSIÓN GENERAL</u>	66
5. <u>CONCLUSIONES GLOBALES</u>	73
6. <u>BIBLIOGRAFÍA</u>	75

RESUMEN

La dificultad para estimar la variabilidad espacial del rendimiento y el interés por parte de los agricultores por conocer el rendimiento previo a la cosecha ha impulsado el desarrollo de metodologías que emplean información satelital en conjunto con modelos de cultivo. El objetivo del trabajo fue evaluar dos métodos para estimar el rendimiento de trigo previo a la cosecha en base a datos de sensoramiento remoto (SR). Las metodologías implementadas se denominaron Método 1 y Método 2. El Método 1 utilizó una serie temporal de imágenes, las cuales fueron asimiladas en un modelo de cultivos para optimizar los parámetros del mismo. Se desarrolló un modelo simple de cultivos basado en el modelo SAFY (Duchemin et al., 2008). El modelo se invirtió contra la serie de imágenes a los efectos de optimizar los parámetros y se ajustó un valor para cada parámetro, en forma independiente, en cada uno de los píxeles. Los valores de ajuste fueron utilizados para correr el modelo en forma independiente. El Método 2 consistió en utilizar una relación empírica entre un índice de vegetación calculado a partir de una imagen en la antesis del cultivo y el rendimiento observado. Los sitios de estudio se ubicaron en el suroeste de Uruguay y se utilizaron todas las imágenes Landsat 7 y 8 libres de nubes durante el ciclo del cultivo. El Método 1 no mostró ventajas respecto al Método 2, el cual es más simple ya que utiliza una única imagen en un momento dado del cultivo (RMSE =1532 kg.ha⁻¹ vs 966 kg.ha⁻¹ para el Método 1 y 2, respectivamente). Ambos métodos presentaron baja precisión, la cual fue probablemente el resultado de un conjunto de factores que contribuyeron a aumentar el error de estimación: alta resolución espacial, baja resolución temporal, limitantes aún no resueltas en las rutinas de correcciones atmosféricas, y errores en los monitores de rendimiento debidos a incidencia de enfermedades en el llenado de grano. En futuros estudios será necesario disponer de mayor resolución temporal, así como también generar mayor experiencia en la utilización de metodologías de corrección atmosférica para lograr mayor precisión.

Palabras claves: Landsat, modelos, índice de área foliar, índices de vegetación

ABSTRACT

The difficulty to estimate the spatial variability of yield and the interest of farmers in knowing final yield, has boosted the development of methodologies, which employed satellite information in conjunction with crop models. The objective of this work was to evaluate two methods for estimating wheat yield before harvest using data from remote sensing (RS). The methodology implemented was called Method 1 and Method 2. Method 1 consisted in optimizing a simple crop model (pySAFY) to predict leaf area index through the assimilation of time series of Landsat images, and later use the calibrated parameters (at the pixel level) to estimate pre-harvest yield and crop growth. The model used is based on the SAFY model, which was developed by Duchemin et al. (2008). First, the model was reversed against the times series of images to optimize the parameters. Then, a value for each parameter was fitted independently for each of the pixels and setting values of the parameters were used to run the model independently. Method 2 used an empirical relationship between vegetation index and observed yield. The study sites were located in the south and west of Uruguay and were planted with wheat in June 2013. Both Landsat 7 and 8 images free from cloud were used. Method 1 did not show advantages in terms of RMSE compared to Method 2, a simpler method that uses an empirical relationship between vegetation index and crop yield (RMSE= 1532 kg.ha⁻¹ vs 966 kg.ha⁻¹ for Method 1 and 2, respectively). The low accuracy obtained with the two methods tested was probably the result of a combination of several factors which contributed to an error on estimation. Such factors are: a) high spatial resolution, b) low temporal resolution, c) issues on atmospheric correction routines unresolved, d) errors due to yield monitors and, e) incidence of diseases in grain filling. In future studies it will be necessary to have higher temporal resolution as well as generating greater experience in the use of different methodologies of atmospheric correction to achieve higher levels of precision.

Keywords: Landsat, crop models, leaf area index, vegetation index

1. INTRODUCCIÓN

El trigo es el principal cultivo de invierno en las rotaciones agrícolas de Uruguay. En la última década el área del cultivo ha oscilado entre 153500 y 593400 hectáreas, con un rendimiento promedio entre 2183 y 3398 kg.ha⁻¹ (DIEA, 2014). La información provista por los monitores de rendimiento evidencian que el rendimiento promedio que alcanza el cultivo en una chacra se caracteriza por presentar gran variabilidad espacial producto de la heterogeneidad de suelos que presenta el área agrícola en Uruguay. Asociado a dichas características existe una demanda creciente por parte de los agricultores y empresas asociadas al sector por desarrollar tecnologías para estimar el rendimiento previo a la cosecha en forma precisa. Contar con una predicción del rendimiento y de su variabilidad espacial en etapas tempranas del cultivo sería de utilidad tanto en la organización de las operaciones comerciales como en la asistencia a las decisiones de manejo y separación de ambientes de diferente potencial. Los modelos de crecimiento de cultivos pueden ser una herramienta adecuada para lograr predicciones tempranas del rendimiento durante la temporada de crecimiento del cultivo. La principal dificultad para emplear modelos de cultivos en grandes áreas agrícolas de Uruguay es que las propiedades del suelo son muy heterogéneas en el espacio y como resultado las condiciones de crecimiento para el cultivo son altamente variables. Por tanto, la aplicación de modelos de cultivos en grandes áreas se ha visto obstaculizada por la falta de información espacial suficiente y precisa sobre las condiciones iniciales y de los valores de los parámetros de entrada de los mismos.

Modelos de Crecimiento de Cultivos. Desde sus comienzos, los modelos de crecimiento de cultivo, fueron diseñados para simular crecimiento y rendimiento en áreas agrícolas donde el suelo, el clima y las prácticas de manejo eran bien conocidos. El desarrollo de los modelos de cultivos comenzó en la década de los 60' junto con las computadoras, que permitieron comenzar con los primeros intentos de sintetizar el conocimiento generado a través de la experimentación analítica en

un modelo conceptual (Bouman et al., 1996; Van Ittersum et al., 2003a). Cuando la mayor parte de la investigación agrícola consistía en trabajos experimentales y su posterior análisis estadístico, varias limitantes fueron evidenciadas, entre las cuales se señala la dificultad para extrapolar y sintetizar el conocimiento generado en diferentes situaciones específicas (Van Ittersum et al., 2003b). Posteriormente a los primeros trabajos pioneros en el área de modelación, en la década de los 80' los científicos se involucraron particularmente en el desarrollo y aplicación de los modelos. En los 90', el enfoque tuvo algunos cambios volcándose a la investigación agronómica, las prácticas de manejo y la formulación de políticas. Soltani y Sinclair (2012b) discuten las oportunidades a futuro de los modelos de cultivos, estos autores señalan una serie de aplicaciones de los modelos de cultivos en su rol heurístico como soporte de la investigación científica, como herramienta para las decisiones de manejo de los agricultores y como ayuda en la educación y entrenamiento.

A lo largo de las diferentes décadas han co-existido varios grupos de científicos con extensa trayectoria en el desarrollo y aplicación de modelos de cultivos. El grupo de Wageningen tradicionalmente ha estado involucrado en el desarrollo y aplicación de los modelos de cultivos, desde los trabajos pioneros de deWit en la década del 60' (Van Ittersum et al., 2003a). Otro grupo de modelación muy conocido es el DSSAT (Decision Support System for Agrotechnology), el cual fue originalmente desarrollado por una red de científicos en cooperación con el proyecto IBSNAT (International Benchmark Sites Network for Agrotechnology Transfer) para facilitar las aplicaciones de los modelos de cultivos (CERES, Cropgro, entre otros) en la investigación agrícola utilizando un enfoque de sistema (Jones et al., 2003). El grupo de modeladores de la Universidad de Queensland en Australia también tiene una extensa trayectoria en el desarrollo y aplicación del modelo APSIM (Agricultural Production Systems SIMulator), el cual se compone de diferentes módulos. Este modelo fue desarrollado para simular procesos biofísicos en los sistemas agrícolas, en particular donde existe interés por el resultado

económico y ecológico de las prácticas de manejo debidas al riesgo climático (Hammer et al., 2010). El modelo APSIM tiene diferentes módulos para las plantas, suelo y manejo, que incluye un rango diverso de cultivos, pasturas y arboles, y los procesos del suelo incluyen el balance de agua y nitrógeno, la transformación de fosforo, el pH del suelo, la erosión y un rango completo de manejos. Un cuarto grupo de científicos se encuentra en Washington State University, quienes han desarrollado el modelo Cropsyst. El desarrollo de Cropsyst comenzó en la década de los 90' (Stockle et al., 1994). La motivación para el desarrollo de este modelo fue la identificación de un nicho de demanda por modelar los sistemas de cultivos, el cual no era correctamente proporcionado. El modelo Cropsyst ha sido una herramienta analítica utilizada para el estudio de los efectos del clima, suelo y manejo en la productividad de los sistemas de cultivos. Por otra parte, además de los grupos tradicionales en el desarrollo de modelos también existen esfuerzos individuales que han tenido prominente impacto en el desarrollo de la disciplina. Algunos ejemplos de esto son: los conceptos sobre un modelo conceptual basado en la eficiencia de uso de la radiación desarrollado por Monteith (1977); y modelos simples para diferentes cultivos como es el de trigo desarrollado por Sinclair y Amir (1992).

La utilización de modelos de simulación de cultivos en grandes áreas requiere conocer las condiciones iniciales de cada sitio y los valores de los parámetros de entrada en cada zona de crecimiento homogéneo. Por lo tanto, la aplicación de los modelos de cultivo para predecir el crecimiento y rendimiento a escala predial continúa siendo un desafío sin resolver, especialmente por la dificultad de delimitar estas zonas homogéneas, debido a la alta variabilidad espacial de nuestras áreas de producción agrícola.

Sensoramiento Remoto. La reflectancia del cultivo ha sido una herramienta utilizada para mejorar la capacidad de predecir el rendimiento en grandes áreas. Mientras que el sensoramiento remoto (SR) permite cuantificar el estado actual de

los atributos de la canopia (índice de área foliar, biomasa aérea acumulada, contenido de nitrógeno, estreses) en tiempo discreto; los modelos de crecimiento funcionan a un paso de tiempo de mayor frecuencia que la resolución temporal de la información satelital (típicamente el paso de tiempo de un modelo es de un día), por lo cual proporcionan una descripción continua del crecimiento de las plantas (Hatfield 1983; Maas, 1988; Delécolle et al., 1992; Hatfield et al., 2008).

Modelos de Cultivos y Sensoramiento Remoto. La complementariedad de los modelos de crecimiento de cultivos y el SR para mejorar la precisión de las estimaciones de rendimiento es ampliamente conocida y ha sido desarrollada en diferentes trabajos (Maas, 1988; Moulin et al., 1998, Rembold et al., 2013). Mientras que los modelos proveen una interpretación de las interacciones entre las plantas y el ambiente, los datos espectrales informan sobre el estado actual de los cultivos, sin tener en cuenta cómo fue alcanzado el mismo. La alta variabilidad espacial de la producción de los cultivos a escala de campo puede ser cuantificada y estudiada mediante la utilización de datos de reflectancia e índices de vegetación obtenidos a través de diferentes sensores remotos (Baret y Guyot, 1991; Moulin et al., 1998; Launay y Guerif, 2005; Duchemin et al., 2008).

En la literatura se han descrito múltiples métodos para utilizar la información espectral en conjunto con modelos de cultivos. Uno de los primeros trabajos fue el de Maas (1988), quien describió cuatro métodos diferentes para combinar los modelos de cultivos con observaciones radiométricas, los cuales posteriormente fueron revisados por Delécolle et al. (1992) y Rembold et al. (2013). Los cuatro métodos propuestos por Maas (1988) fueron identificados como: (i) uso directo de una variable estimada desde datos de sensoramiento remoto (*forcing*); (ii) actualización de las variables del modelo derivadas de datos de SR (*updating*); (iii) reiniciación del modelo, como es el ejemplo del ajuste de las condiciones iniciales para obtener una simulación en acuerdo con las observaciones derivadas del sensoramiento remoto (*re-initialization*); (iv) re-calibración del modelo, como es

el ejemplo del ajuste de parámetros para obtener una simulación en acuerdo con el IAF derivado de las observaciones (*re-calibration*).

Variables Biofísicas y Sensoramiento Remoto. Típicamente, la variable biofísica más utilizada para vincular la información espectral con los modelos de cultivos es el índice de área foliar (IAF) (Delécolle et al., 1992, Hatfield et al., 2008). El índice de área foliar se vincula funcionalmente con la reflectancia espectral de la canopia, por tanto la relación funcional del índice de área foliar con los datos de SR ha incitado a muchas investigaciones durante los últimos años. La estimación del índice de área foliar puede ser abordada desde dos enfoques, que fueron descritos por Baret y Buis (2008): (i) un enfoque centrado en las variables biofísicas, las cuales se calibran a través del proceso de inversión del modelo de crecimiento y (ii) el otro enfoque centrado en los datos radiométricos, donde los valores de IAF son estimados a través de un proceso de optimización, al comparar la reflectancia medida con la reflectancia predicha por medio de modelo de transferencia radiactiva (ej. ProSail). Por otra parte, la estimación del IAF también ha sido abordada desde metodologías más simples, como son la utilización de relaciones empíricas entre dicha variable y un índice de vegetación seleccionado (Hatfield, et al., 2004). Este último enfoque tiene la desventaja que la relación establecida es válida solo bajo las mismas condiciones (Jacquemoud et al., 1995). En caso que algunas de las condiciones sea modificada, la relación estimada entre el índice de vegetación y el IAF cambiará; como es el caso del ángulo de visión, las condiciones del suelo, la concentración de clorofila, la arquitectura del canopeo o las condiciones de humedad, (Jacquemoud et al.,1995).

Si bien en la literatura se pueden encontrar numerosos intentos por estimar el rendimiento de trigo y otros cultivos agrícolas utilizando datos de SR en conjunto con modelos de cultivos, la gran mayoría de los trabajos tuvieron por objetivo predecir el rendimiento a gran escala (país o región). La estimación temprana del

rendimiento a nivel de campo agrícola y con alta resolución espacial (equivalente a la resolución de satélite Landsat) continúa siendo un desafío sin resolver y es de gran utilidad en el sector agrícola, en lo que respecta a operaciones de manejo del cultivo y comercialización. A los efectos de mejorar la estimación espacial del rendimiento de trigo a escala predial, el objetivo de este trabajo fue evaluar dos metodologías para estimar el rendimiento, combinando datos provenientes de sensoramiento remoto (provistos por un satélite de fácil acceso a la información y alta resolución espacial como es Landsat) y variables biofísicas (IAF). Las dos metodologías evaluadas fueron: (i) método con enfoque empírico, donde se estima el rendimiento utilizando la relación entre el índice de vegetación (IAF) en el momento de antesis y el rendimiento observado; y (ii) método con enfoque semi empírico, donde los datos provenientes de las imágenes Landsat son integrados en un modelo simple de cultivos para calibrar los parámetros del mismo y posteriormente estimar el rendimiento previo a la cosecha. Ambos métodos se testearon en 22 predios agrícolas localizados en los departamentos de Soriano y Colonia sembrados con trigo durante los años 2013 y 2014.

2. ANTECEDENTES

2.1 BASES CONCEPTUALES DEL SENSORAMIENTO REMOTO

2.1.1 Evolución de la teledetección

La teledetección es la adquisición de información sobre un objeto o fenómeno, a pequeña o gran escala, desde instrumentos de grabación o escaneo que no están en contacto directo con el objeto (Jensen, 1996a). Típicamente estos instrumentos están montados sobre equipos terrestres, aviones, satélites, aeronaves, boyas o barcos. La percepción remota ha evolucionado enormemente en relación al dominio espectral, espacial y de análisis de la información. En lo que respecta al dominio espectral, se pasó desde las primeras placas fotográficas en 1839 hasta los sensores hiperespectrales como AVIRIS y NASA. En el dominio espacial, la evolución de los satélites con mayor frecuencia y número de sensores. Los de mayor impacto y difusión han sido desde 1 km² en AVHRR hasta 1 m² en IKONOS. Lo que respecta a los métodos de análisis han pasado desde sus inicios con la interpretación visual, al uso de las computadoras hasta la inteligencia artificial. Actualmente las metodologías de inteligencia artificial han tenido gran desarrollo en la clasificación de imágenes (Chuvieco, 2002).

2.1.2. Tipo de sensores

Los sensores más utilizados son instrumentos capaces de registrar la energía que reciben desde alguna fuente. En general, la fuente de energía más común, que la mayoría de los dispositivos y sensores remotos utilizan para observar la superficie terrestre, es la energía dentro del espectro electromagnético. Estos sensores registran la energía que es emitida o reflejada a partir de los atributos de la superficie terrestre (Jensen, 1996b).

Los sensores pueden ser activos o pasivos, dependiendo de cuál es la fuente de energía (natural o artificial). Los sensores pasivos son los que utilizan una fuente natural de energía como es el caso de la radiación del sol. Los sensores activos operan dentro del espectro electromagnético en la región de microondas y ondas de radio. La información que registran estos sensores se graba en formato digital (Jensen, 1996b).

2.1.3. Espectro electromagnético

El espectro electromagnético es la distribución de radiación electromagnética según sus longitudes de onda (Figura 1) (Conway, 1997). El espectro electromagnético se extiende desde la radiación de menor longitud de onda, como los rayos gamma y los rayos X hasta las ondas de mayor longitud como son las ondas de radio. Las regiones del espectro electromagnético se definen según, la longitud de onda, frecuencia y energía. La unidad más usada para medir las longitudes de onda a lo largo del espectro electromagnético es el micrón (μm).

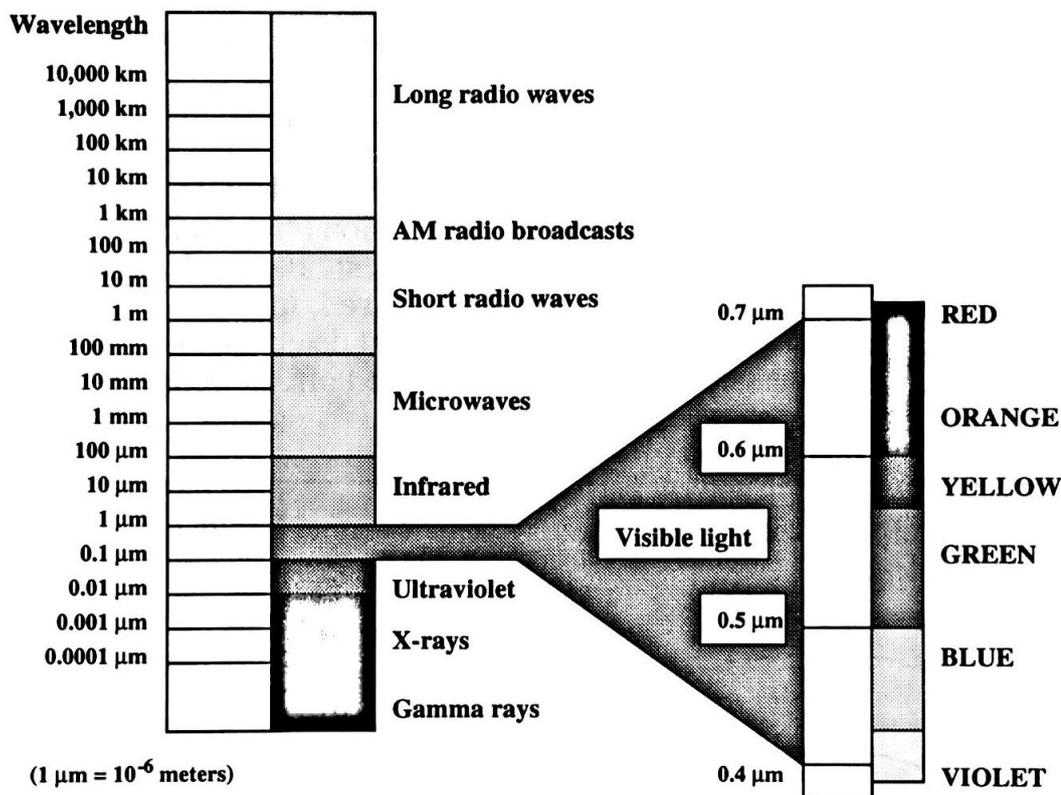


Figura 1. Espectro electromagnético (Conway, 1997).

El espectro electromagnético se divide en tres grandes regiones: ultravioleta, visible y microondas. La región del espectro visible es aquella que es capaz de ser detectada por el ojo humano, se extiende desde los 0,4 μm a 0,7 μm. En la región del visible se divide en las bandas del azul (0,4 μm-0,5 μm), verde (0,5 μm -0,6 μm) y rojo (0,6 μm-0,7 μm). En esta región y en la región del infrarrojo cercano (0,7 μm-1,3 μm) se recibe el máximo de energía solar que llega a la tierra. El infrarrojo termal es aquel que se encuentra entre las longitudes de onda de 4 μm a 22 μm. La mayor parte de los sensores remotos operan en la región del visible, infrarrojo y microondas (Conway, 1997).

2.1.4. Procesos de la radiación en la atmósfera

La atmósfera es el medio a través del cual la radiación electromagnética viaja desde el sol hacia el sensor. La atmósfera afecta a la radiación incidente mediante los mecanismos de dispersión, absorción y emisión (Figura 2).

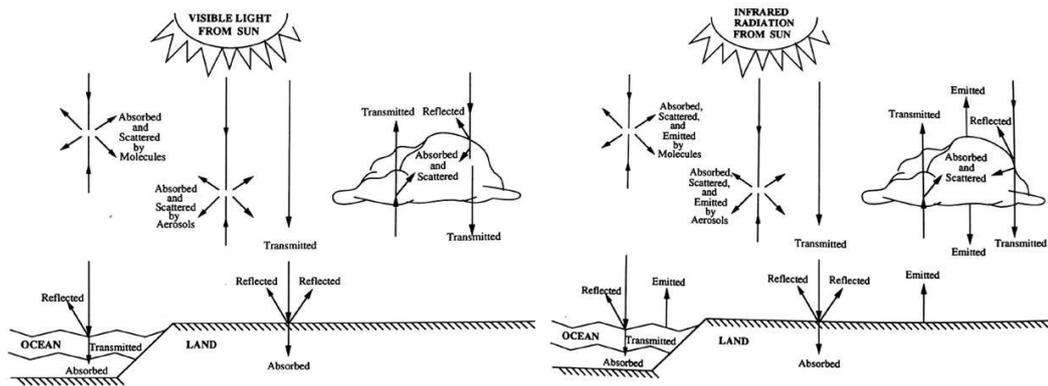


Figura 2. Procesos de dispersión, absorción y transmisión de la radiación (Conway, 1997).

Los gases de la atmósfera intervienen en los registros de los sensores debido a que interactúan con la radiación electromagnética. Por otra parte, en la atmósfera también hay partículas en suspensión como: aerosoles, polvo, cenizas. Los gases que se encuentran en la atmósfera absorben radiación, por lo que intervienen en los procesos de emisión y reflexión. Los principales gases atmosféricos que absorben la radiación son dióxido de carbono, oxígeno, vapor de agua, ozono, metano, óxido nítrico y monóxido de carbono. Las partículas en suspensión como el polvo y cenizas intervienen en el proceso de dispersión de la radiación.

2.1.4.1. **Dispersión**

La dispersión es el proceso impredecible de difusión de la radiación. Hay tres tipos de dispersión: Rayleigh, Mie y no selectivo. La dispersión Rayleigh es la más

común, es la producida por la interacción de partículas de menor diámetro con la radiación de longitudes de onda menores. La dispersión Mie es la producida por la interacción de partículas más grandes, como gotas de agua y polvo, y la radiación de longitudes de onda mayores. La dispersión no selectiva es el proceso mediante el cual se dispersan cantidades similares de luz roja, verde y azul (Schott, 2007).

2.1.4.2. Absorción

Es el proceso por el cual la energía incidente es retenida por una sustancia u objeto. La atmósfera actúa como una sustancia que retiene la energía radiante incidente. Los gases que contiene la atmósfera absorben y transmiten energía en diferentes longitudes de onda. La absorción de la radiación solar es principalmente causada por tres diferentes gases o constituyentes moleculares de la atmósfera. El vapor de agua es el componente de mayor absorción, seguido por el dióxido de carbono y el ozono. El oxígeno y nitrógeno son los gases más abundantes en la atmósfera y los que menos radiación incidente absorben. Se denominan bandas de absorción, aquellas longitudes de onda entre las cuales la absorción de la radiación incidente es máxima (Figura 3).

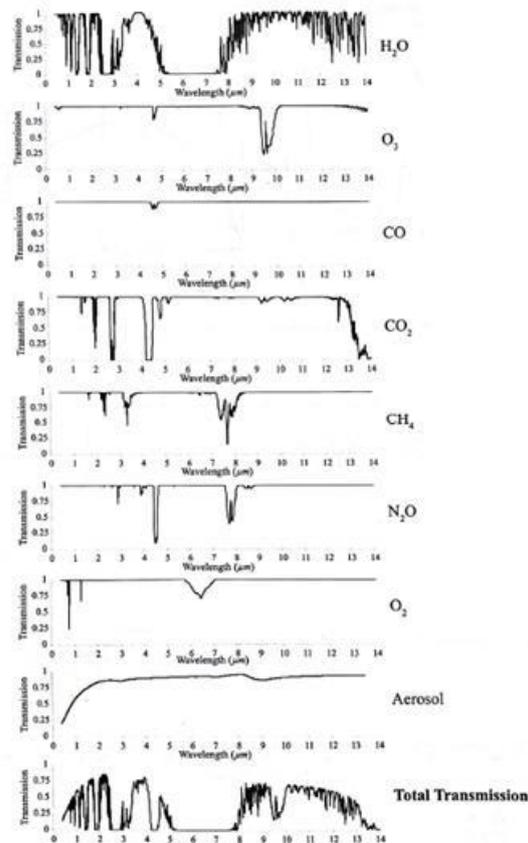


Figura 3. Bandas de absorción atmosférica en la región del visible, infrarrojo cercano e infrarrojo termal del espectro electromagnético (Schott, 2007).

2.1.4.3. Reflectancia

La reflectancia es el proceso mediante el cual una porción de la radiación incidente gira hacia atrás. La forma en que los objetos reflejan la energía está en función de las características de la superficie del objeto. Por esa razón, la reflectancia puede ser especular o difusa (Figura 4). La reflectancia especular es la que se da en superficies planas, donde los ángulos de incidencia y reflexión son iguales. La reflectancia difusa se da sobre superficies ásperas donde la reflectancia ocurre uniformemente en todas las direcciones.

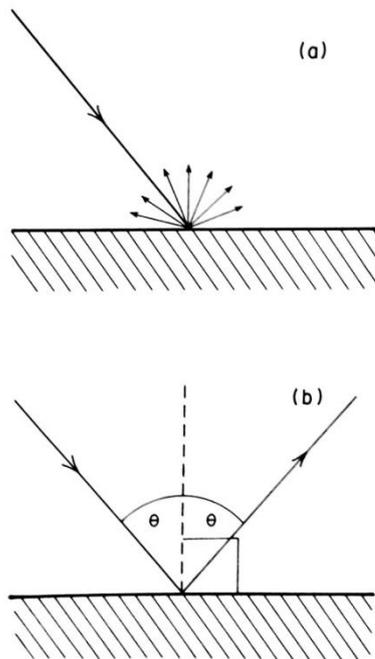


Figura 4. Tipos de reflectancia: (a) difusa, (b) especular.

La superficie de la tierra está cubierta por suelo, agua, rocas y vegetación. El conocimiento de las propiedades espectrales de cada objeto es fundamental para la elección de las bandas del espectro electromagnético que caracterizan a cada objeto y para su posterior estudio mediante sensores remotos. En la Figura 6 se representan las firmas espectrales de diferentes objetos en la superficie terrestre.

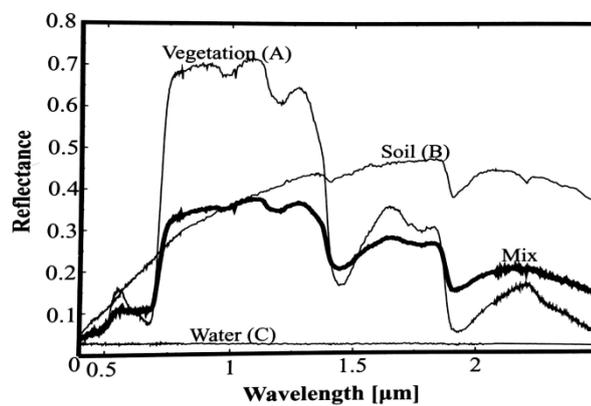


Figura 5. Firmas espectrales de diferentes objetos sobre la superficie terrestre (Schott, 2007).

2.1.5. Resolución de la imagen

La resolución de una imagen comprende el espacio temporal, espectral, radiométrico y espacial. La resolución espacial es la medida del objeto más pequeño que el sensor puede descubrir, está representado por los píxeles. La resolución espectral es el poder del sensor de diferenciar objetos en la superficie que está siendo observada. La resolución radiométrica está dada por el número de niveles digitales, representa los niveles de grises que son captados por el sensor. Esta resolución es la capacidad del sensor de discriminar diferentes niveles de radiación que es reflejada o emitida por un objeto, ósea la cantidad de niveles de grises que es capaz de captar el sensor. La resolución temporal es la frecuencia en el tiempo con la que el sensor toma las imágenes en una misma área.

2.1.6. Correcciones atmosféricas de las imágenes

La radiación que emite o es reflejada por la superficie o un objeto y llega a los sensores remotos esta distorsionada por los efectos de la atmósfera, que es traspasada por la radiación. Las correcciones atmosféricas evalúan y corrigen las distorsiones que la atmósfera introduce en los valores de radiación que llegan al sensor desde la superficie. La atmósfera actúa absorbiendo parte de la radiación emitida por la superficie y dispersándola. Las correcciones de dichos efectos se basan en modelos físicos complejos, como son los modelos basados en la transferencia radiactiva de la radiación (Richter, 2011). Las rutinas para realizar las correcciones atmosféricas se encuentran disponibles e implementadas en diferentes procedimientos (software), por ejemplo los que se listan en la Tabla 1.

Tabla 1. Comparación de los códigos más populares para realizar las correcciones atmosféricas (Richter, 2011).

Feature	ACORN	FLAASH	ISDAS	ATCOR
Multispectral instruments	+	+	+	+
Hyperspectral instruments	+	+	+	+
Adjacency correction	-	+	+	+
Water vapor retrieval	+	+	+	+
Haze removal	-	-	-	+
Spectral polishing	-	+	-	+
Spectral smile correction	+	-	-	+
Thermal region: Surface temperature, emissivity	-	-	-	+
Rugged terrain: DEM topographic correction	-	-	+	+

Note: A plus sign indicates that the corresponding feature is supported, whereas a minus sign indicates the capability is missing.

La Figura 6 contiene un resumen de los principales pasos involucrados en el proceso de corrección atmosférica utilizados en ATCOR. Brevemente el proceso tiene los siguientes pasos, luego de leer la máscara del sensor específico LUT, se procede para obtener las áreas de tierra, agua, niebla, nubes y sombra. Posteriormente, se lleva a cabo en forma opcional la remoción de la neblina o cirrus, seguido por la remoción de la sombra. En el próximo paso, se calcula la visibilidad o el mapa del espesor óptico de los aerosoles, usando el método de la vegetación densa y oscura (DDV). Este paso es seguido por una actualización del modelo de aerosoles (el comportamiento de la radiación en las bandas del rojo y azul), si la banda azul existe, la opción de actualización está habilitada. Luego de calcular el mapa de vapor de agua, la recuperación de la reflectancia de la superficie se lleva a cabo contabilizando los efectos del albedo adyacente y esférico. Posteriormente se realizan las correcciones atmosféricas y en los instrumentos hiperspectrales se realiza un pulido espectral y se pueden realizar también las correcciones BRDF.

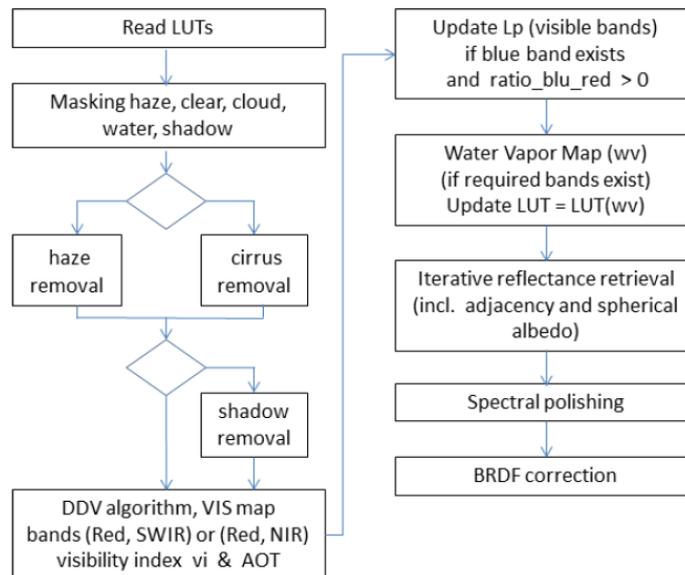


Figure 10.1: Main processing steps during atmospheric correction.

Figura 6. Pasos principales del procesamiento de corrección atmosférica en ATCOR (Richter, 2011).

El paso inicial previo a realizar las correcciones atmosféricas consiste en transformar los números digitales en valores de radiancia. Dicha transformación se realiza a través de una ecuación lineal simple que utiliza parámetros que son específicos para cada banda y sensor remoto (Richter, 2011). A continuación se presenta la relación utilizada para transformar los valores de números digitales en valores de radiación:

$$L = C_0 + C_1ND$$

Donde: L es el valor de radiación, C_0 y C_1 son parámetros específicos para cada banda y sensor y ND es el valor del número digital.

Richter 2011 sintetiza el total de radiación que llega al sensor remoto dividiéndola en tres tipos: a) la proveniente de la dispersión que ocurre por diferentes partículas en la atmósfera, b) la emitida por la superficie comprendida en el pixel de interés y c) la emitida por pixeles vecinos. Los tres tipos de radiación

son representados en la Figura 7 por L_1 , L_2 y L_3 respectivamente. Del total de radiación que es capturada por el sensor remoto, solamente la señal representada por L_2 en el esquema de la Figura 7 contienen información acerca de la superficie de interés (el pixel de interés). Durante el proceso de corrección atmosférica se deberá filtrar las señales representadas por L_1 y L_3 en el esquema de la Figura 7.

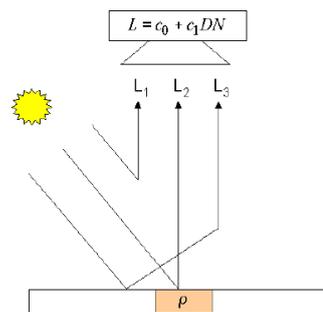


Figura 7. Esquema de los componentes de radiación en un terreno plano. L_1 radiación por la dispersión de partículas en la atmosfera, L_2 reflectancia del pixel de interés y L_3 reflectancia de pixeles adyacentes (Richter y Schläpfer, 2013).

Richter y Schläpfer (2013) divide las condiciones atmosféricas en condiciones estándar y condiciones no estándar. El efecto de las condiciones estándar es simple de filtrar debido a que su comportamiento es conocido, en cambio el comportamiento de las condiciones no estándar como las nubes son poco predecibles (Figura 8).

Los principales factores atmosféricos que distorsionan la señal emitida por la superficie y que llegan al sensor son: los aerosoles y el vapor de agua. Cuando la superficie de interés que se está observando es una cubierta vegetal, el vapor de agua es una variable de gran importancia debido a la fuerte absorción que ocurre en longitudes de onda del infrarrojo cercano. El efecto de los aerosoles es a través de la dispersión de la radiación en bajas longitudes de onda del espectro visible. Para aislar el efecto de los aerosoles se utiliza la reflectancia en los canales de menor longitud de onda del visible (el canal del azul profundo) de un pixel de

comportamiento conocido (un pixel de vegetación densa y oscura). En las capas bajas de la troposfera el contenido de vapor de agua es alto (90% o más), la absorción de radiación que ocurre por dicho componente de la atmósfera es estimado a través de la fuerte absorción que ocurre en las longitudes de onda de $1,38 \mu m$ y $1,88 \mu m$ del espectro electromagnético (Richter y Schläpfer, 2013).



Figura 8. Ejemplo de remoción de neblina en una imagen de ALOS-AVNIR2 en el norte de Alemania el 16 de abril de 2007. Izquierda: una parte original de la imagen, derecha: después de la remoción de la neblina (Richter y Schläpfer, 2013).

Las condiciones no estándar son aquellas que son variables en el tiempo y el espacio, como las nubes, neblina y sombra de nubes (Figura 9). En el caso del software ATCOR, la imagen se divide en las áreas limpias, con neblina y cubiertas por nubes. La zona de neblina es una capa que se encuentra a una altitud entre cero a tres kilómetros. Richter y Schläpfer (2013) explica como son aislados los efectos de la neblina a través de utilizar la relación entre el canal azul y el rojo. Mientras la neblina se encuentra en las capas bajas de la troposfera, las nubes generalmente están en las capas más altas de la troposfera y las más bajas de la estratosfera. Las nubes afectan la zona del NIR y SWIR del espectro visible. Cuando los anchos de

banda son amplios en las zonas de detección de nubes y las nubes son de escaso espesor, resulta casi imposible identificar el efecto de dichas nubes que están sobre la superficie de la tierra, este tipo de nubes son parcialmente transparente. El algoritmo utilizado para corregir las nubes que se encuentran encima de la tierra y agua es diferente. En el agua se utiliza la relación entre los canales de 1,38 μm y 1,24, mientras que en la tierra se usan los canales de 1,38 μm y el rojo (alrededor de 0,66 μm).

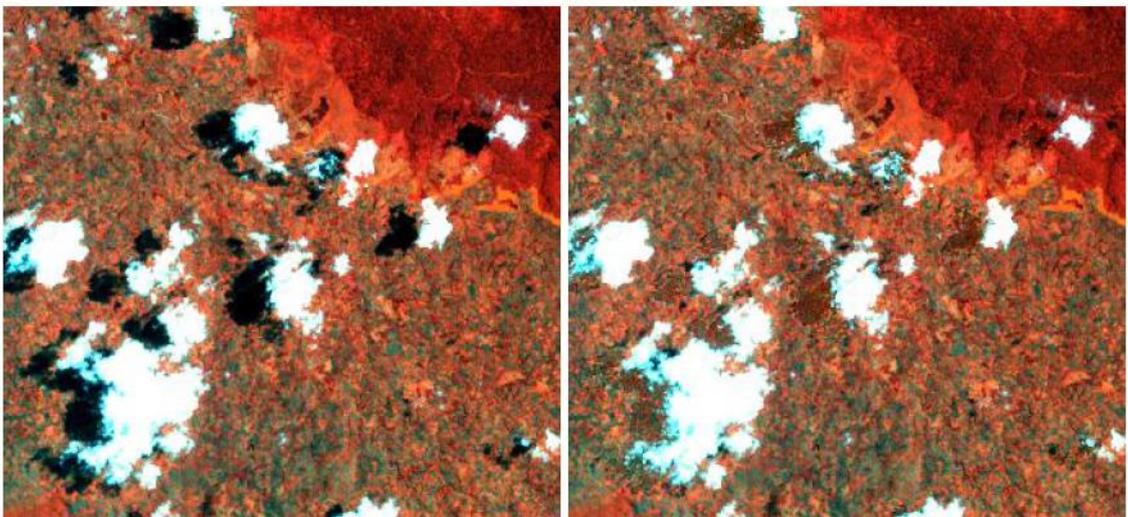


Figura 9. Remoción de la sombra en una imagen Landsat-7 ETM+. Código de color: RGB = bandas 4/2/1 (830, 560, 480 nm). Izquierda: imagen original, derecha: después de remover las sombra.

2.2 MODELOS DE CULTIVOS

La modelación de cultivos surgió en la década de los 60' y desde ese momento ha pasado en su desarrollo por una serie de etapas. Desde los inicios, parecía tener un desempeño prometedor como sustituto de la ambigua y engorrosa experimentación de campo. Durante las primeras etapas, hubo un gran incremento en los niveles de complejidad, el cual fue acompañado del aumento en la sofisticación de los equipos computacionales. La representación de más detalle en

la descripción del funcionamiento de los componentes abióticos y bióticos del sistema de cultivo, condujo a generar grandes expectativas con el uso de los modelos que posteriormente no fueron saldadas (Sinclair y Seligman, 1996). En las etapas más adultas de la modelación de cultivos, como la modelización ecológica avanzada, ha demostrando ser más una herramienta heurística, que un sustituto de la realidad. En el área académica y de investigación, estos modelos pueden ser de gran valor cuando se utiliza como ayuda para el razonamiento sobre el funcionamiento y la respuesta de los sistemas de cultivo en diferentes escenarios (Sinclair y Seligman, 1996).

La transparencia y robustez son dos aspectos críticos para evaluar un modelo. La transparencia refiere a los parámetros del modelo, diagrama de flujo y al grado de comprensión del código del mismo. La robustez es la habilidad del modelo para simular la realidad. El juicio de la comparación con las observaciones dependerá del objetivo con el cual fue desarrollado el modelo (Soltani y Sinclair, 2012b). Las desviaciones entre las predicciones del modelo y las observaciones pueden incrementarse en la medida que aumenta la complejidad del modelo (Reynolds y Acock, 1985 citado en Passioura, 1996). Recientemente Soltani y Sinclair (2015), realizaron una evaluación de la transparencia y robustez entre cuatro modelos de trigo de diferente grado de complejidad. Los autores evaluaron la transparencia de los modelos a través del número de parámetros: CropSyst (50 parámetros) y SSM (55 parámetros) como los modelos más simples y DDSAT (211 parámetros) y APSIM (292 parámetros) como los modelos más complejos. Los autores concluyen que la pérdida de transparencia, sacrificando el número de parámetros no fue recompensada con un incremento en la robustez de las salidas del modelo.

La sumatoria de los errores en la estimación de un modelo se pueden dividir en: errores de estructura y errores de los parámetros. En la Figura 10, se representa gráficamente la relación entre la complejidad del modelo y la precisión del mismo.

En la medida que el modelo es más complejo, se reducen los errores de estructura, debido a que el modelo es más cercano a representar el sistema real que se simula. En los sistemas biológicos donde la estructura no es completamente conocida, los errores de estructura disminuyen hasta cierto punto de complejidad del modelo, a partir del cual los errores de estructura se estabilizan. Como se representa en la Figura 10 los errores totales son minimizados en un cierto rango de nivel de estructura y complejidad del modelo (Reynolds y Acock, 1985 citado en Passioura, 1996).

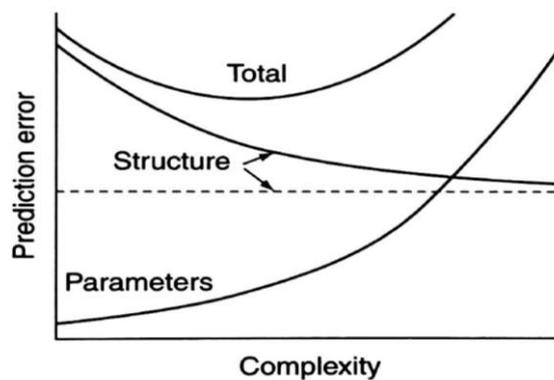


Figura 10. Relación entre la complejidad y los errores de predicción en modelos biológicos. La línea punteada representa los errores de estructura que son irreducibles debido a la falta de conocimiento de la estructura del sistema. (Reynolds y Acock, 1985, citado en Passioura, 1996).

Un modelo de cultivos se puede definir como una representación simple y sintética de los procesos fisiológicos y ecológicos más importantes que gobiernan el crecimiento. Los modelos de simulación de crecimiento de cultivos son herramientas que permiten representar el crecimiento del cultivo y sus interacciones con el ambiente. Existen diferentes tipos de modelos dependiendo del nivel de explicación de los procesos. En las ciencias biológicas donde los procesos ocurren en diferentes niveles de organización, es posible implementar modelos mecanísticos, explicativos de los procesos que ocurren en los diferentes

niveles de integración. Los diferentes niveles de integración se pueden clasificar de acuerdo con el tamaño del sistema, tales como moléculas, estructuras celulares, células, tejidos, órganos, individuos, poblaciones, comunidades y ecosistemas. Los modelos explicativos incluyen al menos dos niveles de integración. Los modelos utilizados en vegetales son generalmente dinámicos, donde la variable tiempo desempeña un rol relevante en el mismo ya que son procesos continuos descriptos en el tiempo. Las variables que son modelizadas no permanecen invariables, son consideradas funciones del tiempo y describen una trayectoria temporal. Cuando se utilizan modelos de cultivos mecanístico, típicamente el modelo se divide en diferentes módulos que dependen del grado de integración de los procesos que comprenden la interacción suelo-planta-atmosfera. En la Figura 11 se representa un ejemplo de un modelo mecanístico como es el modelo Gecros (Yin y van Laar, 2005).

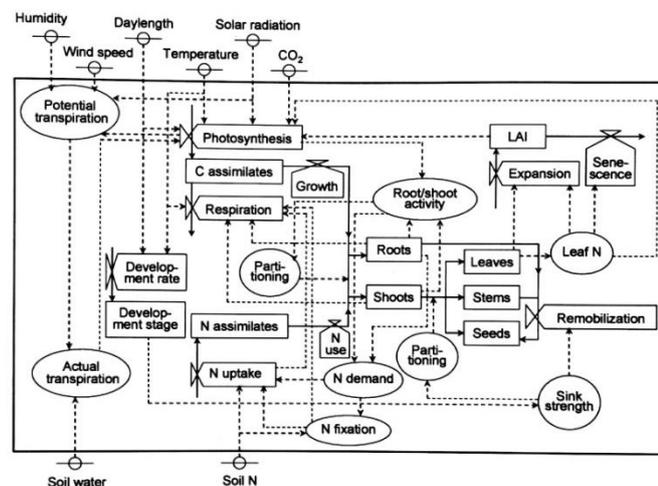


Figura 11. Diagrama relacional de un modelo de simulación de crecimiento de los cultivos mecanístico (Gecros) tomado de Yin y van Laar (2005). En el esquema se utilizan los símbolos estándar de Forrester (1961). El modelo intenta capturar el balance de energía y la asimilación de carbono y nitrógeno. Las variables de entradas ambientales incluyen los factores climáticos (por ejemplo: temperatura y radiación) y las variables edáficas (agua y nitrógeno disponible, los cuales pueden

ser influenciados por factores climáticos y las prácticas de manejo, como la fertilización y riego). Los coeficientes genéticos son otros parámetros de entrada del modelo que no se muestran en el diagrama.

2.2.1 Modelos de cultivos integrados a sensoramiento remoto.

De acuerdo con una clasificación que fue propuesta por Moulin et al. (1998), los modelos de cultivos, que son utilizados para predecir el crecimiento y rendimiento de cultivos asimilando datos de SR, se dividen en tres categorías: (i) Modelos empíricos, (ii) Modelos semi-empíricos, (iii) Modelos mecanísticos. Los modelos empíricos están basados en una relación lineal simple entre el rendimiento y el índice de vegetación. Dicho enfoque se sustenta en la estrecha relación entre las medidas radiométricas y las características del cultivo, como es el ejemplo de la relación entre la biomasa y el ratio entre la reflectancia del rojo y el NIR (Tucker et al., 1981). En este enfoque el rendimiento final está determinado -en parte- por el área foliar al inicio del estado reproductivo, y como el área foliar se relaciona con el índice $R_{\text{rojo}}/R_{\text{NIR}}$ o otros similares, estos índices podrían ser utilizados para definir el potencial de rendimiento cosechable durante la etapa reproductiva (Hatfield, 1983). Los modelos semi-empíricos incorporan la aproximación teórica de Monteith (1977), donde la biomasa aérea total acumulada diariamente es una función de la radiación global incidente, como es el ejemplo que se esquematiza en la Figura 12. En este caso, el crecimiento diario es obtenido a través de computar la integración de la radiación global y tres factores de eficiencia. Los factores de eficiencia se corresponden con: a) la proporción de radiación fotosintéticamente activa del total de radiación (PAR), b) la eficiencia de interceptación de PAR (fPAR) y c) la eficiencia de conversión del PAR interceptado en biomasa (EUR). El enfoque que emplean los modelos mecanísticos comprende aquellos modelos que fueron diseñados para simular los procesos que explican la evolución en el tiempo de las principales variables de estado del cultivo. Por lo tanto el modelo principal integra otros sub-

modelos que describen en forma acoplada numerosos procesos fenológicos y fisiológicos, tales como la fotosíntesis, la respiración, la evapotranspiración y la absorción de nitrógeno (Figura 11).

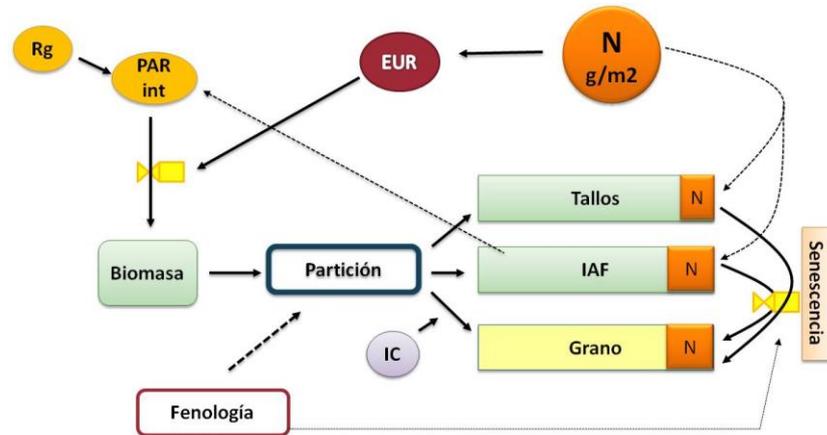


Figura 12. Esquema de un modelo simple de cultivos basado en el modelo SAFY (Duchemin et al., 2008), donde R_g es la radiación global incidente, PAR_{int} es la radiación fotosintéticamente activa interceptada, EUR es la eficiencia de uso de la radiación, N es la concentración de nitrógeno en el cultivo y IC es el índice de cosecha.

El crecimiento diario del cultivo puede ser calculado a través de integrar la radiación fotosintéticamente activa interceptada con la eficiencia de uso de dicha radiación (EUR); como se representa en el esquema de la Figura 12, en un modelo conceptual simple. La EUR es un parámetro crítico para calcular el crecimiento de los cultivos. En condiciones óptimas de temperatura, agua y nitrógeno, la EUR toma un valor único para cada especie de cultivo (Sinclair y Muchow, 1999). En la Tabla 2 se presentan valores de EUR para diferentes cultivos.

Tabla 2. EUR ($\text{gM}\cdot\text{j}^{-1}\text{ PAR}$) para diferentes cultivos (Sinclair y Muchow, 1999).

Crop species	Radiation use efficiency (g MJ^{-1})
Cotton	1.8
Chickpea	1.8
Pea	1.8
Soybean	2.0
Peanut	2.0
Canola	2.0
Sunflower	2.1
Barley	2.1
Wheat	2.2
Rice	2.2
Maize	3.5
Sorghum	3.5
Sugarcane	3.6

Cualquiera de los factores que modifican la tasa de fotosíntesis, como la temperatura, la concentración de dióxido de carbono, estrés por deficiencia de agua y concentración de nitrógeno, resultan en una reducción de la EUR. La EUR es máxima en un rango de temperaturas óptimas, y decrece por debajo o por encima de dicho rango como se muestra en la Figura 13 (Soltani y Sinclair 2012a). Por otra parte, el nitrógeno es un constituyente fundamental de las enzimas involucradas en la fotosíntesis. Los vegetales necesitan grandes cantidades de nitrógeno en los órganos de mayor participación en el proceso de fotosíntesis. La proporción de nitrógeno en las hojas que están vinculadas con el proceso de fotosíntesis es muy alta, tres cuartas partes del nitrógeno total en las hojas está relacionado con la fotosíntesis (Sinclair y Horie, 1989). Varios estudios muestran la relación entre la concentración de nitrógeno en las hojas y la EUR. Sinclair y Horie (1989) presentan una relación cuantitativa entre el nitrógeno y la EUR para tres especies de cultivos con diferentes mecanismos de fotosíntesis (Figura 13).

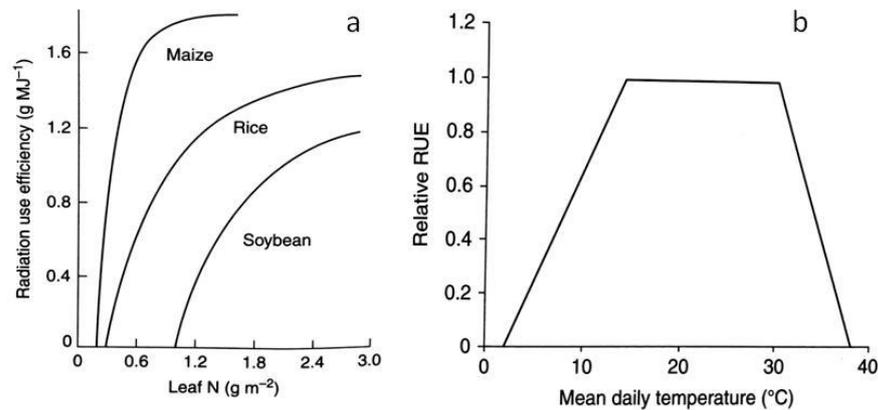


Figura 13. EUR para maíz, arroz y soja en función de la concentración de nitrógeno en la hoja (a) y efecto de la temperatura media en la EUR (Sinclair y Horie, 1989).

2.2.2 Integración de modelos de cultivos.

El modelo que se conceptualiza en la Figura 12 es una conjunción del modelo SAFY presentado por Duchemin et al. (2008) y el modelo conceptual desarrollado por Sinclair y Jamieson (2008), quienes discuten la importancia del carbono y nitrógeno acumulado en la determinación del rendimiento. Los autores muestran evidencias experimentales que sustentan la hipótesis que el rendimiento en grano es fundamentalmente causado por las fuentes de C y N acumuladas previo antesis; en contraposición a la hipótesis que propone que el número de granos es la variable que determina la intensidad de la fotosíntesis y la translocación de fotoasimilados al grano durante el llenado del mismo. El período de llenado de grano, en el modelo representado en la Figura 12, es regulado mediante la translocación de nitrógeno desde los órganos vegetativos al grano. La habilidad de mantener las hojas verdes durante el llenado del grano (*stay-green*) se relaciona con el balance entre el suministro y la demanda de nitrógeno durante el llenado del mismo. Borrell et al., (2001) observaron esta relación entre el mantenimiento de las hojas verdes y la duración del llenado en el cultivo de sorgo. Martre et al. (2003) sugirieron que el N removilizado no es impulsado por la demanda de N por el grano, sino más bien, por el suministro de fuente de los tejidos vegetativos. La demanda

diaria de nitrógeno por los granos conceptualizada en la Figura 12 es definida mediante el crecimiento diario durante el llenado de granos y una concentración de nitrógeno fijada en 65 mg N g^{-1} (Sinclair et al., 2003). La concentración mínima de nitrógeno en los tejidos a la senescencia es de 0.8 g N m^{-2} en las hojas y 8 mg N g^{-1} en los tallos (Sinclair et al., 2003). La translocación de nitrógeno desde las hojas resulta en una reducción del área foliar, con la cual consecuentemente decrece la radiación interceptada y la acumulación de biomasa. Dicho proceso resulta en una “autodestrucción” del cultivo como fue propuesto por Sinclair y deWit, (1976) durante el período de llenado de grano. La madurez fisiológica del cultivo se alcanza cuando los valores de índice de área foliar llegan al valor de 0.1 (Sinclair, 1986).

2.3 UTILIZACION DE LOS DATOS DE SENSORAMIENTO REMOTO EN LA AGRICULTURA

2.3.1. Reflectancia de la cubierta vegetal

La cubierta vegetal tiene una curva de reflectancia característica, con regiones muy acentuadas en la región visible del espectro. La curva de reflectancia de la vegetación tiene dos valles que están determinados por el contenido de pigmentos en las plantas, asociado principalmente a las regiones de absorción de radiación de la clorofila (Figura 14). La clorofila tiene una fuerte absorción en las zonas del azul (450 nm) y rojo (680 nm). Cuando las plantas están sujetas a un estrés que distorsiona el normal crecimiento y la producción de clorofila, la reflectancia en las bandas del azul y rojo se incrementa. En una cubierta vegetal verde, la reflectancia en las bandas correspondientes a la región del verde es de 15 – 20%. En la zona del infrarrojo cercano (NIR) típicamente las plantas reflejan alrededor del 40 al 60% de la radiación incidente, el resto de la radiación es transmitida y solo alrededor del 5% es absorbido por la cubierta vegetal. La alta

reflectancia en la zona del NIR se debe a la dispersión de la luz en el volumen intercelular de las células del mesófilo de las hojas (Merzlyak y Gitelson, 1995).

La absorción y reflectancia espectral de diferentes cubiertas vegetales tienen características comunes. Mientras en la región del azul y del NIR del espectro visible, la sensibilidad al contenido de pigmentos es mínima; las zonas del borde rojo y verde son altamente sensibles al contenido de clorofila. En la región del rojo (670 nm) la absorción y reflectancia de hojas es insensible cuando los contenidos de clorofila son de moderados a altos (Hatfield, et al., 2008). La mayor sensibilidad en la reflectancia por variaciones en el contenido de clorofila ocurre en la banda del verde y el borde rojo (Figura 15).

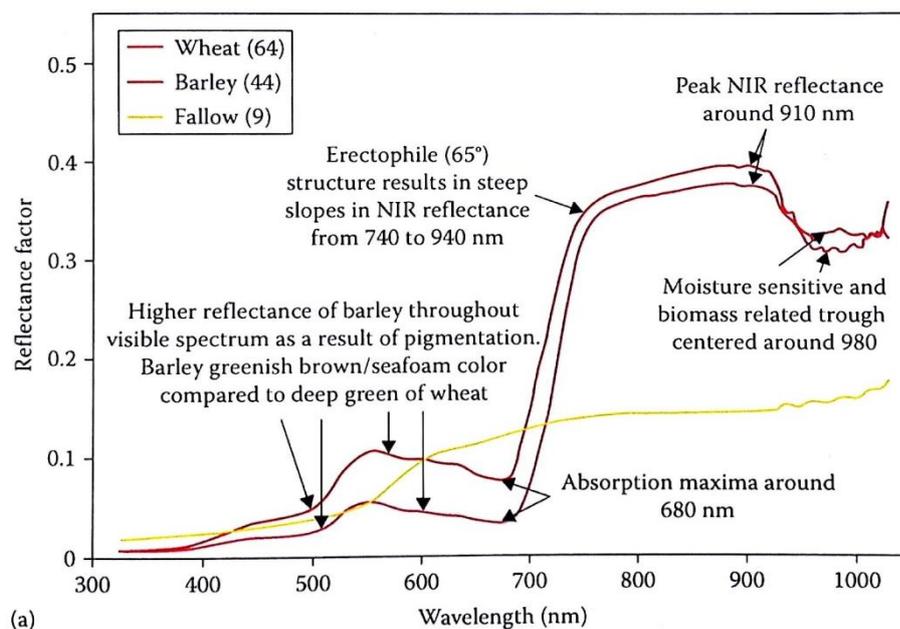


Figura 14. Curvas de reflectancia de dos cultivos agrícolas y de un suelo en barbecho (Gitelson et al., 2012).

2.3.2. Índices de vegetación: aplicación en la agricultura

El índice de vegetación (IV) es un valor calculado a través de operaciones simples entre los valores de reflectancia de distintas longitudes de onda que se

relacionan con las características de la vegetación (Gitelson, 2012). Generalmente los IV son operaciones simples entre las reflectancias de las regiones que contienen la información espectral de una cubierta vegetal. Las dos bandas que se utilizan mayoritariamente son las correspondientes a la región del rojo e infrarrojo, que contienen más del 90% de la información de una cubierta vegetal (Gitelson, 2012). El desarrollo de los índices de vegetación comenzó con el ratio simple propuesto por Jordan (1969) que relacionaba la reflectancia del infrarrojo cercano y el rojo. Posteriormente este índice fue refinado a través de utilizar la diferencia normalizada que propuso Tucker (1979), el cual se denominó como NDVI.

El NDVI presenta la limitante de la falta de linealidad en la relación entre dicho índice y características de la vegetación. Por este motivo, la utilidad de este índice para predecir características de la vegetación como es el IAF es muy baja. Debido a la forma de cálculo del NDVI, que es a través de un simple ratio entre la resta y la suma de las bandas del rojo e infrarrojo, tiende a la saturación cuando el IAF supera el valor de dos a tres (Gitelson, 2012).

Por otra parte, el NDVI presenta una serie de ventajas asociadas a la fácil disponibilidad de información necesaria para su cálculo y a la simpleza del mismo. Al ser un índice relativo, posee además mayor robustez ante diferencias en absorción atmosférica siendo más tolerante a inexactitudes en la corrección atmosférica (referencias). El desarrollo de otros índices continuó en años sucesivos, mejorando la predictibilidad inicial del NDVI. En la Tabla 3 se presenta un resumen de los índices más comunes y sus aplicaciones en la agricultura (Hatfield, et al., 2008).

Tabla 3. Resumen de los índices de amplia utilización en la agricultura, longitudes de onda para su cálculo, aplicaciones y referencias bibliográficas (Hatfield et al., 2008).

Index	Wavebands	Application	Reference
	$R_{800}-R_{680}$	biomass	Jordan, 1969
	$R_{800}-R_{550}$	biomass	Bushman and Nagel, 1993
	R_{550}	chlorophyll	Carter, 1994
	R^{-1}_{700}		Gitelson et al., 1999
	$\log(1/R_{737})$	chlorophyll	Yoder and Pettigrew-Crosby, 1995
Simple ratio	$R = R_{NIR}/R_{red}$	biomass, LAI, cover	Birth and McVey, 1968; Jordan, 1969
Photochemical Reflectance Index	$PRI = (R_{550} - R_{531}) / (R_{550} + R_{531})$	light capture efficiency	Gamon et al., 1992
Pigment-specific normalized difference	$(R_{800} - R_{470}) / (R_{800} + R_{470})$	LAI	Blackburn, 1998
Normalized Difference Vegetation Index	$NDVI = (R_{NIR} - R_{red}) / (R_{NIR} + R_{red})$	intercepted PAR, vegetation cover	Deering, 1978
Perpendicular Vegetative Index	$PVI = (R_{NIR} - aR_{red} - b) / (1 + a^2)^{1/2}$	LAI	Richardson and Wiegand, 1977
Wide Dynamic Range Vegetation Index	$WDRVI = (0.1R_{NIR} - R_{red}) / (0.1R_{NIR} + R_{red})$	LAI, vegetation cover, biomass	Gitelson, 2004
Soil Adjusted Vegetation Index	$SAVI = (R_{NIR} - R_{red})(1 + L) / (R_{NIR} + R_{red} + L)$	LAI	Huete, 1988
Transformed Soil Adjusted Vegetative Index	$TSAVI = a(R_{NIR} - aR_{red} - b) / (R_{red} + aR_{NIR} - ab)$	LAI, biomass	Baret et al., 1989
Enhanced Vegetation Index	$EVI = 2.5(R_{NIR} - R_{red}) / (R_{NIR} + 6R_{red} - 7.5R_{blue} + 1)$	LAI, biomass	Huete et al., 2002
Green NDVI	$(R_{NIR} - R_{green}) / (R_{NIR} + R_{green})$	intercepted PAR, vegetation cover	Bushman and Nagel, 1993; Gitelson and Merzlyak, 1994; Gitelson et al., 1996
Red Edge NDVI	$(R_{NIR} - R_{red\ edge}) / (R_{NIR} + R_{red\ edge})$	intercepted PAR, vegetation cover	Gitelson and Merzlyak, 1994
Visible Atmospherically Resistant Indices	$VARI_{green} = (R_{green} - R_{red}) / (R_{green} + R_{red})$	green vegetation fraction	Gitelson et al., 2002b
	$VARI_{red\ edge} = (R_{red\ edge} - R_{red}) / (R_{red\ edge} + R_{red})$	green vegetation fraction	Gitelson et al., 2002b
Chlorophyll Indices	$CI_{green} = (R_{NIR}/R_{green}) - 1$	LAI, GPP, chlorophyll	Gitelson et al., 2003b, 2005
	$CI_{red\ edge} = (R_{NIR}/R_{red\ edge}) - 1$	LAI, GPP, chlorophyll	Gitelson et al., 2003b, 2005

† LAI, leaf area index; GPP, gross primary productivity.

Los IV más antiguos son calculados a través de los sensores con anchos de banda amplios, asociados a los sensores disponibles en los primeros satélites. En cambio mucho de los IV que se utilizan actualmente emplean anchos de banda estrechos y longitudes de onda que están fuertemente relacionados con las características de reflectancia del canopeo, por lo que se relacionan con mayor precisión con los parámetros del cultivo. La tendencia hacia el uso de bandas estrechas fomenta un refinamiento en la utilidad de los IV y aumenta la capacidad de explorar información detallada sobre el canopeo que se observa. Parte de esta evolución se visualiza en el uso de la banda correspondiente al borde rojo y las bandas que están más allá del espectro visible y del infrarrojo cercano, como son las regiones del SWIR (Hatfield, et al., 2008).

El contenido de pigmentos de la cubierta vegetal es lo que determina las características de reflectancia y absorción en las diferentes longitudes de onda del espectro visible. La clorofila es el principal pigmento que contienen las hojas, responsable de la absorción de la radiación en la región visible del espectro. Cuando

se incrementa el contenido de clorofila en las hojas, la absorción en la región del azul y rojo del espectro visible puede alcanzar 90% (Figura 15). En las zonas de alta absorción de la clorofila (bandas azul y roja) aún con contenidos bajos de este pigmento la fracción de radiación que es absorbida es alta, en estas regiones la profundidad de penetración de la luz en las hojas es muy baja (Kumar y Silva, 1973; Cui et al., 1991; Fukshansky et al., 1993; Merzlyak y Gitelson, 1995). La absorción de la radiación en la región del verde o borde rojo es altamente dependiente del contenido de clorofila en las hojas. Los IV que incorporan estas bandas en su cálculo tienen alta sensibilidad al contenido de clorofila y son de gran utilidad para predecir la concentración de N en las hojas (Figura 15).

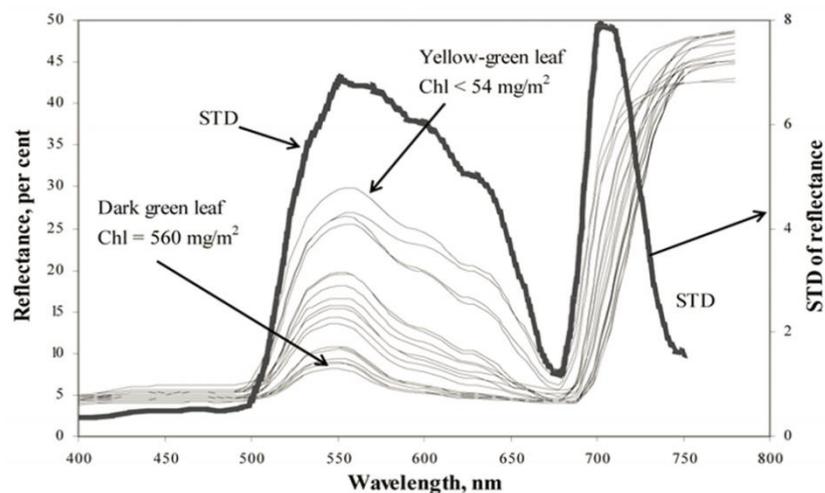


Figura 15. Reflectancia espectral de las hojas de maíz y desviación estándar de la reflectancia (Hatfield, et al., 2008).

Los cambios en el IAF generan variabilidad en la curva de reflectancia, principalmente en las regiones correspondientes a las longitudes de onda de rojo y NIR (Figura 16). El incremento del IAF se corresponde con aumentos en la absorción de la clorofila y la dispersión en el NIR, resultando en un incremento en la reflectancia medida en la zona del infrarrojo cercano y disminución en la región del rojo (Figura 16). Habitualmente los índices de vegetación se calculan a través de

operaciones que relacionan una región de longitudes de onda absorbentes con otra no absorbentes. Por lo tanto los cambios en el IAF son detectados por aquellos índices que incorporan las bandas sensibles a variaciones en dicha variable (Roberts et al., 2012).

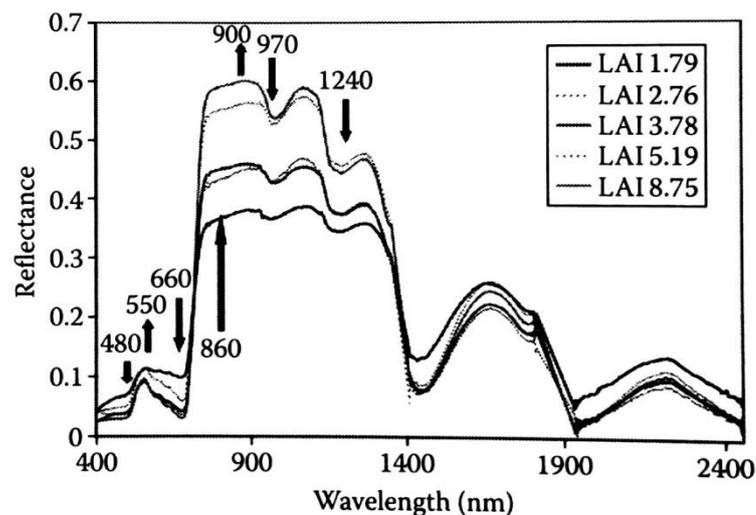


Figura 16. Reflectancia espectral de híbridos de *Populus trichocarpa* sobre un rango de IAF (LAI). Las etiquetas en las longitudes de onda refieren a las características de absorción 8480, 660, 970 y 1240 nm) o la región de dispersión en el infrarrojo cercano (860 y 900 nm). Las flechas marcan la región donde la reflectancia decrece debido a la absorción o incrementa debido a la dispersión (Roberts et al., 2012).

2.3.3. Complementariedad de los datos de sensoramiento remoto y los modelos de cultivos

Los datos de reflectancia de un cultivo han sido una herramienta utilizada para mejorar la capacidad de predecir el rendimiento en grandes áreas. Mientras los datos de SR proveen una cuantificación del estado actual de los atributos de la canopia (índice de área foliar, biomasa aérea acumulada, contenido de nitrógeno) en tiempo discreto, los modelos de crecimiento proporcionan una descripción continua del crecimiento de las plantas (Figura 17). La complementariedad de los

modelos de crecimiento de cultivos y los datos de SR para mejorar la precisión de las estimaciones de rendimiento es ampliamente conocida y ha sido desarrollada en trabajos de los 80' y 90' (Maas, 1988, Moulin et al., 1998). Mientras que los modelos proveen una interpretación de la interacción entre las plantas y el ambiente, los datos espectrales informan sobre el estado actual de los cultivos, pero no de cómo fue alcanzado el mismo. La alta variabilidad espacial en la producción de los cultivos a nivel de campo puede ser cuantificada y estudiada mediante la utilización de datos de reflectancia e índices de vegetación (Baret y Guyot, 1991; Duchemin et al., 2008; Moulin et al., 1998).

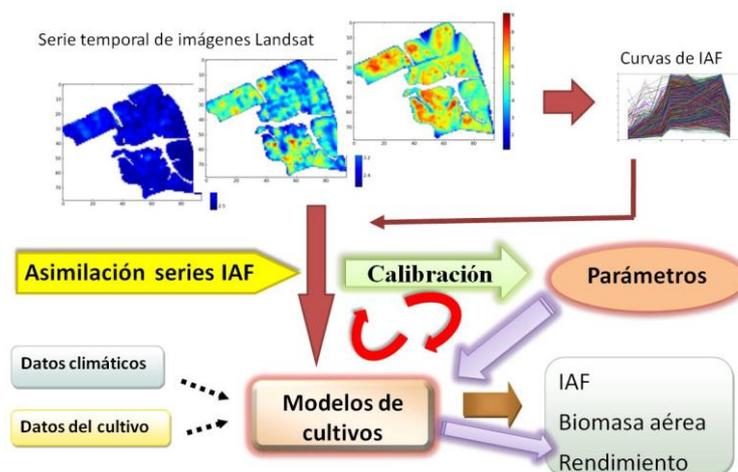


Figura 17. Esquema del proceso de asimilación de datos de SR en modelos de cultivos.

Maas (1988) describe cuatro métodos diferentes para combinar los modelos de cultivos con observaciones radiométricas (datos de satélites), los cuales fueron revisados posteriormente por Delécolle et al. (1992) y Rembold et al. (2013). La mayoría de estos enfoques fueron testeados por Mass (1989) donde utilizó un modelo simple que predice el crecimiento y desarrollo de las gramíneas: el modelo GRAMI. Los cuatro métodos descritos por Maas (1988) fueron identificados como:

(i) uso directo de una variable estimada desde datos de sensoramiento remoto

(*forcing*); (ii) actualización de las variables de estado del modelo (por ejemplo IAF) derivadas desde datos de SR (*updating*); (iii) reiniciación del modelo, por ejemplo el ajuste de las condiciones iniciales para obtener una simulación en acuerdo con las observaciones derivadas del sensoramiento remoto (*re-initialization*); (iv) recalibración del modelo, como es el ajuste de parámetros para obtener una simulación en acuerdo con el IAF derivado de las observaciones (*re-calibration*).

La primer estrategia consiste de actualizar al menos una variable del modelo (*forcing*) a través de los datos de sensoramiento remoto; donde el modelo requiere que los valores de las variables tengan una frecuencia acorde al paso de tiempo del modelo. Frecuentemente la disponibilidad de datos de SR para actualizar el modelo depende de la resolución temporal del satélite, por tanto se genera un espacio sin información satelital que deberá ser completada con procedimientos de interpolación. La estrategia de derivar las variables del modelo puede ser utilizada también para estimar las condiciones iniciales o algunos parámetros del modelo (Moulin et al., 1998).

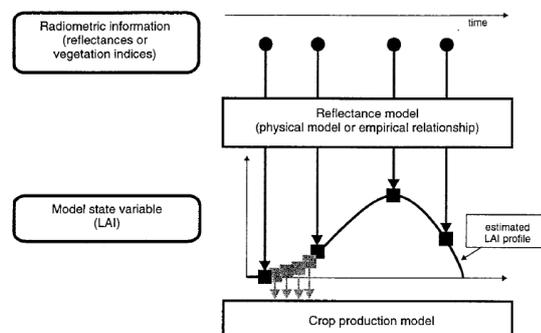


Figura 18. Representación de la estrategia de actualizar el comportamiento de una variable de estado del cultivo (*forcing*) a través de los datos de SR y su uso posterior como variable de entrada en el modelo (Delécolle et al., 1992).

La estrategia de reinicializar o reparametrizar puede dividirse en 2 modalidades: el uso de sensoramiento remoto para derivar variables del cultivo y el

uso directo de información radiométrica. La metodología consiste en reducir al mínimo las diferencias entre las variables derivadas o la señal radiométrica y las simulaciones a través de la reparametrización o reinicialización del modelo. En el primer caso, el perfil temporal de la variable debe estar en concordancia con las observaciones; por ejemplo: el IAF estimado permite restringir la serie de IAF y su valor inicial. En la estrategia de uso directo de la información radiométrica, las observaciones del satélite pueden ser reproducidas a través de acoplar un modelo de transferencia radiativa y un modelo de crecimiento de cultivos (Moulin et al., 1995). En este caso la reinicialización o reparametrización es llevada a cabo mediante la minimización de las diferencias entre las reflectancia observada y simulada con un modelo de transferencia radiativa (Figura 19). En la medida que la resolución temporal de las imágenes es limitada, se reduce el número de observaciones durante el período de crecimiento del cultivo y los parámetros que se pueden ajustar.

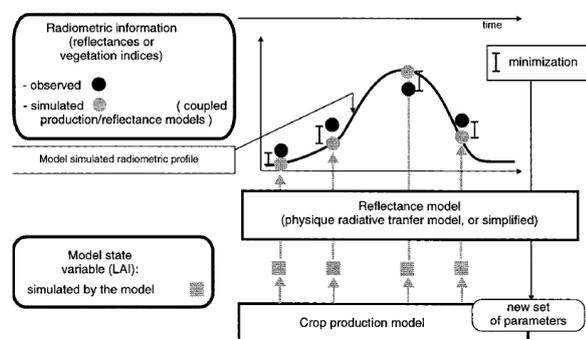


Figura 19. Representación de la estrategia de asimilación: se compara el perfil de reflectancia simulado (acoplando el modelo de crecimiento de cultivos y el de transferencia radiativa de la radiación) y la reflectancia del satélite, lo que permite que algunos parámetros del modelo o condiciones iniciales sean re-sintonizados (Moulin et al., 1998).

2.3.4. Métodos para estimar características de la canopia desde observaciones de sensoramiento remoto

Las metodologías para predecir el IAF son de gran interés, dado que el IAF es una de las variables biofísicas del canopeo que son claves en los modelos que describen procesos de intercambio de masa y energía entre el sistema suelo-planta-atmósfera. Baret y Buis (2008) realizan una descripción del estado del arte en la estimación de las características de la canopia a través de observaciones de SR. Dichos autores dividen las metodologías para estimar el IAF en 2 enfoques: (i) un enfoque que maneja variables biofísicas del canopeo; y (ii) otro enfoque que maneja datos radiométricos. En la Figura 20 se representa un esquema de los dos enfoques planteados por Baret y Buis (2008).

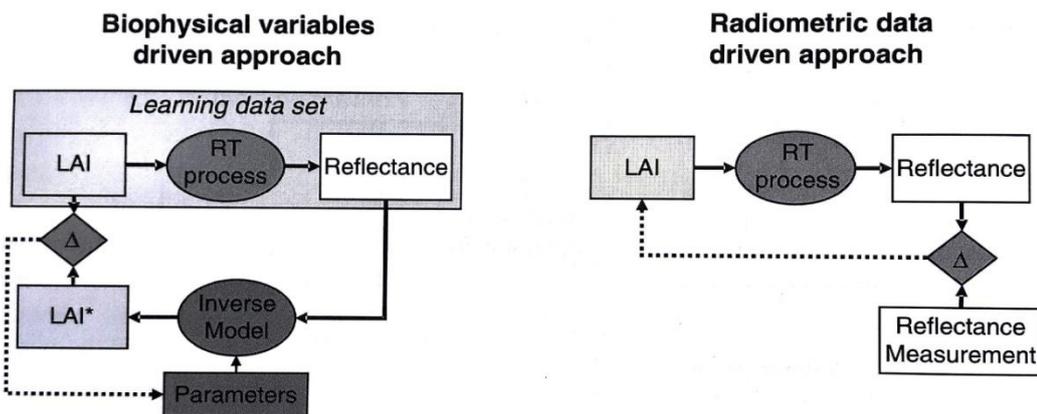


Figura 20. Principales enfoques para estimar características del canopeo como el IAF (LAI en la figura) desde datos de sensoramiento remoto. En el lado izquierdo se encuentra el enfoque centrado en las variables biofísicas que muestran la calibración a través de invertir el modelo (*Biophysical Variables Driven Approach*). En el lado derecho se encuentra el enfoque centrado en los datos radiométricos que muestran el proceso de búsqueda de una solución que lleva a los valores de IAF estimado (*Radiometric Data Driven Approach*) (Baret y Buis, 2008).

En el primer enfoque (i) se requiere, en primer término, una etapa de calibración donde se invierte el modelo contra un conjunto de datos. El conjunto de datos de las variables de interés, en este caso IAF, puede ser obtenido a través de observaciones o generado con simulaciones de un modelo de transferencia radiactiva. La utilización de los datos experimentales para la calibración es el enfoque más antiguo e históricamente utilizado. Esta metodología presenta la limitante que la relación entre el IV y la variable de interés (IAF) depende de la vegetación que se está observando. Por este motivo no es una tarea fácil utilizar esta metodología con resoluciones espaciales medias a bajas. Por otra parte, la utilización de la metodología de calibrar sobre simulaciones generadas con modelos de transferencia radiactiva evita las limitaciones asociadas a la naturaleza empírica de entrenar un conjunto de datos. Utilizando modelos de transferencia radiactiva es posible generar un rango amplio de situaciones a través de las simulaciones. Varios autores han propuesto remplazar las observaciones *in situ* por experimentos numéricos basados en los modelos de transferencia radiactiva (Baret y Guyot, 1991; Rondeaux et al., 1996; Huete et al., 1997). Los IV están intrínsecamente limitados por el empirismo de su diseño y el reducido número de bandas que utilizan para su cálculo (habitualmente de 2 a 3 bandas). Esta característica no es un problema para estimar la fracción de cobertura del suelo o la fracción de radiación fotosintéticamente activa que es interceptada, debido a que es relativamente simple. Sin embargo, la no linealidad con variables como el IAF o el contenido de clorofila y las medidas de reflectancia, provocan que la estimación de estas variables presente mayores dificultades (Weiss et al., 2000).

Baret y Buis, (2008) describen el enfoque que maneja datos radiométricos (ii), el cual se basa en encontrar el mejor ajuste entre los valores de reflectancia y sus simulaciones, con modelos de transferencia radiactiva o almacenados en bases de datos que fueron construidas con observaciones experimentales. El comportamiento de este enfoque depende de los algoritmos de minimización en sí mismos y el desempeño de invertir el problema. Existen varias técnicas de

minimización que han sido utilizadas: optimización clásica iterativa, simulaciones con un algoritmo de búsqueda meta-heurística, tablas de búsqueda (*look up tables*) o cadenas Monte Carlo Markov. Las técnicas más utilizadas han sido las tablas de búsqueda y la optimización iterativa clásica.

La técnica de optimización iterativa consiste en la actualización de los valores desconocidos de las variables biofísicas del canopeo que se utilizan como valores de entrada en los modelos de transferencia radiactiva hasta que las simulaciones de reflectancia muestren un ajuste cercano a las medidas correspondientes (Jacquemound et al., 1995). La buena calidad del ajuste entre las medidas y las simulaciones de reflectancia espectral son cuantificadas por la función de costo, que puede contabilizar explícitamente las incertidumbres por el modelo y las medidas (Baret y Buis, 2008). La función de costo puede ser teóricamente derivada de la máxima verosimilitud.

La metodología de tablas de búsqueda conceptualmente es la técnica más simple pero su implementación no es trivial (Weiss et al., 2000). En primer término se genera una larga base de datos que consiste en un conjunto de variables que son utilizadas como datos de entrada en un modelo de transferencia radiactiva. Luego se simulan los valores de reflectancia correspondientes a utilizar combinaciones de los valores de las variables de entrada generados. Una vez que se generó la tabla de búsqueda con valores de reflectancia, se encuentra la solución seleccionando los casos donde la reflectancia en la tabla de búsqueda tuvo valores muy cercanos a los valores medidos, de acuerdo a la función de costo.

3. EVALUACIÓN DE DOS METODOLOGÍAS PARA ESTIMAR EL RENDIMIENTO DE TRIGO UTILIZANDO DATOS DE SENSORAMIENTO REMOTO

3.1. RESUMEN

La predicción del rendimiento de trigo previo a la cosecha continúa siendo un desafío parcialmente resuelto. Existe gran variabilidad espacial en el rendimiento logrado en predios de productores, el cual se evidencia en los monitores de rendimiento. El objetivo de este estudio fue evaluar dos métodos (Método 1 y Método 2) para estimar el rendimiento de trigo previo a la cosecha utilizando datos de sensoramiento remoto (SR). El Método 1 utilizó una serie temporal de imágenes de Landsat 7 y 8 que fueron asimiladas en un modelo de cultivos para optimizar sus parámetros. El modelo se invirtió contra la serie de imágenes obtenidas, ajustando un valor para cada parámetro del modelo. Los valores ajustados de los parámetros fueron utilizados para correr el modelo en forma independiente. El Método 2 consistió en utilizar una relación empírica obtenida entre un índice de vegetación en el momento de antesis y el rendimiento observado. Los sitios de estudio se localizaron en la región suroeste de Uruguay, en los departamentos de Soriano y Colonia. Si bien se alcanzó mayor precisión con el Método 2 respecto al el Método 1, cuando se evaluaron los desvíos entre el rendimiento observado y el simulado a escala de pixel, (RMSE de 966 kg.ha⁻¹ vs 1532 kg.ha⁻¹ para el Método 2 y 1 respectivamente), el Método 1 permitió diferenciar la variabilidad espacial en el rendimiento estimado, la cual fue concordante a lo esperado según el rendimiento

observado con los monitores. En futuros estudios será necesario disponer de mayor resolución temporal, así como también generar mayor experiencia en la utilización de metodologías de corrección atmosférica para lograr mayor precisión y poder describir mejor la variabilidad espacial observada.

Palabras claves: Landsat, modelos de cultivos, IAF, índice de vegetación

3.2. INTRODUCCIÓN

Durante las últimas cuatro décadas la estimación del rendimiento previo a la cosecha ha sido un problema abordado mediante la combinación de datos de sensoramiento remoto (SR) y modelos de cultivos (Mass et al., 1988; Moulin et al., 1998; Casa et al., 2012). Los modelos de cultivos son una herramienta adecuada para predecir el rendimiento durante la temporada de crecimiento del cultivo (Delécolle et al., 1992). La aplicación de modelos de cultivos en grandes áreas se ha visto obstaculizada por la falta de información suficiente y precisa sobre los parámetros y entradas de los mismos. El principal problema para alcanzar una precisión adecuada con el modelo de cultivo es la dificultad de conocer los valores de las condiciones iniciales y los parámetros (Moulin et al., 1998). Por esta razón, desde sus comienzos, los modelos de crecimiento de cultivos fueron desarrollados para simular el crecimiento y rendimiento de áreas agrícolas donde el suelo, el clima y las prácticas de manejo eran bien conocidos (Mass et al., 1988).

En las áreas agrícolas de Uruguay, las propiedades del suelo son muy heterogéneas en el espacio y como resultado las condiciones de crecimiento para el cultivo son altamente variables. Para utilizar los modelos de simulación de cultivos en grandes áreas es necesario conocer las condiciones iniciales y los valores de los parámetros en cada zona de crecimiento homogéneo. Por lo tanto, la aplicación de los modelos de cultivo para predecir el crecimiento y rendimiento a escala predial continúa siendo un desafío parcialmente resuelto. Los datos de reflectancia del cultivo obtenidos mediante SR han sido una herramienta utilizada para mejorar la capacidad de predecir el rendimiento en grandes áreas. Mientras que el SR provee una cuantificación del estado actual de los atributos de la canopia (índice de área foliar, biomasa aérea acumulada, contenido de nitrógeno) en tiempo discreto, los modelos de crecimiento proporcionan una descripción continua del crecimiento de las plantas (Hatfield, 1983; Maas, 1988; Delécolle et al., 1992; Hatfield et al., 2008).

La complementariedad de los modelos de crecimiento de cultivos y los datos de SR para mejorar la precisión de las estimaciones de rendimiento es ampliamente conocida y ha sido desarrollada en diferentes trabajos (Maas, 1988; Moulin et al., 1998). La variabilidad espacial en la producción de los cultivos en pequeñas áreas puede ser cuantificada y estudiada mediante la utilización de datos de reflectancia e índices de vegetación (Moulin et al., 1998; Baret y Guyot, 1991; Launay y Guerif, 2005; Duchemin et al., 2008). Si bien en la literatura existe una lista extensa de trabajos que estiman el rendimiento de trigo a escala regional con suficiente precisión ($RMSE < 500 \text{ kg ha}^{-1}$), continúa siendo desafiante alcanzar una alta

precisión en la estimación de la variabilidad espacial a escala predial utilizando datos con alta resolución espacial continúa.

Los modelos de cultivos pueden ser clasificados por su grado de complejidad. Moulin et al. (1998) clasifican los modelos de cultivos en tres categorías: (i) Modelos empíricos, basados en una regresión lineal simple entre el rendimiento y un índice de vegetación (IV); (ii) Modelos semi-empíricos, que usualmente utiliza la teoría de Monteith (1977), donde la biomasa área total acumulada diariamente es una función de la radiación global incidente y; (iii) Modelos mecanísticos, aquellos que simulan los procesos que explican la evolución en el tiempo de las principales variables de estado del cultivo. En este trabajo se emplearon los dos primeros enfoques para estimar el rendimiento de trigo.

El objetivo de este trabajo fue evaluar dos metodologías para estimar el rendimiento de trigo utilizando imágenes del satélite Landsat, en 22 predios agrícolas localizados en los departamentos de Soriano y Colonia. Los métodos evaluados fueron: (i) un enfoque semi empírico, donde los datos provenientes de las imágenes Landsat son asimilados en un modelo de cultivos para calibrar los parámetros y estimar el rendimiento previo a la cosecha (Método 1) ; y (ii) un enfoque empírico, donde se utiliza la relación entre el IV en antesis y el rendimiento observado (Método 2).

3.3. MATERIALES Y MÉTODOS

3.3.1. Localización de los sitios de estudio y determinaciones en el cultivo

Los sitios de estudio se localizaron en los departamentos de Colonia y Soriano, en la región sur y oeste de Uruguay. Se seleccionaron 22 predios de productores agrícolas que fueron sembrados con trigo (*Triticum aestivum*) durante los años 2013 y 2014. Todos los sitios fueron manejados en un sistema de agricultura continua, con una rotación de cultivos que utilizó cultivo de invierno (trigo o cebada) y cultivo de verano (soja o maíz). El rango de siembra fue desde el 15 de mayo al 15 de julio en ambos años de estudio. El rendimiento en todos los sitios se midió con monitores montados en la maquinaria de cosecha. Se analizó los datos de los monitores de rendimiento de diferentes proveedores y maquinaria de cosecha. Se obtuvo el valor de rendimiento observado para cada pixel correspondiente a la grilla Landsat a través de realizar el promedio de los puntos de rendimiento dentro de cada pixel. De esta forma se logró un mapa de rendimiento con pixeles equivalentes al mapa que se simuló con las imágenes Landsat. Durante el año 2013 en un sitio localizado en la zona oeste (latitud: 33°34'44S; longitud: 58°10'06O) y uno en la zona sur (latitud: 34°23'31S; longitud: 57°38'01O) se seleccionaron 13 puntos de muestreo en zonas de diferente potencial productivo dentro de la chacra, para representar la variabilidad espacial del sitio. Las zonas se identificaron en función del conocimiento previo de las características del suelo, rendimientos logrados en años anteriores e índices de vegetación máximos en la estación de

crecimiento del cultivo. Cada punto de muestreo se visitó aproximadamente en la misma fecha que estuvo disponible la imagen. Se realizó un muestreo compuesto donde se midió la biomasa aérea y el índice de área foliar (LAI) con un ceptometro (AccuPAR, Decagon Devices), 5 veces entre la emergencia y la madurez fisiológica del cultivo, en tres puntos localizados a diez metros de distancia del punto central.

3.3.2. Datos satelitales y correcciones atmosféricas de las imágenes

Se utilizaron las imágenes de los satelites Landsat 7 Enhanced Thematic Mapper Plus (ETM+) y Landsat 8 Operational Land Imager (OLI). Se descargaron de los archivos USGS EROS todas las imágenes libres de nubes durante la estación de crecimiento del cultivo y las zonas SLC-off de las imágenes Landsat 7 se interpolaron con la extensión gap-fill implementada para ENVI 5.0. Se realizaron correcciones radiométricas y atmosféricas siguiendo el procedimiento implementado en el software ATCOR 2. Luego de realizadas las correcciones atmosféricas se extrajeron los valores de reflectancia de las bandas del NIR, rojo y verde (canales 4,3,2 para el Landsat 7 y canales 5,4,3 para Landsat 8) para calcular los índices de vegetación. Los 22 sitios seleccionados totalizaron 31420 pixeles donde se testearon las dos metodologías (Método 1 y Método 2).

3.3.3. Predicción del rendimiento del cultivo: metodologías utilizadas

Se evaluaron dos metodologías para estimar el rendimiento de trigo. La primera metodología (Método 1) consistió en la asimilación de una serie de imágenes en un modelo de cultivos. El modelo de cultivos se describe detalladamente en las siguientes secciones. En la primer etapa, se calibraron los parámetros seleccionados a través de invertir el modelo contra la serie de imágenes entre el período de emergencia a floración. El proceso de inversión consistió en ajustar los parámetros seleccionados del modelo contra las series de IV de las imágenes, mediante la utilización del algoritmo de optimización de Levenberg-Marquardt (python-numpy). Se ajustaron dos parámetros: contenido específico de nitrógeno y biomasa en la emergencia. En la segunda etapa, el modelo corre en forma independiente para cada uno de los pixeles, utilizando los valores de los parámetros ajustados anteriormente.

En la segunda metodología (Método 2) se estimó el rendimiento utilizando la relación resultante entre el rendimiento observado con los monitores y el IV entorno a antesis extraído desde las imágenes Landsat. En este método se utilizó una única imagen cercana al momento de floración. En el Método 2 se utilizó el procedimiento de validación cruzada para estimar el rendimiento. Se tomaron al azar el 50% de los puntos para entrenamiento del modelo y con el 50% restante se validó el modelo, repitiendo la metodología 1000 veces.

3.3.4. Índices de vegetación para predecir IAF

Se eligieron tres índices de vegetación (NDVI, WDRVI y CI) para predecir el IAF. Los índices fueron calculados para cada imagen de acuerdo con la ecuación 1, 2 y 3. Los valores de los índices en cada punto de muestreo y en cada una de las fechas fueron correlacionados con las medidas de IAF registradas en los mismos puntos.

$$\text{NDVI} = (\rho_{\text{NIR}} + \rho_{\text{ROJO}}) / (\rho_{\text{NIR}} - \rho_{\text{ROJO}}) \quad (1)$$

$$\text{WDRVI} = \alpha \rho_{\text{NIR}} - \rho_{\text{ROJO}} / \alpha \rho_{\text{NIR}} + \rho_{\text{ROJO}} \quad (2)$$

$$\text{CI} = (\alpha \rho_{\text{NIR}} / \rho_{\text{VERDE}}) - 1 \quad (3)$$

dónde ρ_{NIR} , ρ_{ROJO} y ρ_{VERDE} es la reflectancia en la banda del NIR, rojo y verde respectivamente; y el valor α es un parámetro fijado en 0.2 en base a Gitelson (2008).

Para ajustar la relación entre el IV y el IAF observado se utilizaron los valores de cada uno de los índices durante el crecimiento vegetativo del cultivo y los valores de IAF observados en los puntos de muestreo. La relación resultante entre el IV y el IAF observado se empleó en cada uno de los píxeles para predecir la evolución del IAF.

3.3.5. Descripción del modelo de cultivos.

Se utilizó un modelo simple de cultivos de paso diario, basado en el modelo SAFY (Duchemin et al., 2008), el cual fue totalmente modificado. Los datos de entrada que requiere el modelo son únicamente la radiación global, la fecha de emergencia y la floración del cultivo.. El modelo fue basado en la evolución diaria de la biomasa aérea usando la teoría de Monteith (1977). El total de biomasa

acumulada diariamente es el producto de la integración de la radiación incidente y tres factores de eficiencia. Los factores de eficiencia son: la proporción de radiación fotosintéticamente activa del total de radiación (PAR), lo cual es el ratio entre la radiación fotosintéticamente activa y la radiación total; la eficiencia de intercepción de la luz (fPAR), la cual es la proporción de la radiación fotosintéticamente activa que es absorbida; y la eficiencia de uso de la luz (EUL), la cual es el ratio entre la biomasa producida y la radiación fotosintéticamente activa absorbida. La biomasa total acumulada es calculada a través de la siguiente ecuación:

$$BT = Rg * \epsilon_c * \epsilon_i * EUL \quad (4)$$

dónde BT es la biomasa total acumulada, Rg es la radiación incidente, ϵ_c es la proporción de radiación fotosintéticamente activa del total de radiación, ϵ_i es la proporción de luz interceptada del total de radiación fotosintéticamente activa y EUL es la eficiencia de uso de la luz.

La EUL está fuertemente asociada con el contenido de nitrógeno en las hojas. La evolución de EUL durante la estación de crecimiento es una función del nitrógeno acumulado en las hojas. La EUL se calculó utilizando la ecuación propuesta por Sinclair y Amir (1992) que relaciona el contenido de nitrógeno en las hojas y la EUL:

$$EUL = 1.5 * (1 - \exp(-1.7 * N_h^{-3})) \quad (5)$$

dónde N_h es el contenido de nitrógeno en las hojas.

El modelo produce biomasa a través de integrar la radiación fotosintéticamente activa absorbida con los factores de eficiencia. El IAF acumulado es una función de la biomasa total, para computar el IAF diario se ajustó una función con datos locales del cultivo:

$$IAF = ((BT (i) / BT (i-1)) \exp lallomb) * IAF (i-1) \quad (6)$$

dónde BT (i) and BT (i-1) es la biomasa aérea el día i y i-1 respectivamente, IAF (i-1) es el índice de área foliar el día i-1 y lallomb es un parámetro asociado con la partición entre hojas y tallos. El parámetro lallomb se ajustó con datos locales de campo, el valor de ajuste fue 0.8747.

La cantidad de nitrógeno disponible que fue translocado a los granos se calculó en el modelo de cultivos en función de las ecuaciones descritas por Sinclair y Amir (1992), como el total de nitrógeno acumulado en las hojas y tallos al final del período vegetativo menos el nitrógeno estructural que no estaba disponible para ser translocado. De esta forma el nitrógeno que se acumula en la planta y la tasa de translocación del mismo gobierna el largo del llenado de granos.

La biomasa producida diariamente es direccionada a destinos vegetativos o reproductivos dependiendo de las fases fenológicas. Por esta razón, para correr el modelo fue necesario conocer el inicio y finalización de la etapa vegetativa y reproductiva (emergencia, floración y madurez fisiológica). El modelo no contaba con una rutina que simule las etapas fenológicas, por lo tanto estas fueron suministradas. El rendimiento final fue computado como la integración de la

biomasa total producida en la etapa vegetativa multiplicado por un índice de cosecha. Para el cálculo del índice de cosecha se tomó la relación reportada por Kemanian et al. (2007). La ecuación que se utilizó para calcular el rendimiento fue:

$$\text{Rend} = \text{BT} * \text{IC} \quad (7)$$

$$\text{IC} = \text{IC_ini} + 0.21 * \text{fr} \quad (8)$$

dónde Rend es el rendimiento final, BT es la biomasa total, IC es el índice de cosecha, IC_ini es el índice de cosecha inicial que toma el valor de 0.34 según Kemanian et al. (2007) y fr es la fracción de acumulación de biomasa en el grano del total de biomasa acumulado.

3.3.6. Evaluación del desempeño de los dos métodos (I y II)

La precisión de los dos Métodos (I y II) testeados fue evaluada a través de los siguientes estadísticos:

$$D_i = Y_i - Y \quad (9)$$

$$\text{Bias} = \sum D_i / N \quad (10)$$

$$\text{RMSE} = \sqrt{\sum (Y_i - Y)^2 / N} \quad (11)$$

dónde N es el número total de situaciones, Y_i es el rendimiento observado en el punto i , Y corresponde al valor estimado por el modelo en el punto i .

3.4. RESULTADOS Y DISCUSIÓN

3.4.1. Correlación entre el área foliar observada y los índices de vegetación provenientes de las imágenes Landsat

Se contrastaron los puntos observados de IAF durante el ciclo del cultivo (de dos sitios durante el año 2013) contra los valores de los tres IV's (NDVI, WDRVI y CI) obtenidos de la serie de imágenes Landsat (Figura 1). La relación resultante entre el IAF y cada uno de los índices calculados se presenta en la Figura 1. El NDVI muestra una alta saturación a partir de valores muy bajos de IAF; debido a este comportamiento la utilidad de dicho índice para predecir el IAF es muy limitada (Figura 1). En cambio los índices WDRVI y CI tuvieron una menor saturación una relación de respuesta al incremento del IAF. La transformación del NDVI para obtener el WDRVI permitió atenuar satisfactoriamente la saturación que se observó en el NDVI. En el caso del CI, la utilización de zonas del espectro con alta sensibilidad a variaciones en características del canopy (banda de la región verde) permite obtener una relación de respuesta del IAF a variaciones en el IV.

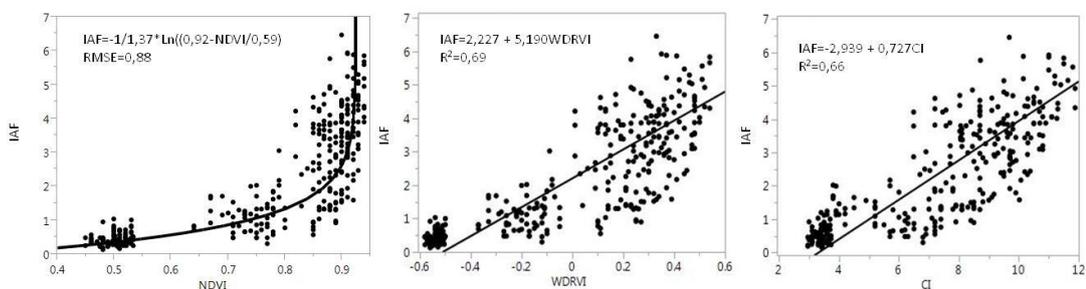


Figura 1. Relación observada entre IAF y tres índices de vegetación durante el período vegetativo, en el año 2013 en el sitio localizado en el departamento de Soriano.

No obstante las limitaciones que presenta el NDVI como predictor del IAF es uno de los índices más utilizados. Algunos estudios demuestran que el NDVI es un mejor estimador de la luz interceptada que del IAF, debido a la saturación que se observa durante la estación de crecimiento (Wiegand et al., 1992; Gitelson, 2012). La relación entre el NDVI y IAF es esencialmente no lineal y cambia significativamente entre distintas cubiertas vegetales (Haboudane et al., 2004, Nguy-Robertson et al., 2012). Generalmente cuando el IAF excede el valor de dos, el NDVI es insensible a incrementos en el IAF en canopias forestales, pasturas, cultivos de cereales y de hojas anchas (Gitelson, 2012). La relación observada en este trabajo, entre el NDVI y el IAF fue concordante con lo esperado, lo que demuestra que el NDVI es útil únicamente en las primeras etapas de la estación de crecimiento. Cuando el IV utiliza la banda correspondiente al verde, como es el caso del índice CI, la sensibilidad frente a cambios en el IAF es alta.

El comportamiento del índice CI se debe a la absorción de la clorofila en la región verde, la cual es una región del espectro visible con alta variabilidad frente a cambios en el IAF (Hatfield et al., 2008). La reflectancia en la región del borde rojo presenta gran sensibilidad frente a un rango muy amplio de verdor de las hojas, debido a la absorción de la clorofila en dicha región del espectro (Haboudane et al., 2004; Hatfield et al. 2008). Por otra parte, los IV que incorporan la banda del borde rojo son de gran utilidad para predecir características del canopeo, pero en general esta banda no se encuentra disponible en los satélites de libre acceso (Nguy-Robertson et al., 2012).

3.4.2. Estimación del rendimiento utilizando el Método 1

La implementación de la metodología de inversión del modelo de cultivo contra la serie de IAF para calibrar los parámetros seleccionados pixel a pixel derivó en dos mapas que reflejaron la variabilidad espacial de dichos parámetros (Figura 2). Los parámetros seleccionados fueron: el contenido específico de nitrógeno en hoja y la biomasa a la emergencia del cultivo. Los valores de ajuste de los parámetros estuvieron relacionados a la distribución espacial de las curvas de IAF, de esta forma cada uno de los pixeles utilizó un valor diferente e independiente para la EUL. El rendimiento final del cultivo se determinó por el ajuste de los parámetros en cada pixel, el cual se asoció a la dispersión de las curvas de IAF.

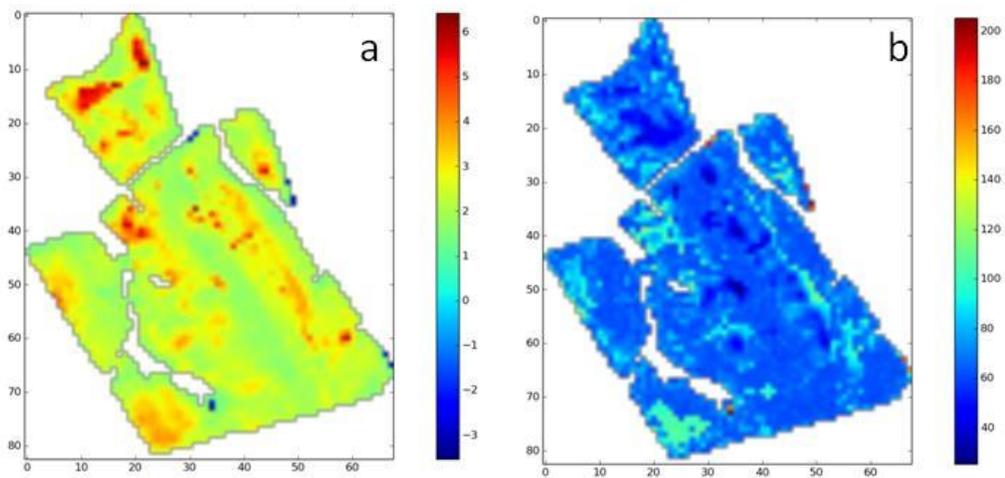


Figura 2. Distribución espacial del parámetro contenido específico de nitrógeno en g.m^{-2} (a) y la biomasa en la emergencia en g.m^{-2} (b) en uno de los predios de estudio (Cina_Cina).

La EUL potencial para cada cultivo es ampliamente conocida, en el caso de trigo los

valores de EUL máximos son de $2,2 \text{ g.Mj}^{-1}$ (Sinclair y Muchow, 1999). Sin embargo la EUL que logra realmente un cultivo tiene gran variabilidad dependiendo de las condiciones ambientales y el estado nutricional que enfrenta el mismo (Soltani y Sanclair, 2012a). Varios de los factores que afectan la tasa de fotosíntesis pueden reducir la EUL potencial, los cuales incluyen la temperatura, la concentración atmosférica de anhídrido carbónico, la deficiencia de agua y la concentración de nitrógeno en las hojas (Soltani y Sanclair, 2012a). Por este motivo en grandes extensiones de cultivo la EUL se distribuye espacialmente en función de los factores más limitantes en cada zona. El principal factor limitante en la producción de trigo en Uruguay es la disponibilidad de nitrógeno para el cultivo (Berger et al., 2014). La variabilidad espacial en la disponibilidad de nitrógeno en cada chacra fue estimada a través de utilizar la metodología de inversión de las curvas de crecimiento. El proceso de inversión de las curvas de crecimiento obtenidas a partir de las imágenes consistió en el ajuste de un valor para el contenido de nitrógeno de cada uno de los pixel a pixel en forma independiente. De esta forma se cuantifica y sintetiza la variabilidad espacial de los diferentes factores limitantes a través del contenido de nitrógeno que se ajustó en cada pixel. Al implementar la metodología de ajuste de parámetros contra una serie de IAF, se contempla en forma indirecta la variabilidad en los factores que determinan el crecimiento durante el período vegetativo (Moulin et al., 1998).

La combinación de los valores de ajuste de los parámetros determina el rendimiento simulado por el modelo. En las zonas de bajo crecimiento del cultivo

durante el período vegetativo, el Método 1 subestimó el rendimiento simulado, mientras que en las zonas de alto crecimiento se sobreestimó (Figura 3). El rendimiento estimado cuando se utilizó el Método 1 tuvo alta dispersión respecto a la línea 1:1, esto fue debido a que el modelo representó mayor variabilidad en el rendimiento estimado que la observada en el monitor de rendimiento (Figura 3). Los desvíos entre el rendimiento simulado y observado se deben principalmente a las zonas donde el modelo sobreestimó. Las zonas de mayor concentración de puntos son en la región de altos rendimientos simulados (Figura 3). Si bien la concentración de puntos en la zona de sobreestimación del rendimiento se reflejó en ambos años en que se testeó el Método 1, en el años 2014 este hecho fue más acentuado debió a la incidencia del *Fusarium graminearum* durante el llenado de grano en el año 2014. El efecto de agentes bióticos reductores del rendimiento no son contemplados en el modelo, por lo tanto cuando ocurrieron éstos factores el modelo sobreestimó el rendimiento.

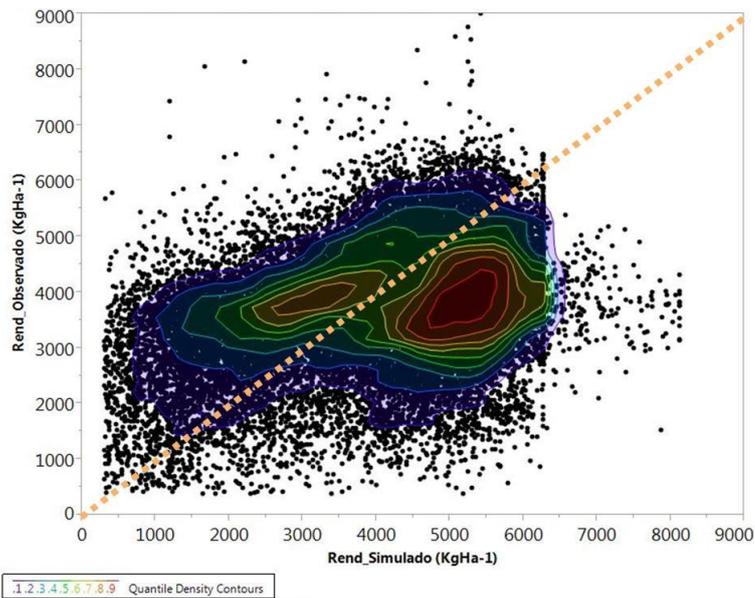


Figura 3. Relación entre el rendimiento observado y estimado con el Método 1 en el total de predios utilizados. Los contornos de diferentes colores representan zonas de concentración de puntos.

La precisión lograda con el Método 1 fue comparable a la reportada cuando se utilizan metodologías similares para estimar el rendimiento con alta resolución espacial, a escala de chacra. El RMSE obtenido cuando se utilizó el Método 1 fue de $1532 \text{ kg}\cdot\text{ha}^{-1}$ ($r\text{RMSE} = 36\%$) y el Bías de $-401 \text{ kg}\cdot\text{ha}^{-1}$; mientras Silbey et al. (2014) obtuvieron RMSE relativos de 20 a 35% cuando estimaron el rendimiento de maíz en condiciones de riego y seco con la resolución espacial de las imágenes Landsat. Por otra parte, Bastiaanssen y Ali (2003) logran $r\text{RMSE}$ menores a 25% utilizando baja resolución espacial (píxeles de $1,1 \text{ km}^2$) en diferentes cultivos de la secuencia agrícola. Pero existe una serie de trabajos reportados donde utilizan baja resolución espectral y alcanzan $r\text{RMSE}$ en la estimación de rendimiento menores al 10% (Doraiswamy et al., 2005; Becker-Reshef et al., 2010; Franch et al., 2015).

Las diferencias entre los niveles de precisión reportados en trabajos anteriores y los que se lograron en este estudio posiblemente se corresponde en parte a las diferencias en las resoluciones espaciales utilizadas y a las características de los datos de rendimiento observado. Cuando se utilizan imágenes de baja resolución espacial (MODIS, AVHRR) se reduce la variabilidad de las series de IAF y en consecuencia también se reduce la dispersión en el rendimiento estimado. De la misma forma también se reduce la variabilidad espacial en los rendimientos observados cuando se utiliza información de rendimiento proveniente de estadísticas a nivel país, en lugar de datos de monitores de rendimiento con una resolución espacial muy alta. Como resultado se alcanza alta precisión en la estimación del rendimiento producto de reducir la variabilidad espacial a través de la resolución utilizada.

La distribución de los rendimientos observados con el monitor e interpolados a la grilla equivalente al Landsat tuvo una distribución muy concentrada sobre el valor medio de rendimiento del sitio. En contraposición a lo observado en monitores provistos por productores, Dumont et al. (2015) demuestra que la distribución del rendimiento es asimétrica hacia valores altos de rendimiento (valor de asimetría de -1,02 y de curtosis cerca de 3,85) cuando el ambiente es de alto rendimientos, como es el ejemplo de alta disponibilidad de nitrógeno. En cambio en los casos de situaciones de bajos promedios de rendimiento la distribución es normal (Dumont et al., 2015). La distribución del rendimiento observado (distribución normal en la mayor parte de los sitios)

probablemente sea atribuible a la forma de medición de los sensores montados sobre la maquinaria de cosecha. El sensor de medición tiene un retraso de 40 m aproximadamente en la medida del rendimiento. Cuando la interpolación de los puntos de rendimiento es sobre una grilla de alta resolución como la de Landsat (30 x 30 m), probablemente existen pequeñas zonas de potencial menor o mayor que las zonas aledañas que no son correctamente identificadas. Éstas zonas contribuyen a incrementar los desvíos entre el rendimiento observado y simulado cuando se evalúa la precisión del modelo pixel a pixel.

El comportamiento del Método 1 fue variable a través de las situaciones testeadas (Figura 4). Mientras en algunos sitios, como el representado en la Figura 4 (g), mostró un desempeño aceptable, con una dispersión tolerable de los puntos respecto a la línea 1:1; en otros campos como los representados en las Figuras 4 (a, h, ñ) los rendimientos simulados tuvieron un comportamiento totalmente diferente al observado. Los campos de menor área fueron los que tuvieron los valores más altos de RMSE, lo cual se asoció al bajo número de píxeles que dejó en mayor evidencia la descoordinación de escalas (retraso en la medida del monitor e interpolación a la grilla del Landsat). Como resultado en la imagen se detectan áreas muy pequeñas de dos a tres píxeles, con crecimiento del cultivo totalmente diferente al de las áreas aledañas, pero que el monitor de rendimiento no fue capaz de identificar como píxeles de rendimiento diferente.

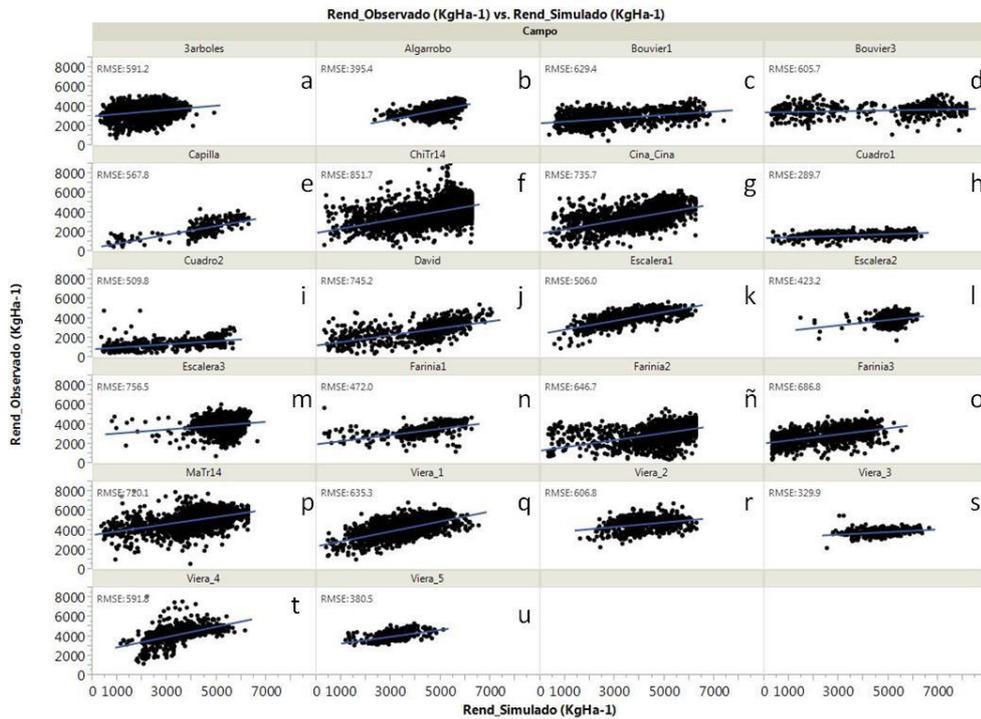


Figura 4. Relación entre el rendimiento observado y simulado con el Método 1 para cada uno de los predios utilizados.

3.4.3. Estimación del rendimiento utilizando el Método 2

El rendimiento simulado con los índices NDVI y CI en antesis mostró un rango de variación más estrecho que el rendimiento observado. El rango de rendimiento simulado fue de 2500 a 5200 kg ha⁻¹ tanto cuando se utilizó el índice NDVI como el CI (Figura 5). La baja variabilidad en el rendimiento estimado fue determinada por la curva promedio de regresión. La precisión del Método 2 fue similar cuando se utilizó el índice CI y el NDVI (RMSE de 826 y 966 kg.ha⁻¹ para el CI y NDVI respectivamente).

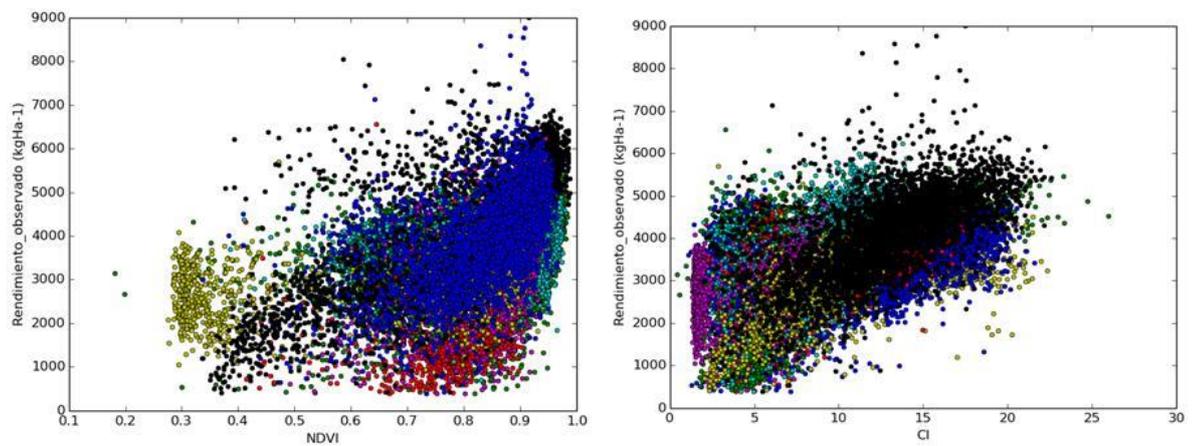


Figura 5. Relación entre dos índices de vegetación entorno antesis (NDVI y CI) y el rendimiento observado ($\text{kg}\cdot\text{ha}^{-1}$). Cada punto corresponden a un pixel de la imagen y los colores representan cada uno de los campos utilizados.

A pesar de las claras diferencias en las correlaciones de los IV en antesis y el rendimiento (Figura 5), la precisión del Método 2 para predecir el rendimiento fue independiente del índice utilizado (Figura 6). La relación resultante entre el NDVI en antesis y el rendimiento fue concordante con la relación observada entre el NDVI y el IAF durante el ciclo del cultivo. La relación obtenida entre el NDVI y el rendimiento se debe a que en antesis la mayor parte de los puntos superaron el valor de saturación del NDVI.

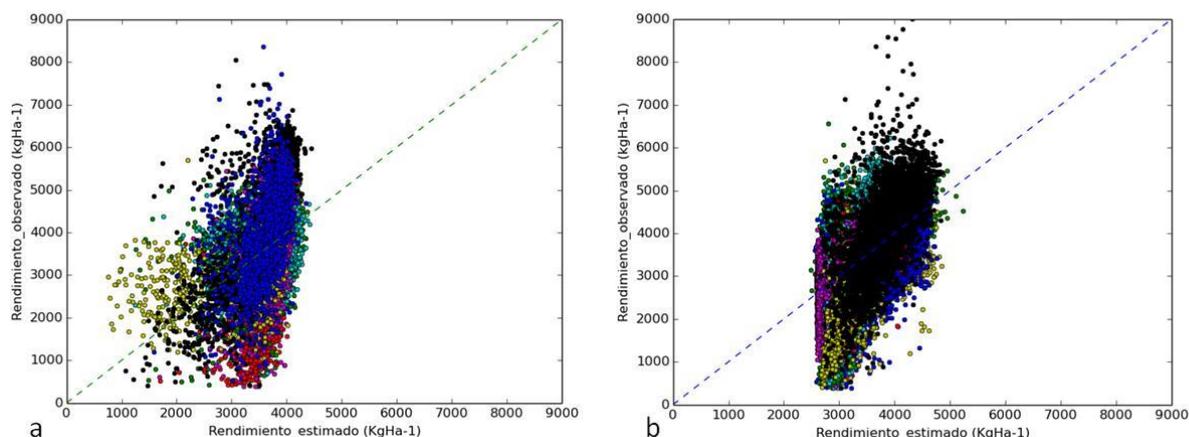


Figura 6. Relación entre el rendimiento observado y estimado con el Método 2 utilizando el índice NDVI (a) y CI

Silbey et al (2014) lograron precisiones similares cuando utilizaron la misma metodología para estimar el rendimiento de maíz con imágenes Landsat. Si bien la simpleza en la implementación del Método 1 es una ventaja de la metodología, no mostró un comportamiento favorable para representar la variabilidad esperable en el rendimiento observado. El uso de una metodología como es el Método 2 no permitió considerar factores de estrés como son el agua y el nitrógeno. El impacto del estrés por agua y nitrógeno se ajusta con las observaciones de IAF a través del parámetro eficiencia de uso de la luz, por lo tanto la dinámica de evolución de las hojas verdes (IAF) representa de buena forma las tensiones ambientales en el cultivo (Duchemin et al., 2008). Dado que en el Método 2 no son considerados los factores de estrés durante el crecimiento vegetativo del cultivo a través de las curvas de IAF, la distribución del rendimiento simulado por este Método presentó reducida variabilidad.

3.5. CONCLUSIONES

No se evidenció mayor precisión por la utilización de un modelo de cultivos en forma conjunta con datos de SR respecto a un método más simple que utilizó únicamente una imagen en el ciclo del cultivo (RMSE de 1532 y 826 kg.ha⁻¹ para el Método 1 y 2 respectivamente). Sin embargo la implementación del Método 1 permitió representar variabilidad espacial en los rendimientos estimados que estuvo en concordancia con lo esperable.

Los altos valores de RMSE posiblemente sean el resultado de múltiples factores de error, entre los cuales se pueden señalar: (i) la resolución espacial utilizada (se contrastaron rendimientos simulados y observados de pixeles de 30m); (ii) la baja resolución temporal de las imágenes Landsat; (iii) errores en las rutinas de corrección atmosférica; (iv) errores de medición en los monitores de rendimiento; y (v) estreses en llenado de grano que no fueron contemplados.

Ambas metodologías tienen limitada utilidad para estimar el rendimiento a escala de predio agrícola. Es necesario disponer de mayor resolución temporal de las imágenes para alcanzar niveles de precisión aceptables en la estimación del rendimiento a nivel predial y de su variabilidad espacial. De esta manera la metodología tendrá mayor alcance para pronosticar los volúmenes de cosecha, así como también para ser utilizada como insumo cuando se separan ambientes de diferente potencial de rendimiento.

3.6. REFERENCIAS

- Baret F, Guyot G. 1991. Potentials and limits of vegetation indices for LAI and APAR assessment. *Remote Sensing of Environment*, 35: 161 – 173.
- Bastiaanssen WGM, Ali S. 2003. A new crop yield forecasting model based on satellite measurements applied across the Indus Basin, Pakistan. *Agriculture, Ecosystems y Environment*, 94: 321 – 340.
- Becker-Reshef I, Vermote E, Lindeman M, Justice C. 2010. A generalized regression-based model for forecasting winter wheat yields in Kansas and Ukraine using MODIS data. *Remote Sensing of Environment*, 114(6): 1312 – 1323.
- Berger AG, Gaso D, Calistro R, Morales MX. 2015. Limitantes Ambientales y Potencial de Rendimiento de Trigo en Uruguay. En: Seminario internacional 1914-2014, un siglo de mejoramiento de trigo en La Estanzuela. Complete papers book. Colonia. INIA. 50 – 63.
- Casa R, Varella H, Buis S, Guérif M, De Solan B, 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): 1 – 10.
- Delécolle R, Maas SJ, Gurrit M, Baret F, 1992. Remote sensing and crop production models : present trends. *ISPRS Journal of Photogrammetry and Remote Sensing*, 47: 145 – 161.
- Doraiswamy PC, Sinclair TR, Hollinger S, Akhmedov B, Stern A, Prueger J. 2005. Application of MODIS derived parameters for regional crop yield assessment. *Remote Sensing of Environment*, 97(2): 192 – 202.
- Duchemin B, Maisongrande P, Boulet G, Benhadj I. 2008. A simple algorithm for yield estimates: Evaluation for semi-arid irrigated winter wheat monitored with green leaf area index. *Environmental Model and Software*, 23(7): 876 – 892.

- Dumont B, Basso B, Leemans V, Bodson B, Destain JP, Destain MF. 2015. Yield variability linked to climate uncertainty and nitrogen fertilisation. *Precision Agriculture*, 16(4): 361 - 384.
- Franch B, Vermote EF, Becker-Reshef I, Claverie M, Huang J, Zhang J, Justice C, Sobrino JA. 2015. Improving the timeliness of winter wheat production forecast in the United States of America, Ukraine and China using MODIS data and NCAR Growing Degree Day information. *Remote Sensing of Environment*, 161: 131 – 148.
- Gitelson AA. 2004. Wide Dynamic Range Vegetation Index for remote quantification of biophysical characteristics of vegetation. *J. Journal of Plant Physiology*, 161(2): 165 – 73.
- Gitelson AA, Peng Y, Masek JG, Rundquist DC, Verma S, Suyker A, Baker JM, Hatfield JL, Meyers T. 2012. Remote estimation of crop gross primary production with Landsat data. *Remote Sensing of Environment*, 121: 404 – 414.
- Gitelson AA. 2012. Remote Sensing Estimation of Crop Biophysical Characteristic at Various Scales. En: Thenkabail PS, Lyon JG, Huete A. (Eds.). *Hyperspectral Remote Sensing of Vegetation*. New York: Taylor y Francis. 329 - 358.
- Haboudane D, Miller JR, Pattey E, Zarco-Tejada PJ, Strachan IB. 2004. Hyperspectral vegetation indices and novel algorithms for predicting green LAI of crop canopies: Modeling and validation in the context of precision agriculture. *Remote Sensing of Environment*, 90(3): 337 – 352.
- Hatfield JL. 1983. Remote sensing estimators of potential and actual crop yield. *Remote Sensing of Environment*, 13(4): 301 – 311.
- Hatfield JL, Gitelson AA, Schepers JS, Walthall CL. 2008. Application of spectral remote sensing for agronomic decisions. *Agronomy Journal*, 100(3): 117 – 131.
- Kemanian AR, Stöckle CO, Huggins DR, Viegas LM. 2007. A simple method to estimate harvest index in grain crops. *Field Crop Research*, 103(3): 208 – 216.

- Launay M, Guerif M. 2005. Assimilating remote sensing data into a crop model to improve predictive performance for spatial applications. *Agriculture, Ecosystem and Environment*, 111(1-4): 321 – 339.
- Maas SJ. 1988. Use of remote-sensed information in agricultural crop growth model. *Ecological Modelling*, 41: 247 – 268.
- Monteith JL. 1977. Climate and the efficiency of crop production in Britain. *Philosophical Transactions of the Royal Society of London, Series B*, 281(1977): 277 - 294.
- Nguy-Robertson A, Gitelson A, Peng Y, Viña A, Arkebauer T, Rundquist D. 2012. Green leaf area index estimation in maize and soybean: Combining vegetation indices to achieve maximal sensitivity. *Agronomy Journal*, 104(5): 1336–1347.
- Richter R. 2011. Atmospheric Correction Methods for Optical Remote Sensing Imagery of Land. En: Qihao Weng. (Eds.). *Advances in Environmental Remote Sensing, Sensors, Algorithms, and Applications*. Indiana. Taylor y Francis. 161-172.
- Sibley AM, Grassini P, Thomas NE, Cassman KG, Lobell DB. 2014. Testing Remote Sensing Approaches for Assessing Yield Variability among Maize Fields. *Agronomy Journal*, 106(1): 24 - 32.
- Sinclair TR, Amir J. 1992. A model to assess nitrogen limitations on the growth and yield of spring wheat, 30(1-2): 63 – 78.
- Sinclair TR, Muchow RC. 1999. Radiation use efficiency. *Advances in Agronomy*. 65: 215-265.
- Soltani A, Sinclair TR. 2012a. Dry Matter Production. En: Soltani A, Sinclair TR. (Eds.). *Modeling Physiology of Crop Development Growth and Yield*. London . CABI. 117 – 128.
- Soltani A, Sinclair TR. 2012b. Status of Crop Modeling. En: Soltani A, Sinclair TR. (Eds.). *Modeling Physiology of Crop Development Growth and Yield*. London. CABI. 117 - 128.

Wiegand CL, Maas SJ, Aase JK, Hatfield JL, Pinter PJ, Jackson RD, Kanemasu ET, Lapitan RL. 1992. Multisite analyses of spectral-biophysical data for wheat. *Remote Sensing of Environment*, 42(1): 1 – 21.

4. DISCUSIÓN GENERAL

El incipiente interés por parte de los agricultores, empresas de comercialización y agentes estatales por obtener estimaciones tempranas del rendimiento, ha incitado al desarrollo de metodologías asociadas al uso de imágenes satelitales para dichos fines. En la literatura se han reportado numerosos trabajos donde se intenta predecir el rendimiento final de cultivos a escala de estado o país (Moulin et al., 1998; Doraiswamy et al., 2005; Duchemin et al., 2008; Becker-Reshef et al., 2010; Casa et al., 2012; Franch et al., 2015). En la totalidad de dichos trabajos el rendimiento estimado (con resolución espacial variable dependiendo de la imagen seleccionada) fue contrapuesto contra la información del rendimiento observado proveniente de promedios de chacras o estados. Si bien en estos trabajos se alcanzaron rRMSE que estuvieron en un rango de 10 a 35%, la predicción de la variabilidad espacial a escala de chacra con alta resolución temporal continúa siendo un desafío con múltiples aspectos que aún no han sido abordados. Alguno de estos aspectos que aún no han sido resueltos y contribuyen en los desvíos en la estimación del rendimiento son: la homogenización de la reflectancia en una serie temporal de imágenes a través de la utilización de las rutinas de correcciones atmosféricas; la metodología utilizada para estimar parámetros de interés en el cultivo (en este caso el IAF); la metodología implementada para estimar el rendimiento; la simplicidad del modelo de cultivo implementado para asimilar la información espectral; aspectos vinculados a los instrumentos de medición del rendimiento observado en los monitores de rendimiento.

El proceso de filtrar las distorsiones por los efectos atmosféricos utilizando las rutinas para las correcciones atmosféricas es una etapa fundamental para estandarizar una serie temporal de imágenes. Las correcciones de dichos efectos se basan en modelos físicos complejos, como son los modelos basados en la transferencia radiativa de la radiación solar (Richter, 2011). Si bien el desarrollo de

las rutinas para realizar las correcciones atmosféricas se ha iniciado hace ya varias décadas, recién en los últimos años algunas de estas rutinas han sido incorporadas en diferentes software comerciales como es el ejemplo del software ATCOR. En la actualidad existen múltiples aspectos en las correcciones atmosféricas que aún no han sido totalmente resueltos y contribuyen a generar variabilidad y error en la estimación del IAF (Mannschatz et al., 2014). La falta de conocimiento del comportamiento de las condiciones no estándar de la atmósfera, como son las nubes o la neblina, impone ciertas restricciones para filtrar dichos efectos atmosféricos. Por un lado este hecho contribuye directamente a incrementar el error en la predicción de la reflectancia final y por otro lado reduce la frecuencia temporal de la información espectral.

Los diferentes enfoques que se han desarrollado para predecir características del canopeo requieren en primer término una etapa de calibración donde se invierte el modelo contra un conjunto de datos. El conjunto de datos de las variables de interés, en este caso IAF puede ser obtenido a través de observaciones o generado con simulaciones de un modelo de transferencia radiactiva (Baret y Buis, 2008). En el presente trabajo se utilizó el enfoque más antiguo e históricamente utilizado el cual emplea directamente los datos de reflectancia observados para predecir el IAF a través de una relación empírica. Dicha metodología presenta la limitante que la relación entre el IV y la variable de interés (IAF) depende de la vegetación que se está observando y de las condiciones ambientales (Hatflied et al., 2008). Por este motivo no es una tarea simple utilizar esta metodología con resoluciones espaciales medias a bajas y en múltiples condiciones ambientales. Estos aspectos condujeron a que se generaron en otros trabajos metodologías que emplean un modelo de transferencia radiactiva para generar un rango amplio de situaciones simuladas y evitar las limitaciones asociadas a la naturaleza empírica de utilizar una relación simple desde un conjunto de datos observados (Baret y Buis, 2008).

Por otra parte existen limitantes asociadas al índice seleccionado para predecir el IAF y la relación de respuesta al mismo. Si bien el NDVI es uno de los índices más conocidos y utilizados, varios estudios demuestran que debido a la saturación que se observa durante la estación de crecimiento el NDVI tiene mayor utilidad como estimador de la luz interceptada que del IAF (Wiegand et al., 1992; Gitelson, 2012). La no linealidad en la relación entre el NDVI y el IAF que se observó en el presente trabajo, estuvo acorde a lo esperado según lo reportado en la literatura donde se muestra que generalmente cuando el IAF excede el valor de dos, el NDVI es insensible a incrementos en el IAF (Gitelson, 2012). Los IV que incorporan las bandas de la región del verde y borde rojo muestran alta sensibilidad a cambios en el área foliar. Dicho comportamiento está vinculado a las regiones del espectro donde ocurre absorción por los pigmentos, especialmente la absorción por parte de la clorofila (Haboudane et al., 2004; Hatfield et al. 2008). Si bien los IV que incorporan la banda del borde rojo son de gran utilidad para predecir características del canopy, en general esta banda no se encuentra disponible en los satélites de libre acceso (Nguy-Robertson et al., 2012). Por otra parte la utilización de un único ajuste entre el IV y el IAF contribuye a incrementar el error en la estimación de los parámetros del cultivo, debido a que esta relación es variable con el ambiente. Esto se debe a que las relaciones empíricas implementadas entre el IAF y el IV presentan la limitante de ser variables entre ambientes (Haboudane et al., 2004, Nguy-Robertson et al., 2012). Por tanto para lograr un comportamiento más aceptable se requeriría un ajuste local para cada situación.

La implementación de una metodología que incorpora un modelo de cultivos y simula la evolución continua en el tiempo de las relaciones entre el cultivo y el ambiente no permitió alcanzar mayor precisión respecto a un método más simple que utilizó una relación empírica. Si bien las ventajas de asimilar la información espectral en un modelo de cultivos para estimar el rendimiento ya han sido descriptas y comprobadas desde los trabajos de Mass (1988) y Moulin et al., (1998), en este trabajo no se constató dicha ventaja. El método más simple que utilizó

únicamente una relación empírica alcanzó mayor precisión que el método que incorporo un modelo de cultivo en forma conjunta con las imágenes satelitales. Los altos valores de RMSE obtenidos al utilizar la metodología de asimilar las imágenes en un modelo de cultivo posiblemente sea atribuido a diversos factores que introducen fuente de variabilidad en los resultados, entre los cuales se encuentran: la alta resolución espacial y baja resolución temporal utilizada; las relaciones planta ambiente que no son considerados en el modelo de cultivos; los errores en las rutinas de corrección atmosférica que fueron explicados anteriormente y los errores en los instrumentos de medida de los monitores de rendimiento.

Si bien existen diferencias en la características de los sensores del Landsat 7 y Landsat 8, es posible combinar ambos satélites para lograr teóricamente alta frecuencia en la serie temporal de imágenes (Flood et al., 2014; Li et al., 2014). Esto otorgaría teóricamente una frecuencia temporal de una imagen por semana, pero la elevada frecuencia de días nublados en las latitudes de Uruguay durante la estación de crecimiento del trigo y las zonas SCL-off del Landsat 7 conducen a obtener frecuentemente una resolución temporal insuficiente para reconstruir el crecimiento del cultivo con un volumen de información mayor a cinco imágenes en el período vegetativo del cultivo. Contar con una serie temporal de imágenes completa para recopilar las curvas de crecimiento del cultivo no es frecuente, lo cual introduce fuente de variación en la predicción del IAF para cada pixel. Por otra parte el volumen de información durante el ciclo del cultivo, dado por el número de imágenes libres de nubes, condiciona el número de parámetros que pueden ser ajustados y de alguna manera también el tipo de modelo de cultivos que es posible utilizar (Moulin et al., 1998). En la medida que únicamente se pueden calibrar un número bajo de parámetros, un modelo simple y poco parametrizado es el tipo de modelo de cultivos más apropiado para utilizar en forma conjunta con información espectral de baja resolución temporal.

Por otra parte la alta resolución espacial de las imágenes Landsat y la metodología de medición del rendimiento de los monitores conducen a generar una gran fuente de error en los rendimientos observados. La descoordinación de escala es debida a que el instrumento de medida en el monitor de rendimiento puede tener un atraso en la medida de 40m, mientras que la resolución utilizada para interpolar la información del monitor se corresponde con una grilla de 30m x 30m. Por otra parte además de la descoordinación de escalas, la metodología de medición de los monitores conduce a obtener valores de rendimientos observados que son productos de una media móvil que va realizando el instrumento de medida. El hecho que el instrumento de medida realice una media móvil, lleva a que en la gran mayoría de los sitios se obtiene una distribución normal, que está muy centrada en el valor medio de la distribución. Sin embargo la distribución esperable del rendimiento en los ambientes de alto potencial (determinado en trigo principalmente por alta disponibilidad de nitrógeno) es una distribución con altos niveles de asimetría (asimetría entre 0 y -1), y en las situaciones con bajos niveles de fertilidad es esperable una distribución normal del rendimiento (Dumont et al., 2015).

La limitada disponibilidad de información del cultivo que se obtiene a través de las imágenes satelitales fuerza a que solo sea posible utilizar modelos simples, con reducida cantidad de parámetros, donde algunos de ellos son seleccionados para ser calibrados. La simpleza del modelo implementado y de los procesos que son representados impulsa a generar diversas fuentes de error producto de los procesos que no son contemplados, entre los cuales se pueden señalar: la reducción de los factores determinantes del crecimiento del cultivo a tan solo la radiación interceptada y la eficiencia de uso de la misma; la asunción que el contenido de nitrógeno es constante a lo largo del ciclo del cultivo y la falta de contemplación de los factores abióticos de estrés. Si bien como fue puntualizado

previamente la utilización de un modelo simple presenta múltiples restricciones, la metodología de invertir el modelo contra la serie de IAF permite contemplar la variabilidad existente en el crecimiento del cultivo a través de los parámetros de ajuste (Moulin et al., 1998). Con esta metodología se sintetizan todos los factores que determinan la variabilidad en la EUL (las condiciones ambientales y el estado nutricional) a través de cuantificar el crecimiento que logra el cultivo en cada microzona del campo (cada pixel). De esta forma se contemplan varios de los factores que afectan la tasa de fotosíntesis y reducen la EUL potencial, los cuales incluyen la temperatura, la concentración atmosférica de anhídrido carbónico, la deficiencia de agua y la concentración de nitrógeno en las hojas (Soltani y Sinclair, 2012).

El Método 1 no alcanzó un nivel de precisión suficiente para ser utilizado con fines prácticos a nivel predial ($RMSE = 1532 \text{ kg.ha}^{-1}$, $rRMSE = 36\%$ y $Bías = -401 \text{ kg.ha}^{-1}$), pero esta precisión fue equiparable a la reportada cuando se utilizaron metodologías similares para estimar el rendimiento con alta resolución espacial (Silbey et al., 2014). Sin bien existe una serie de trabajos reportados donde alcanzan $rRMSE$ en la estimación de rendimiento menores al 10% todos ellos utilizan baja resolución espacial (Doraiswamy et al., 2005; Becker-Reshef et al., 2010; Franch et al., 2015). Las diferencias entre los niveles de precisión reportados en trabajos anteriores y los que se lograron en este estudio posiblemente se corresponde en parte a las diferencias en las resoluciones espaciales utilizadas y a las características de los datos de rendimiento observado. Cuando se utiliza imágenes de baja resolución espacial (MODIS, AVHRR) en los hechos se realiza un promedio a una menor resolución espacial, y por lo tanto se reduce la variabilidad de las series de IAF y en consecuencia también se reduce la dispersión en el rendimiento estimado. De la misma forma también se reduce la variabilidad espacial en los rendimientos observados cuando se utiliza información de rendimiento proveniente de estadísticas a nivel país, en lugar de datos de monitores de rendimiento con una resolución espacial muy alta. Como resultado se alcanza alta precisión en la

estimación del rendimiento producto de reducir la variabilidad espacial a través de la resolución utilizada, pero en cambio se pierde la cuantificación de la microvariación espacial en el rendimiento del cultivo.

5. CONCLUSIONES GLOBALES

No se evidenció mayor precisión por la utilización de un modelo de cultivos en forma conjunta con datos de SR (Método 1) respecto a un método más simple que utilizó únicamente una imagen en el ciclo del cultivo (RMSE de 1532 y 826 kg.ha⁻¹ para el Método 1 y 2 respectivamente). Sin embargo la implementación del Método 1 permitió representar la variabilidad espacial en los rendimientos estimados que estuvo en concordancia con la dispersión esperable en el rendimiento.

Los altos valores de RMSE posiblemente fueron el resultado de múltiples factores de error, entre los cuales se pueden señalar: (i) la resolución espacial utilizada (se contrastaron rendimientos simulados y observados de pixeles de 30m); (ii) la baja resolución temporal de las imágenes Landsat producto de la frecuencia de días nublados; (iii) errores en las rutinas de corrección atmosférica; (iv) errores de medición en los monitores de rendimiento; y (v) estreses en llenado de grano que no son contemplados por el modelo.

La utilidad de ambas metodologías para estimar la variabilidad espacial del rendimiento a escala de predio agrícola es muy limitada debido a los altos valores de RMSE observados. Posiblemente si se dispone de mayor resolución temporal de las imágenes se logren niveles de precisión aceptables en la estimación del rendimiento y de su variabilidad espacial, debido a que es posible ajustar un número mayor de parámetros y contar con una curva de crecimiento estimada más cercana a la real.

En trabajos futuros será necesario disponer de mayor volumen de información espectral (resolución temporal), así como también generar mayor experiencia en la utilización de las diferentes metodologías de corrección atmosférica de las imágenes para alcanzar mayores niveles de precisión en estimaciones del rendimiento a nivel predial y de su variabilidad espacial. De esta manera la metodología tendrá mayor alcance para pronosticar los volúmenes de

cosecha, así como también para ser utilizada como insumo cuando se separan ambientes de diferente potencial de rendimiento.

6. BIBLIOGRAFÍA

- Baret F, Guyot G. 1991. Potentials and limits of vegetation indices for LAI and APAR assessment. *Remote Sensing of Environment*, 35: 161 – 173.
- Baret, F, Buis, S. 2008. Estimating Canopy Characteristics from Remote Sensing Observations: Review of Methods and Associated Problems, System, Modeling, Inversion and Application. En: Liang, S. (Eds.). *Advances in Land Remote Sensing*. Maryland. Springer. 173 - 202.
- Bastiaanssen, WGM, Ali, S. 2003. A new crop yield forecasting model based on satellite measurements applied across the Indus Basin, Pakistan. *Agriculture, Ecosystems and Environment*, 94: 321 – 340.
- Becker-Reshef, I., Vermote, E., Lindeman, M., Justice, C., 2010. A generalized regression-based model for forecasting winter wheat yields in Kansas and Ukraine using MODIS data. *Remote Sensing of Environment*, 114(6): 1312 – 1323.
- Berger, AG, Gaso, D, Calistro, R, Morales, MX. 2015. Limitantes Ambientales y Potencial de Rendimiento de Trigo en Uruguay. En: Seminario internacional 1914-2014, un siglo de mejoramiento de trigo en La Estanzuela. Complete papers book. Colonia. INIA. 50 – 63.
- Borrell, AK, Hammer, GL, Van Oosterom, E. 2001. Stay-green: a consequence of the balance between supply and demand for nitrogen during grain filling? *Annals Applied Biology*, 138(1): 91 – 95.
- Bouman, BAM, Van Keulen, H, Van Laar, HH, Rabbinge, R. 1996. The “School of de Wit” crop growth simulation models: A pedigree and historical overview. *Agricultural Systems*, 52(2-3):171 – 198.
- Casa, R, Varella, H, Buis, S, Guérif, M, De Solan, B, 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): 1 – 10.

- Chuvieco, E. 2002. Nociones Introductorias. En: Chuvieco. (Eds.). Teledetección ambiental. La observación de la tierra desde el espacio. Barcelona. Ariel S.A. 17-40.
- Conway, ED. 1997. Foundations of Remote Sensing. En: Conway, ED. (Eds.). An Introduction to Satellite Image Interpretation. Maryland. The Johns Hopkins University. 1 – 8.
- Cui, M, Vogelmann, TC, Smith, WK. 1991. Chlorophyll and light gradients in sun and shade leaves of *Spinacia oleracea*. *Plant Cell Environment*, 14(5): 493 – 500.
- Delécolle, R, Maas, SJ, Gurrit, M, Baret, F. 1992. Remote sensing and crop production models : present trends. *ISPRS Journal of Photogrammetry and Remote Sensing*, 47: 145 – 161.
- DIEA (Dirección de Estadística Agropecuaria). 2014. Anuario Estadístico Agropecuario 2014. [En línea].
<http://www.mgap.gub.uy/Dieaanterior/Anuario2014/Diea-Anuario%202014-Digital01.pdf>.
- Doraiswamy, PC, Sinclair, TR, Hollinger, S, Akhmedov, B, Stern, A, Prueger, J. 2005. Application of MODIS derived parameters for regional crop yield assessment. *Remote Sensing of Environment*, 97(2): 192 – 202.
- Duchemin, B, Maisongrande, P, Boulet, G, Benhadj, I. 2008. A simple algorithm for yield estimates: Evaluation for semi-arid irrigated winter wheat monitored with green leaf area index. *Environmental Model and Software*, 23(7): 876 – 892.
- Dumont, B, Basso, B, Leemans, V, Bodson, B, Destain, JP, Destain, MF. 2015. Yield variability linked to climate uncertainty and nitrogen fertilisation. *Precision Agriculture*, 16(4): 361 - 384.
- Flood, N, 2014. Continuity of Reflectance Data between Landsat-7 ETM+ and Landsat-8 OLI, for Both Top-of-Atmosphere and Surface Reflectance: A Study in the Australian Landscape. *Remote Sensing*, 6(9): 7952–7970.

- Franch, B, Vermote, EF, Becker-Reshef, I, Claverie, M, Huang, J, Zhang, J, Justice, C, Sobrino, JA. 2015. Improving the timeliness of winter wheat production forecast in the United States of America, Ukraine and China using MODIS data and NCAR Growing Degree Day information. *Remote Sensing of Environment*, 161: 131 – 148.
- Fukshansky, LA, Remisowsky, AM, McClendon, J, Ritterbusch, A, Richter, T, Mohr, H. 1993. Absorption spectra of leaves corrected for scattering and distributional error: A radiative transfer and absorption statistics treatment. *Photochemistry and Photobiology*, 57(3): 538 – 555.
- Gitelson, AA. 2004. Wide Dynamic Range Vegetation Index for remote quantification of biophysical characteristics of vegetation. *J. Journal of Plant Physiology*, 161(2): 165 – 73.
- Gitelson, AA, Peng, Y, Masek, JG, Rundquist, DC, Verma, S, Suyker, A, Baker, JM, Hatfield, JL, Meyers, T. 2012. Remote estimation of crop gross primary production with Landsat data. *Remote Sensing of Environment*, 121: 404 – 414.
- Gitelson, AA. 2012. Remote Sensing Estimation of Crop Biophysical Characteristic at Various Scales. En: Thenkabail, P.S., Lyon, J.G., Huete, A. *Hiperspectral Remote Sensing of Vegetation*. New York: Taylor y Francis. 329 - 358.
- Haboudane, D, Miller, JR, Pattey, E, Zarco-Tejada, PJ, Strachan, IB. 2004. Hyperspectral vegetation indices and novel algorithms for predicting green LAI of crop canopies: Modeling and validation in the context of precision agriculture. *Remote Sensing of Environment*, 90(3): 337 – 352.
- Hammer, GL, van Oosterom, E, McLean, G, Chapman, SC, Broad, I, Harland, P, Muchow, RC. 2010. Adapting APSIM to model the physiology and genetic of complex adaptive traits in field crops. *Journal of Experimental Botany*, 61(8): 2185 – 2202.
- Hatfield, JL. 1983. Remote sensing estimators of potential and actual crop yield. *Remote Sensing of Environment*, 13(4): 301 – 311.

- Hatfield, JL, Gitelson, AA, Schepers, JS, Walthall, CL. 2008. Application of spectral remote sensing for agronomic decisions. *Agronomy Journal*, 100(3): 117 – 131.
- Huete, AR, Liu, HQ, Batchily, K, van Leeuwen, W. 1997. A comparison of vegetation indices over a global set of TM images for EOS-MODIS. *Remote Sensing of Environment*, 59: 440 - 451.
- Jacquemoud, S, Baret, F, Andrieu, B, Danson, M, Jaggard, K. 1995. Extraction of vegetation biophysical parameters by inversion of the PROSPECT+SAIL model on sugar beet canopy reflectance data. Application to TM and AVIRIS sensors. *Remote Sensing of Environment*, 52(3): 163 - 172.
- Jensen, JR. 1996a. Remote Sensing Data Acquisition Alternatives. En: Clarke, KC. (Eds.). *Introductory Digital Image Processing*. New Jersey: Prentice-Hall (2nd ed.). 1 – 12.
- Jensen, J.R. 1996b. Image Preprocessing: radiometric and Geometric Correction. En: Clarke, KC. (Eds.). *Introductory Digital Image Processing*. New Jersey: Prentice-Hall (2nd ed.). 107 – 135.
- Jones, JW, Hoogenboom, G, Porter, CH, Boote, KJ, Batchelor, WD, Hunt, LA, Wilkens, PW, Singh, U, Gijsman, AJ, Ritchie, JT. 2003. The DSSAT cropping system model. *European Journal of Agronomy*, 18: 235-265.
- Jordan, CF. 1969. Derivation of leaf area index from quality of light on the forest floor. *Ecology*, 50(4):663–666.
- Kemanian, AR, Stöckle, CO, Huggins, DR, Viegas, LM. 2007. A simple method to estimate harvest index in grain crops. *Field Crop Research*, 103(3): 208 – 216.
- Kumar, R, Silva, L. 1973. Light ray tracing through a leaf cross section. *Applied Optics*, 12(12): 2950 – 2954.
- Launay, M, Guerif, M. 2005. Assimilating remote sensing data into a crop model to improve predictive performance for spatial applications. *Agriculture, Ecosystem and Environment*, 111(1-4): 321 – 339.

- Li, P, Jiang, L, Feng, Z. 2014. Cross-comparison of vegetation indices derived from landsat-7 enhanced thematic mapper plus (ETM+) and landsat-8 operational land imager (OLI) sensors. *Remote Sensing*, 6(1): 310 – 329.
- Maas, SJ. 1988. Use of remote-sensed information in agricultural crop growth model. *Ecological Modelling*, 41: 247 – 268.
- Mannschatz, T, Pflug, B, Borg, E, Feger, KH, Dietrich, P. 2014. Uncertainties of LAI estimation from satellite imaging due to atmospheric correction. *Remote Sensing of Environment*. 153: 24 – 39.
- Martre, P, Porter, JR, Jamieson, PD, Triboi, E. 2003. Modelling grain nitrogen accumulation and protein composition to understand sink/source regulations of nitrogen remobilization for wheat. *Plant Physiology*, 133(4): 1959 – 1967.
- Merzlyak, MN, Gitelson, AA. 1995. Why and what for the leaves are yellow in autumn? On the interpretation of optical spectra of senescing leaves (*Acer platanoides* L.). *Journal of Plant Physiology*, 145(3): 315 – 320.
- Monteith, JL. 1977. Climate and the efficiency of crop production in Britain. *Philosophical Transactions of the Royal Society of London, Series B*, 281(1977): 277 - 294.
- Moulin, S, Bondeau, A, Delécolle, R. 1998. Combining agricultural crop models and satellite observations: From field to regional scales. *International Journal of Remote Sensing*, 19(6): 1021–1036.
- Moulin, S, Fischer, A, Dedieu, G, Delécolle, R. 1995. Temporal variations in satellite reflectances at field and regional scales compared with values simulated by linking crop growth and SAIL models. *Remote Sensing of Environment*, 54(3): 261 – 272.
- Nguy-Robertson, A, Gitelson, A, Peng, Y, Viña, A, Arkebauer, T, Rundquist, D. 2012. Green leaf area index estimation in maize and soybean: Combining vegetation indices to achieve maximal sensitivity. *Agronomy Journal*, 104(5): 1336–1347.

- Passioura, JB. 1996. Simulation models: science, snake oil, education, or engineering. *Agronomy Journal*, 88(5): 690 - 694.
- Rembold, F, Atzberger, C, Savin, I, Rojas, O. 2013. Using low resolution satellite imagery for yield prediction and yield anomaly detection. *Remote Sensing*, 5(4): 1704 – 1733.
- Richter, R, Schläpfer, D. 2013. Atmospheric/Topographic Correction for Satellite Imagery (ATCOR-2/3 User Guide, Version 8.3.1, February 2014). [En línea] <http://www.rese.ch/download/index.html>
- Richter, R. 2011. Atmospheric Correction Methods for Optical Remote Sensing Imagery of Land. En: Qihao Weng. (Eds.). *Advances in Environmental Remote Sensing, Sensors, Algorithms, and Applications*. Indiana. Taylor y Francis. 161-172.
- Rondeaux, G, Steven, MD, Baret, F. 1996. Optimization of soil adjusted vegetation indices. *Remote Sensing of Environment*, 55(2): 95 - 197.
- Roberts, DA, Roth, KL, Perroy, RL. 2012. Hyperspectral Vegetation Indices. En: Thenkabail, PS, Lyon, JG, Huete, A. (Eds.). *Hiperspectral Remote Sensing of Vegetation*. New York. Taylor y Francis. 309 - 327.
- Schott, JR. 2007. Radiometry and Radiation Propagation. En: Schott, JR. (Eds.). *Remote Sensing the Image Chain Approach*. New York. Oxford University . 57 – 108.
- Sibley, AM, Grassini, P, Thomas, NE, Cassman, KG, Lobell, DB. 2014. Testing Remote Sensing Approaches for Assessing Yield Variability among Maize Fields. *Agronomy Journal*, 106(1): 24 - 32.
- Sinclair, TR, de Wit. 1976. Analysis of the carbon and nitrogen limitations to soybean yield. *Agronomy Journal*, 68(2): 319 - 324.
- Sinclair, TR. 1986. Water and nitrogen limitations in soybean grain production. I. Model development. *Field Crops Research*, 15(2): 125 - 141.

- Sinclair, TR, Horie, T. 1989. Leaf nitrogen, photosynthesis, and crop radiation use efficiency: a review. *Crop Science*, 29(1): 90 - 98
- Sinclair, TR, Amir, J. 1992. A model to assess nitrogen limitations on the growth and yield of spring wheat, 30(1-2): 63 – 78.
- Sinclair, TR, Seligman, N. 1996. Crop modeling: from infancy to maturity. *Agronomy Journal*, 88(5): 698 - 704.
- Sinclair, TR, Muchow, RC. 1999. Radiation use efficiency. *Advances in Agronomy*. 65: 215-265.
- Sinclair, TR, Farias, JR, Neumaier, N, Nepomuceno, AL. 2003. Modeling nitrogen accumulation and use by soybean. *Field Crops Research*, 81(2-3): 149–158.
- Sinclair, TR, Jamieson, PD. 2008. Yield and grain number of wheat: A correlation or causal relationship? *Field Crops Research*, 105(1-2): 22–26.
- Soltani, A, Sinclair, TR. 2012a. Dry Matter Production. En: Soltani, A, Sinclair, TR. (Eds.). *Modeling Physiology of Crop Development Growth and Yield*. London . CABI. 117 – 128.
- Soltani, A, Sinclair, TR. 2012b. Status of Crop Modeling. En: Soltani, A, Sinclair, TR. 2012. (Eds.). *Modeling Physiology of Crop Development Growth and Yield*. London. CABI. 117 - 128.
- Soltani, A, Sinclair, TR. 2015. A comparison of four wheat models with respect to robustness and transparency: Simulation in a temperate, sub-humid environment. *Field Crop Research*, 175: 37 – 46.
- Stockle, CO, Martin, S, Campbell, GS. 1994. CropSyst, a cropping systems model: water/nitrogen budgets and crop yield. *Agricultural Systems*, 46(3): 335 – 359.
- Tucker, CJ. 1979. Red and photographic infrared linear combinations for monitoring vegetation. *Remote Sensing of Environment*, 8: 127 – 150.
- Tucker, CJ, Holben, BN, Elgin, JH. 1981. Remote sensing of total dry-matter accumulation in winter wheat. *Remote Sensing of Environment*, 11: 171 - 189.

- Van Ittersum, MK, Leffelaar, PA, Van Keulen, H, Kropff, MJ, Bastiaans, L, Goudriaan, J. 2003a. Developments in modelling crop growth, cropping systems and production systems in the Wageningen school. *NJAS - Wageningen Journal Life Science*, 50(2): 239 – 247.
- Van Ittersum, MK, Leffelaar, PA, Van Keulen, H, Kropff, MJ, Bastiaans, L, Goudriaan, J, 2003b. On approaches and applications of the Wageningen crop models. *European Journal of Agronomy*, 18(3-4): 201 – 234.
- Weiss, M, Baret, F, Myneni, R, Pragnère, A, Knyazikhin, Y. 2000. Investigation of a model inversion technique for the estimation of crop characteristics from spectral and directional reflectance data. *Agronomie*. 20: 3-22.
- Wiegand, CL, Maas, SJ, Aase, JK, Hatfield, JL, Pinter, PJ, Jackson, RD, Kanemasu, ET, Lapitan, RL. 1992. Multisite analyses of spectral-biophysical data for wheat. *Remote Sensing of Environment*, 42(1): 1 – 21.
- Yin, X, van Laar, HH. 2005. Introduction. En: Yin, X, van Laar, HH. (Eds.). *Crop Systems Dynamics. An ecophysiological simulation model for genotype-by-environment interactions*. Wageningen. Wageningen Academic Publishers. 1-8.