

# COMPARACIÓN ENTRE ECUACIONES EMPÍRICAS Y MODELOS DE SIMULACIÓN PARA ESTIMAR CONTENIDO DE AGUA EN PASTIZALES

YEBRA ALVAREZ, M., CHUVIECO SALINERO E.,  
NIETO SOLANA, H., AGUADO SUAREZ, I.

Departamento de Geografía, Universidad de Alcalá  
Colegios, 2, 28801 Alcalá de Henares (Madrid)  
marta.yebra@uah.es; emilio.chuvieco@uah.es; hector.nieto@uah.es;  
inmaculada.aguado@uah.es

## RESUMEN

En este trabajo se estima contenido de humedad (FMC) de pastizales en el marco del uso de la teledetección para estimar condiciones de riesgo de incendio. La estimación se realiza a partir de dos perspectivas que emplean la teledetección para la estimación de FMC: *ajustes empíricos multitemporales* y *modelos teóricos de simulación de la reflectividad*. De esta manera se presentan regresiones múltiples entre datos de contenido en humedad de pastizales del Parque Nacional de Cabañeros (años 2001-2005) e imágenes Terra-MODIS de las mismas fechas, que permiten obtener coeficientes de determinación de 0.9. Análogamente, se emplean los modelos de simulación Prospect y SAILH en modo directo para generar una tabla de referencia (LUT) a partir de la cual se realiza un ajuste entre los FMC parametrizados y sus correspondientes espectros MODIS simulados. Se obtienen de esta forma un ajuste sensiblemente inferior al obtenido con el modelo empírico ( $r^2$  de 0.86), si bien al validar esta última ecuación el ajuste entre los datos estimados y observados aunque con un coeficiente de determinación significativo (0.73) es lejano a una relación 1:1, mientras que al validar la ecuación empírica se obtiene una relación muy cercana a 1:1 y un  $r^2$  de 0.9. Preliminarmente se concluye que aunque los modelos de simulación poseen un carácter más generalizable, para conseguir estimaciones de FMC precisas se debe conocer la distribución de los diferentes parámetros del modelo para los combustibles objeto de estimación del FMC, así como combinaciones no reales de los mismos, lo que complica su potencial uso global.

## Palabras clave:

Contenido de agua, riesgo de incendio, Modelos de simulación, RTM, Teledetección

## 1. INTRODUCCIÓN

La estimación del contenido de agua en las plantas resulta clave para entender mejor sus relaciones con el ecosistema, sus características fisiológicas y la explicación de algunos mecanismos vitales. En el ámbito del análisis del riesgo de incendios forestales el contenido de humedad (FMC, cantidad de agua en la planta por unidad de peso seco), es una de las variables más importantes en la estimación de condiciones de peligro, por lo que afecta a la ignición y posterior propagación del fuego (Van Wagner 1967; Brown and Kenneth 1979; Burgan, Klaver et al. 1998). Asimismo, el FMC afecta notablemente a la aplicación de algunos tratamientos preventivos, como la reducción del combustible mediante fuegos prescritos (Mbow, Goïta et al. 2004), y es clave para

mejorar la estimación de emisiones, ya que el FMC está relacionado con la intensidad de la quema (Chuvienco, Cocero et al. 2004).

La importancia de estimar FMC afecta tanto a combustibles muertos como a vivos. Los primeros se han estimado a partir de índices meteorológicos, ya que están directamente asociados a la variación de las condiciones atmosféricas (Camia, Leblon et al. 2003). En cuanto a los combustibles vivos, resulta mucho más complejo, ya que su FMC depende también de las condiciones del suelo y de la propia fisiología de la planta. La forma más precisa es el muestreo de FMC en campo, pero resulta poco operativo y costoso, por lo que, en la práctica, esta metodología sólo se emplea para la validación de otras. Debido a que la disminución en el FMC de los combustibles vivos tiene efectos en la forma en la que estos reflejan o emiten energía, pueden emplearse técnicas basadas en la teledetección (radiómetros de laboratorio o sensores remotos) para estimar FMC.

Existen principalmente dos perspectivas para emplear la teledetección para la estimación de FMC: *ajustes empíricos multitemporales* y *modelos teóricos de simulación de la reflectividad*. Ambas perspectivas asumen que las variaciones en la reflectividad causadas por el cambio en el FMC son suficientemente nítidas como para diferenciarse de las causadas por otros factores: reflectividad del suelo, parámetros bioquímicos (celulosa y lignina), peso específico y estructura interna de la hoja, parámetros biofísicos del dosel (LAI) y la influencia de la atmósfera (Ceccato 2001). Los métodos más empleados para estimar el FMC se basan en las bandas del SWIR (1,6 a 2  $\mu\text{m}$ ), en donde el agua presente fuerte absorción, mientras el IRC (0,7 a 1  $\mu\text{m}$ ) se utiliza para normalizar, ya que es relativamente insensible al agua (Gao 1996; Ceccato, Gobron et al. 2002).

En los últimos años se han publicado numerosos trabajos que muestran buenos ajustes empíricos entre medidas de FMC de campo con datos de reflectividad o índices derivados de los mismos, usando tanto radiometría de laboratorio (Sims and Gamon 2003), como sensores remotos de alta resolución radiométrica o espacial (Serrano, Ustin et al. 2000) (Chuvienco, Riaño et al. 2002) (Jackson, Chen et al. 2004). También se han empleado imágenes de baja resolución espacial pero alta frecuencia, como las adquiridas por el NOAA-AVHRR (Kogan, Gitelson et al. 2003; Chuvienco, Cocero et al. 2004) y, más recientemente, el MODIS (Moderate Resolution Imaging Spectrometer), embarcado sobre los satélites Terra y Aqua (Dennison, Roberts Dar et al. 2005).

El principal problema de las ecuaciones empíricas es su escaso poder de generalización, ya que son muy dependientes del tipo de especie y las condiciones meteorológicas del año (Roberts, Peterson et al. 2005), por lo que su empleo queda limitado en aplicaciones locales. La alternativa a los modelos empíricos son los modelos de simulación (RTM), que al tener mayor base física, permiten aplicarse – adecuadamente parametrizados- a muy diversas condiciones (Privette, Emery et al. 1996). Estos modelos pueden emplearse de forma directa, introduciendo sus correspondientes parámetros de entrada para simular la reflectividad resultante, o inversa, en donde se estiman los parámetros de entrada a partir de la reflectividad medida por el sensor. No todos pueden ser invertidos o su inversión es excesivamente compleja (Woodcock and Strahler 1987). Tanto de forma directa como inversa, los RTM se han empleado en los últimos años para estimar FMC. Generalmente, la forma directa ayuda a diseñar nuevos índices de vegetación sensibles a variaciones en el

contenido de humedad, que posteriormente pueden ser utilizados para la estimación de FMC mediante ajustes empíricos (Zarco Tejada and Ustin Susan 2001; Ceccato, Gobron et al. 2002). Por su parte, la forma inversa permite estimar FMC mediante un ajuste de los parámetros del modelo hasta que los espectros modelados de forma directa se ajusten a los observados, extrayéndose de ahí los parámetros de entrada que mejor simulan las condiciones observadas, ya sean espectros de laboratorio o imágenes de teledetección. Entre las aplicaciones recientes de estos modelos a la estimación del FMC pueden citarse los estudios de Zarco-Tejada, Rueda et al. (2003) y Riaño, Vaughan et al. (2005). Pese a su robustez, estos modelos también presentan problemas. En primer lugar, asumen condiciones y simplificaciones, diferentes según el modelo, que a veces no se encuentran en la naturaleza, y requieren parámetros que son difíciles de obtener. En segundo lugar, se plantean con problemas de indeterminación en las inversiones (diferentes combinaciones de varios parámetros puede originar el mismo espectro), además de las propias incertidumbres en los datos de entrada que crean errores de estimación (Combal, Baret et al. 2002).

En cuanto a la precisión de las estimaciones, los estudios realizados mediante metodologías empíricas o RTM difieren en la fuente de los datos radiométricos, zonas y/o especies de estudio, por lo que los resultados que arrojan, no parecen ser comparables. En cuanto a su aplicabilidad a nivel global, todo parece indicar que la inversión de RTM será la metodología más adecuada, debido a su mayor poder de generalización pero, sin embargo no se sabe hasta que punto será operativo ya que, para conseguir estimaciones de FMC precisas se debe emplear información complementaria sobre la distribución de los diferentes parámetros del modelo para los combustibles objeto de estimación del FMC, lo que complica su potencial uso global.

El objetivo de este artículo es comparar las estimaciones de contenido de humedad obtenidas mediante datos de reflectividad del sensor MODIS, ajustes empíricos y la inversión de RTM, para especies herbáceas. El objetivo final es elegir la técnica más adecuada para desarrollar una metodología operativa de estimación de FMC para espacios mediterráneos, en el marco de uso de la teledetección para estimar condiciones de riesgo de incendio, por lo que el estudio será ampliado en etapas posteriores a especies de matorral y arbolado. El principal desafío de este estudio es aplicar ambas metodologías de manera que los resultados de sus estimaciones sean completamente comparables. Por ello, se han empleado los datos de campo y los de reflectividad procedentes del mismo sensor (sensor MODIS), lugar y especies, tanto para calibrar como validar los modelos.

## **2. MATERIALES Y METODOS**

La figura 1 incluye un esquema general de la metodología que se ha seguido en este trabajo. Dicho esquema será desglosado y explicado en los posteriores apartados.

### **2.1. Trabajo de campo**

El área seleccionada para la realización de este estudio está situada en el Parque Nacional de Cabañeros (figura 2), localizado entre el cuadrante noroccidental de la provincia de Ciudad Real y el suroccidental de la de Toledo.

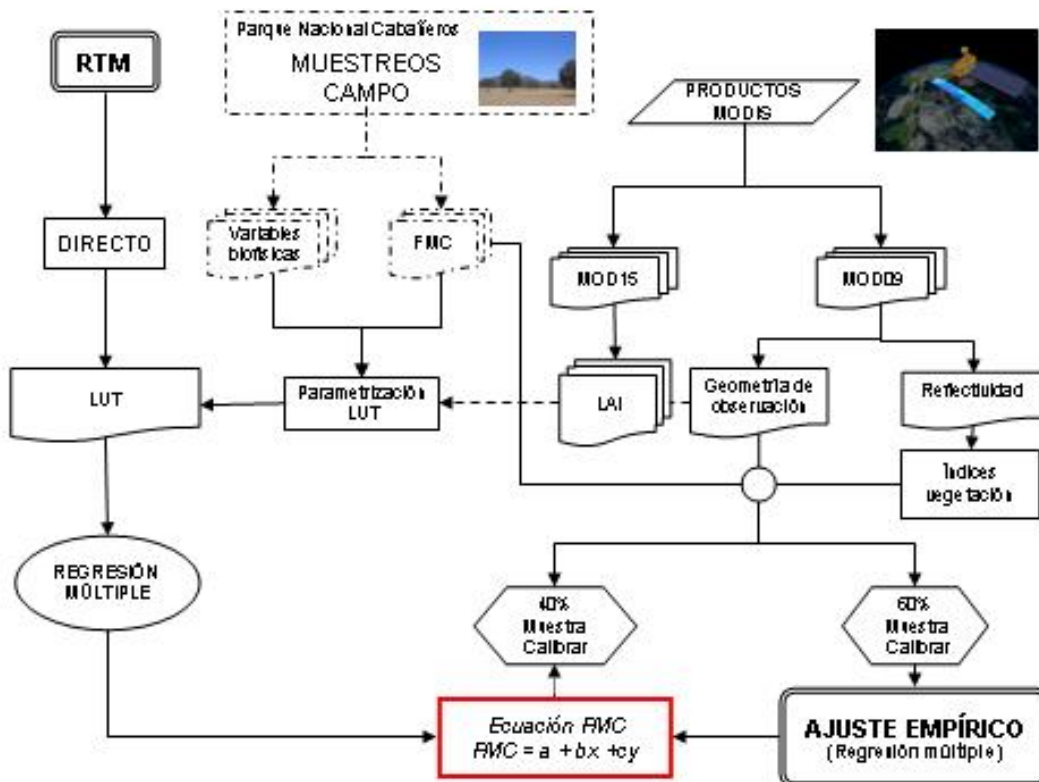


Figura 1. Esquema metodológico seguido para la estimación de FMC mediante metodologías empíricas y de RTM

Se considera esta zona ideal para la calibración de modelos por varias razones. En primer lugar, al tratarse de un Parque Nacional, resulta más asequible asegurar la consistencia temporal de las parcelas de muestreo. En segundo lugar, porque presenta extensas manchas de pastizal Mediterráneo y en tercer lugar, porque nuestro grupo de investigación lleva haciendo seguimientos de contenidos en humedad en esa zona desde 1996, por lo que se dispone de una base de datos consistente sobre la evolución del FMC de las especies presentes en la zona.

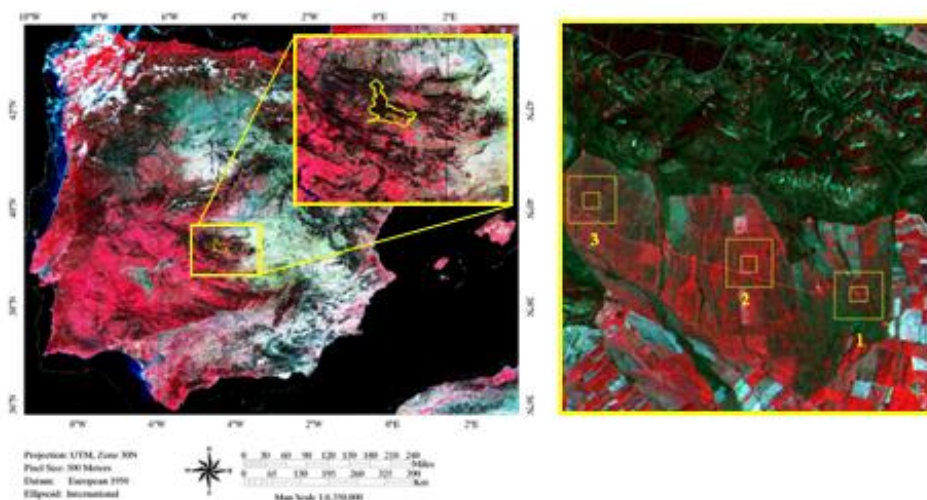


Figura 2. Localización del área de estudio. Imagen MODIS (izda) y Landsat (dcha), con la localización de las 3 parcelas utilizadas en el inventario de campo y los píxeles MODIS correspondientes al centro de la parcela y a una ventana 3x3

Para la obtención de los datos de humedad necesarios, tanto para la calibración como para la validación de las dos metodologías objeto de comparación, se ha contado con los datos de campo disponibles en nuestro grupo desde 2001 hasta 2005, durante los meses que comprenden la estación de incendios (marzo-abril a septiembre). Todas las medidas de campo se realizaron bajo el mismo protocolo estandarizado para asegurar la significación espacial y temporal de las muestras, siguiendo las recomendaciones de diferentes autores (Desbois, Deshayes et al. 1997). De esta forma, en cada campaña de campo se recolectaron cada 8 ó 16 días y a la hora de mínimo FMC y máximo riesgo de incendio (entre las 12:00 y las 16:00 horas), tres muestras de pastizal de peso comprendido entre 50 y 100 gr., de cada una de las 3 parcelas de 30 X 30 metros seleccionadas para los muestreos. Las muestras así recogidas se introdujeron en sobres de papel, y se pesaron en campo (peso fresco) con una balanza de precisión “Sartorius BP211D” (error de 0,01 mg). Posteriormente, fueron llevadas a laboratorio y secadas en una estufa durante 48h a 60° C, para obtener el peso seco. Los valores de humedad se expresaron como FMC según la expresión (1) (Slavik 1974):

$$FMC(\%) = \frac{Pf - Ps}{Ps} \times 100 \quad (1), \text{ donde Pf = peso fresco (en campo) y Ps = peso seco}$$

Las campañas de campo de los años 2004 y 2005 fueron intensificadas con el objetivo de poder parametrizar adecuadamente los RTM. Así, cada quince días, además de FMC, se recogieron muestras para la obtención de peso específico (PE), espesor equivalente de agua (EWT) y contenido en clorofila (Ca+b) y se midió la reflectividad a nivel de dosel. Debido a la dificultad de medir el área foliar de las especies de pastizal, se recolectaron todos los individuos incluidos en un cuadrat de 40 x 40 cm, superficie que se tomo como área foliar proyectada. Finalmente, se calcularon dichas variables con las siguientes expresiones:

$$PE(\text{gr.cm}^{-2}) = \frac{Ps}{\text{Área}} \quad (2) \quad EWT(\text{gr.cm}^{-2}) = \frac{Pf - Ps}{\text{Área}} \quad ;$$

La clorofila (Ca+b) se calculó a partir de un muestreo destructivo de 10 hojas, extrayendo la concentración de clorofila mediante el método DMSF y lectura espectrofotométrica (Wellburn 1994). Por otro lado, se midió la reflectividad del suelo de las parcelas de muestreo, parámetro de entrada de los modelos a nivel de dosel que influye bastante sobre las estimaciones finales. Para ello, se tomaron dos muestras de suelo desnudo de cada una de las parcelas y se midieron en el exterior con el radiómetro GER 2600 (GER Corp., Millbrook, NY) a la misma hora de la toma de muestras. La reflectividad final de entrada al RTM se obtuvo como un promedio de las muestras tomadas.

## 2.2. Adquisición y tratamiento de imágenes MODIS

El sensor MODIS presenta una buena resolución espacial para estudios regionales (250m, 500m y 1000 m según las bandas) y una amplia cobertura espectral (36 bandas espectrales, con longitudes de onda que van desde los 0.4 μm a los 14.4 μm). Sus imágenes son de descarga gratuita, a través de un servidor de la NASA (<http://edcimswww.cr.usgs.gov/pub/imswelcome/>). Las imágenes MODIS, son convertidas por diferentes equipos de la NASA en productos derivados (Justice,

Townshend et al. 2002). Para este trabajo descargamos el producto de reflectividad MOD09 (Vermote and Vermeulen 1999), compuesto de 8 días de las 7 primeras bandas del sensor (resolución 500 m), y otras con información auxiliar (geometría de observación, día del año de extracción del valor del píxel del compuesto e información sobre la calidad de los datos). También descargamos el producto estándar de área foliar (LAI), denominado MOD15A2 (Knyazikhin, Glassy et al. 1999), que es un compuesto de 8 días a una resolución espacial de 1 km. El algoritmo de generación de este producto, validado en diferentes estructuras vegetales y lugares, está basado en la teoría de transferencia radiativa (RTM tridimensional) y en técnicas de inversión LUT a partir de datos de reflectividad de las bandas del rojo e infrarrojo cercano del producto MOD09 e información complementaria sobre las características de la superficie. Su solución es dependiente del tipo de vegetación (producto de usos del suelo, MOD12) y es sustituido por estimaciones empíricas en condiciones de observación extremas.

Se solicitaron los productos descritos para el mismo periodo de estudio del que teníamos información de campo (marzo 2001- septiembre 2005). Todos los productos fueron reproyectados a UTM con una resolución común de píxel de 500 m. Con el fin de paliar el efecto de valores anómalos que pudieran extraerse como consecuencia de defectos en el ajuste multitemporal entre imágenes, y reducir el ruido consecuente de efectos atmosféricos residuales, los valores de reflectividad y LAI característicos de cada una de las cubiertas fueron extraídos de cada imagen como la mediana de ventanas de 3 x 3 píxeles en torno al centro de cada parcela. Una vez extraídos los valores de reflectividad, se calcularon los índices de vegetación que aparecen en la tabla 1. La selección de los mismos se realizó en base a resultados obtenidos por diferentes autores en estudios previos realizados con el mismo sensor u otros de similares características.

Para asignar a cada fecha de campo los datos de reflectividad de un compuesto MODIS, se eligió para cada parcela y píxel los valores del día más cercano (siempre que fuera anterior) al de muestreo de campo. Emplear el compuesto que incluye la fecha de muestreo puede suponer en ocasiones que se elijan valores adquiridos después del mismo, lo que distorsionaría los resultados si ha habido precipitaciones tras la toma de datos en terreno. El mismo criterio se utilizó para extraer los valores del producto LAI.

Finalmente, la muestra de 66 periodos disponibles fue dividida aleatoriamente en dos grupos, un 60% para la calibración de los ajustes empíricos y un 40% para la validación de los ajustes empíricos y los RTM. En las dos muestras se combinan años secos y húmedos, lo que asegura mayor representatividad en los resultados.

### **2.3. Análisis de los datos:**

En lo que a modelos empíricos se refiere, se correlacionaron los valores promedios de las tres parcelas de pasto existentes con los promedios de los valores FMC medidos en campo para las mismas. Posteriormente, aquellas bandas del MODIS o variables derivadas de ellas que mostraron coeficientes de Pearson significativos con el FMC de campo fueron introducidas como variables independientes en una análisis de regresión lineal múltiple (RLM) en SPSS 13.0 (SPSS 1999), con el objetivo de obtener una ecuación integrada de estimación de FMC. Se eligió la metodología de RLM por pasos hacia delante con umbrales de valor de tolerancia de probabilidad de  $F=0.08$  para incluir y  $F=0.1$  para rechazar una variable en la ecuación.

**Tabla 1. Índices extraídos de los datos de reflectividad de MODIS agrupados según se traten de índices de verdor, los primeros, o de contenido en humedad, los segundos.**

FORMULACIÓN MODIS	PROPIEDADES	AUTOR ÍNDICE
$NDVI = \frac{\rho_2 - \rho_1}{\rho_2 + \rho_1}$	“Normalized Difference Vegetation Index” Su valor incrementa según la vegetación se hace más verde o densa. Los valores típicos oscilan entre 0.1 para suelos desnudos y 0.9 para vegetación densa.	(Rouse, Haas et al. 1974)
$SAVI = \frac{\rho_2 - \rho_1}{\rho_2 + \rho_1 + L}(1+L)$	“Soil Adjusted Vegetation Index” Incorpora el parámetro L, constante que ajusta la línea vegetación-suelo al origen. Varía de 0 a 1 dependiendo de la cantidad de suelo visible. La gran mayoría de los valores de LAI asumen un L de 0,05.	(Huete 1988)
$EVI = \frac{2,5 \times (\rho_2 - \rho_1)}{(\rho_2 + 6 \times \rho_1 - 7,5 \times \rho_3 + 1)}$	“Enhanced vegetation index” Diseñado para optimizar la señal de la vegetación, mejorando la sensibilidad (disminuyendo las influencias del fondo del dosel y atmosféricas) y en consecuencia su seguimiento en regiones con alta biomasa.	(Huete, Didan et al. 2002)
$GEMI_1 = \frac{eta * (1 - 0,25 * eta) - \rho_1 - 0,12}{1 - \rho_1}$ $eta = \frac{2 * (\rho_2^2 - 1,5 \rho_2 + 0,5 \rho_1)}{\rho_2 + \rho_1 + 0,5}$	“Global Environmental Monitoring Index” Diseñado para reducir el efecto de las perturbaciones atmosféricas. El ruido del suelo hace que el GEMI no funcione para coberturas bajas de vegetación (impropio para regiones áridas)	(Pinty and Verstraete 1992)
$VARI_i = \frac{\rho_4 - \rho_1}{\rho_4 + \rho_1 - \rho_3}$	“Visible Atmospheric Resistant Index” muy poco sensible a efectos atmosféricos.	[Gitelson, 2002 #4725]
$NDII_6 = \frac{\rho_2 - \rho_6}{\rho_2 + \rho_6}$	“Normalized Difference Infrared Index” (para el sensor MODIS se le ha denominado “Shortwave Infrared Water Stress Index” : SIWISI). Es más sensible al contenido de humedad al incluir una banda en la región de absorción del agua.	(Hunt and Rock 1989) (Fensholt and Sandholt 2003)
$D_{kl} = \frac{\rho_l - \rho_k}{w_l - w_k}$	Derivada: l,k son bandas contiguas, w es el centro de banda. Para sensores que no poseen bandas continuas se puede calcular la pendiente o gradiente entre bandas.	(Danson, Steven et al. 1992) (Chuvienco, Riaño et al. 2002)
$I = 20 \times \rho_3 + 20 \times \rho_4 + 50 \times \rho_1 + 24 \times \rho_6 + 50$	Integral. Consiste en el cálculo de la integral de las reflectividades en las bandas del SWIR y el visible multiplicada por sus respectivos anchos de banda. Este índice debe estar negativamente correlacionado con el FMC ya que se basa en el efecto de absorción que el agua tiene en dichas bandas (en especial las del SWIR).	(Chuvienco, Riaño et al. 2002)
$NDWI = \frac{\rho_2 - \rho_5}{\rho_2 + \rho_5}$	Normalizad Difference Water Index” Índice basado en dos bandas de baja absorción de agua; 860 nm, absorción mínima y 1.240 nm. poca absorción de agua. Parece ser poco sensible a la dispersión atmosférica y ofrece buenos resultados en cubiertas densas debido a su sensibilidad a la reflectividad del suelo.	(Gao 1996)
$GVMI = \frac{(\rho_2 + 0,1) - (\rho_6 + 0,02)}{(\rho_2 + 0,1) + (\rho_6 + 0,02)}$	“Global Vegetation Moisture Index” con la misma filosofía que el NDII combina bandas del SWIR y del IRC fue creado para optimizar la estimación de contenido en humedad expresado como (EWT) y minimiza los efectos atmosféricos.	(Ceccato, Gobron et al. 2002)

Respecto a los RTM, se seleccionaron dos modelos ampliamente referenciados en la literatura, el PROSPECT (Jacquemoud 1990), y el SAILH (Verhoef 1984) que simulan en el espectro solar, entre 400 y 2500 nm. El primero simula las propiedades ópticas de las hojas considerándolas como una pila de  $N$  láminas paralelas compuestas de elementos absorbentes y dispersores. La absorción es modelada usando la concentración de pigmentos ( $Ca+b$ ), de agua (EWT), y de materia seca (PE) empleando sus correspondientes coeficientes de absorción espectral ( $Ka+b$ ,  $Kw$ ,  $Km$ ). El SAILH es un modelo de turbidez a nivel de dosel, por lo que trata la cobertura vegetal como una capa horizontal infinitamente extendida, uniforme y plana, formada por elementos de vegetación distribuidos de forma aleatoria en capas paralelas que hacen de pequeñas partículas reflectoras que absorben dependiendo de sus propiedades ópticas (reflectividad y la transmisividad) lo que le hace idóneo para cubiertas homogéneas (Jacquemoud 1993) como es el caso del pastizal. Tiene en cuenta no solo la reflectividad de la hoja, sino también la del suelo, la arquitectura de la planta (LAI y LAD), el aporte de radiancia difusa por parte de la atmósfera y los ángulos de observación e iluminación.

Respecto a las técnicas empleada para la inversión, se empleó inicialmente el método de inversión tradicional de optimización iterativa, mediante el programa Inv-Prospect-Sailh (Rueda 2001), para realizar un análisis preliminar de los datos y adquirir un conocimiento más profundo de los modelos, debido a que su uso es más intuitivo. No obstante, como el objetivo final de este trabajo es usar las inversiones de manera operativa con imágenes satélite, se descartó esta metodología por ser muy costosa en tiempo. Entre las otras alternativas de inversión (tablas de referencia, LUT, y redes neuronales, NNT), se selecciono la LUT ya que la fase de aprendizaje de NNT sigue requiriendo alta inversión en tiempo computacional y por otro lado, la LUT tiene la ventaja de permitir eliminar combinaciones de parámetros no reales (Weiss 2000). La inversión mediante LUT consiste en generar escenarios a partir de variar en un rango conocido los parámetros de entrada de los RTM (fase de parametrización). Estos valores de entrada corresponden a nuestras observaciones de campo o las extraídas de la literatura (tabla 2). Las variables más dinámicas se dejaron oscilar entre los valores máximos y mínimos observados en campo, mientras que aquellas sin o con escasa variación estacional o cuya variación afecta a longitudes de onda poco relacionadas con el FMC, se mantuvieron fijos. Con el objetivo de obtener un tamaño de LUT óptimo, se fijaron diferentes saltos en las simulaciones en función del dinamismo del parámetro de entrada y de la sensibilidad del modelo al mismo. No obstante, para cubrir mejor el espacio de variación y tener en cuenta posibles errores en la precisión de las medidas de campo, se incluyó en cada variable un número aleatorio  $\pm 0.5$  veces el salto. El resto de parámetros de entrada al modelo SAILH no reflejados en la tabla, se mantuvieron fijos. Se empleó un fichero estándar la radiación difusa, para el suelo el fichero de reflectividad del suelo de Cabañeros, obtenido con el GER, la LADF se fijó en erectófilo. De esta manera, variando aleatoriamente en los intervalos fijados los parámetros de entrada se obtuvieron un rango muy amplio de espectros (5940) a partir de los cuales se generaron los espectros sintéticos del sensor MODIS.

El FMC correspondiente a cada simulación de la LUT fue calculado a partir de los parámetros EWT y PE del modelo PROSPECT mediante la expresión (4).

$$FMC(\%) = \frac{EWT}{PE} \times 100 \quad (4)$$



**Tabla 2. Rango de valores de campo observados para los parámetros a nivel de hoja y de dosel relevantes para la parametrización de PROSPECT-SAILH y saltos empleados para la simulación y generación de la LUT.**

Modelo	Parámetro	Mín	Máx	Salto
PROSPECT	N	1.25	2.5	0.5
	PE (gr/cm <sup>2</sup> )	0.01	0.04	0.003
	EWT (gr/cm <sup>2</sup> )	0.002	0.06	0.002
	Ca+b(μg/cm <sup>2</sup> )	20	20	-
SAILH	LAI	0.5	2	0.6
	Hotspot	0.001	0.001	-
	ts	27	51	16
	tv	5	5	-
	psr	-30	-30	-

Generalmente, la estimación del FMC se realiza a partir de encontrar qué combinación de parámetros simulados en la LUT obtiene una mayor similitud con las reflectividades observadas extraídas de la zona que quiere invertirse. Esa similitud se basa en minimizar una función de error (habitualmente mínimos cuadrados). De esta forma, solo se corre el RTM en la fase de construcción de la LUT, lo que reduce considerablemente el tiempo computacional a la hora de realizar la inversión. En nuestro caso en lugar de la función de error, se aplicó a los datos de la LUT la metodología seguida en el ajuste empírico (RLM), como si de observaciones de campo se trataran.

Puesto que las simulaciones se hacen variando sistemáticamente los parámetros de entrada puede fácilmente ocurrir que algunas de las combinaciones simuladas sean poco realistas. Por ejemplo, podrían simularse bajos valores de humedad con altos valores de LAI, lo que es poco probable que ocurra con el pastizal, en donde la pérdida de LAI es bastante paralela a la de la humedad). A partir de los valores de FMC medidos en campo y del LAI extraído del producto MODIS, obtuvimos una buena relación lineal entre ambos parámetros ( $r^2=0.925$ ), lo que permitió aplicar una sencilla regla para eliminar de la simulación situaciones poco realistas.

$R_{\min} > LAI_{LUT} - LAI_{est} < R_{\max}$  (5), donde  $LAI_{LUT}$  y  $LAI_{est}$  son, respectivamente, el LAI simulado en la LUT y el estimado a partir de la ecuación FMC-LAI, mientras  $R_{\max}$  y  $R_{\min}$  son los residuales máximos y mínimos de dicha ecuación para el periodo considerado (2004 y 2005). Eliminados esos casos de las simulaciones iniciales, contábamos con 2270 para el ajuste por regresión, siguiendo la misma metodología comentada en el ajuste empírico.

Finalmente, se validaron sendas ecuaciones de estimación de FMC obtenidas por regresión (empírica y teórica), con el 40 % de los datos recogidos en campo reservados para dicho objetivo. Se comparó así la exactitud de las estimaciones de una y otra metodología, según el  $r^2$ , el residual relativo (6) y la pendiente del ajuste entre valores de FMC observados o simulados y valores de FMC estimados con sus respectivas ecuaciones.

$$RR = \frac{Estimado - Observado}{Observado} \quad (6)$$

### 3. RESULTADOS:

En la tabla 3 se incluyen los coeficientes de Pearson entre los datos MODIS y los valores de FMC de campo y simulados mediante RTM. Es interesante anotar que las tendencias son similares, con correlaciones elevadas para las bandas 1 (rojo), 3 (verde) y las ubicadas en el infrarrojo de onda corta (6 y 7). Destaca la diferencia entre la banda 5 real y la simulada, lo que puede ser debido al problema radiométrico que presenta el sensor MODIS en esta banda, al parecer debido a un problema en la corrección atmosférica de los datos (Stow, Niphadkar et al. 2005). Lo contrario puede afirmarse de la banda 4, en donde los datos reales MODIS ofrecen correlaciones más altas que los simulados.

**Tabla 3. Coeficientes de correlación de Pearson entre los datos MODIS y los valores de FMC (empíricos y simulados en la LUT).**

MODIS	FMC <sub>observado</sub>	FMC <sub>LUT</sub>
B3	<b>-0.725</b>	<b>-0.621</b>
B4	<b>-0.680</b>	<b>-0.195</b>
B1	<b>-0.816</b>	<b>-0.710</b>
B2	<b>0.540</b>	<b>0.215</b>
B5	<b>-0.241</b>	<b>-0.637</b>
B6	<b>-0.768</b>	<b>-0.799</b>
B7	<b>-0.771</b>	<b>-0.793</b>
D <sub>3,4</sub>	-0.260	<b>-0.415</b>
D <sub>4,1</sub>	<b>-0.667</b>	<b>-0.769</b>
D <sub>1,2</sub>	<b>0.901</b>	<b>0.612</b>
D <sub>2,5</sub>	<b>-0.900</b>	<b>-0.913</b>
D <sub>5,6</sub>	<b>-0.812</b>	<b>-0.884</b>
D <sub>6,7</sub>	<u>0.444</u>	<b>0.615</b>
Integral	<b>-0.810</b>	<b>-0.783</b>
NDII <sub>6</sub>	<b>0.887</b>	<b>0.902</b>
NDWI	<b>0.859</b>	<b>0.915</b>
GVM <sub>6</sub>	<b>0.890</b>	<b>0.887</b>
EVI	<b>0.945</b>	<b>0.721</b>
GEMI	<b>0.896</b>	<b>0.554</b>
VARI	<b>0.623</b>	<b>0.812</b>
NDVI	<b>0.952</b>	<b>0.792</b>
SAVI	<b>0.933</b>	<b>0.788</b>
Muestras	n=40	n=2270

Respecto a los índices, los coeficientes son todos significativos al 99%, excepto la primera derivada entre las bandas 3 y 4 (no significativa) y la primera derivada entre las bandas 6 y 7 (significativa al 95%) del conjunto de datos empíricos. En general, se observa que para estos, los índices de verdor NDVI, SAVI y EVI son los que presentan mayores coeficientes de correlación (todos mayores que 0.9), mientras que los índices de contenido de humedad, presentan coeficientes menores que 0.9. Estos resultados son consistentes con los obtenidos con otros sensores en la misma zona de estudio (Chuvieco, Riaño et al. 2002). Sin embargo, para los datos simulados desde RTM, los coeficientes de Pearson más elevados coinciden con los índices que realzan las bandas de absorción de agua (SWIR), especialmente el NDII<sub>6</sub> y el NDWI. Las derivadas entre bandas continuas del MODIS presentan coeficientes de correlación similares para los

dos conjuntos de datos, lo que sorprende en el caso de la derivada entre la banda 5 y 2 ya que dichas bandas presentan coeficientes de correlación diferentes con los datos de FMC observados o los datos simulados.

En lo que al análisis de regresión múltiple, la variable seleccionada para el análisis empírico fue el NDVI con un ajuste final con coeficiente de determinación significativo de 0.907 y un error típico de la estimación de 30.10% de FMC.

$$FMC_{PASTO} = -161.112 + 650.226 \times NDVI \quad (6)$$

La ecuación para los datos simulados que incluyen otras bandas consigue un coeficiente de determinación inferior alto ( $r^2 = 0.861$ ) y un error típico de la estimación bastante bajo (25,78 %).

$$FMC_{PASTO} = -102.16 + 428.62 \times NDII + 673.98 \times B2 \quad (7)$$

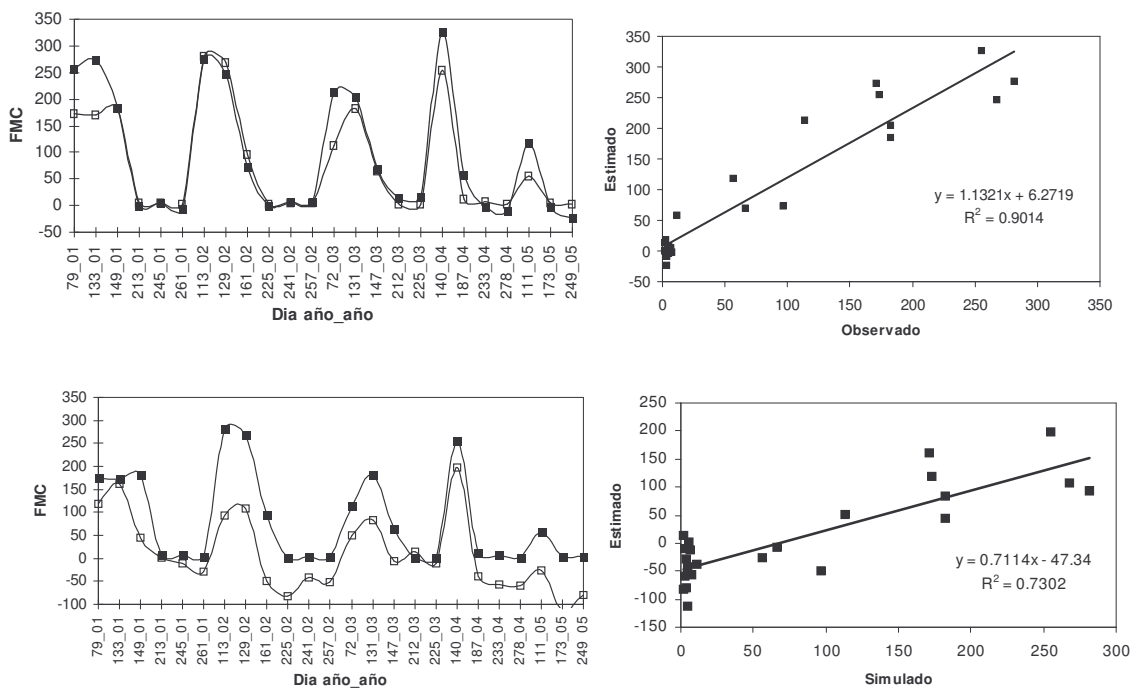


Figura 3. Valores observados (cuadrados negros) y estimados (cuadrados sin color).

En la figura 3 se muestran los valores observados y estimados con las ecuaciones 6 y 7 para la muestra de validación. Cuando se emplea la ecuación empírica para la estimación del FMC del pasto, la relación es cercana a 1:1 y con una ordenada en el origen mayor que cero, lo que indica una ligera tendencia a la sobreestimación. Respecto a los residuales, cabe destacar que los residuos tipificados resultantes de la estimación del pasto siguen una distribución normal con una media muy cercana a cero y una desviación típica de 0.98. En términos relativo, los errores máximos están en torno al 8% del FMC. Por su parte, la relación para los datos simulados se aleja más de la ideal 1:1, la ordenada en el origen es negativa lo que indica que el modelo subestima. Los residuales del modelo ofrecen valores más altos, algunos muy extremos, con errores de estimación máximos del -49.42% del FMC.

#### 4. CONCLUSIONES

Se presentan los primeros resultados que comparan la eficacia de los métodos empíricos frente a los basados en simulación de la señal (RTM) para estimar el contenido de humedad del pastizal en ámbitos mediterráneos. Mientras los modelos empíricos resultan muy asequibles de obtener y tienen una precisión conocida, los basados en RTM resultan complejos de calibrar, si bien presentan un mayor potencial para la generalización. Para el ejemplo concreto de la estimación del FMC del pastizal, los modelos empíricos han ofrecido mejores ajustes con la muestra de validación, extraída de distintos periodos a lo largo de la serie de cinco años utilizada en nuestro estudio. Habrá que verificar si en otra zona diferente a la de calibrado sigue siendo mejor el modelo empírico o el teórico le supera, de ser así se confirmaría la mayor capacidad de generalización. En la tabla 4 se hace un balance global del interés de estos modelos, frente a las limitaciones que presentan. En futuros trabajos pretendemos explorar con mayor detalle esas posibilidades.

MODELO	TEÓRICOS	EMPIRICOS
DIFICULTAD	Alta El procesamiento de las muestras recogidas en campo para la obtención de los parámetros de entrada a los modelos es más complejo y laborioso (extracción de clorofila, obtención del área foliar, medidas de LAI) Se precisa alto conocimiento de programación para correr múltiples simulaciones y generar la LUT El mismo modelo no puede aplicarse a todo tipo de vegetación. Se precisa alto conocimiento de los modelos y sus asunciones para la selección de aquel que más concuerde con la realidad.	Baja Procesamiento de las muestras recogidas en campo sencillo. Las metodología (regresiones múltiples entre valores de FMC/dots de reflectividad) pueden ser aplicadas a cualquier tipos de vegetación.
TIEMPO REALIZACIÓN	Alto Obtención de la información auxiliar a los datos de reflectividad ya sea con trabajo de campo o búsquedas bibliográficas.  Procedimiento de inversión: <ul style="list-style-type: none"> <li>• Algoritmo iterativo alto tiempo de computación (no operativo)</li> <li>• LUT alto tiempo para su correcto diseño (parametrización, optimización tamaño y eliminación de combinaciones no reales)</li> </ul>	Alto/Medio Es necesario una serie lo suficientemente larga de medidas de FMC de campo para que las relaciones con las medidas satélite sean significativas. Alto número de imágenes a procesar Trabajo de campo más frecuente, en aquellos meses en los que la variación del contenido de humedad es mas drástico (abril a junio). Si se quiere aplicar a otras zonas diferentes a las de calibrado, se deben realizar muestreos de FMC para la validación de los modelos, lo que supone una inversión en tiempo adicional (desplazamiento, localización de parcelas)
COSTE ECONÓMICO	Medio Los muestreos para la obtención de la variación de los parámetros son menos frecuentes (15 días) Algunos parámetros se pueden obtener de bibliografía o de experimentos controlados en laboratorio sin necesidad de desplazarse a campo.	Alto Es necesario realizar muestreos de FMC frecuentes para la calibración y en lugares distantes para la validación, lo que conlleva gastos de desplazamiento, dietas y, en algún caso, alojamiento.

MODELO	TEÓRICOS	EMPIRICOS
INFORMACIÓN AUXILIAR a datos reflectividad que pueden mejorar las estimaciones	Análisis Lineal de Mezclas Espectrales en zonas heterogéneas de vegetación para sacar la proporciones de los diferentes tipos de vegetación y de partes no fotosintéticas.	
	<p>Conocimiento de la vegetación sobre la que se va a aplicar el modelo y las propiedades ópticas asociadas a la misma para la correcta selección del modelo.</p> <p>Reflectividad y transmisibilidad de una hoja del dosel tomada individualmente, (radiometría y esfera de integración) ahorraría el estimar todos los parámetros de entrada a Prospect y se podrían usar directamente como entrada a Sailh.</p> <p>Geometría de observación</p> <p>Parámetros sobre la arquitectura del dosel considerado</p> <p>Aporte de la radiancia difusa por parte de la atmósfera</p> <p>Parámetros de definición de la superficie sobre la que se encuentra situado el dosel</p> <p>Variaciones de los parámetros de entrada, puede limitar la solución</p> <p>Combinaciones no reales de los parámetros de entrada</p>	<p>Ecuaciones del variación estacional del FMC en función del día del año</p> <p>Datos de temperatura de superficie</p>
PROBLEMAS A RESOLVER	Buscar soluciones en manchas heterogéneas de vegetación	
	<p>Pocas publicaciones con datos cuantitativos de campo de los parámetros de entrada para la validación y calibrado de los modelos.</p> <p>Falta de estudios de las geometrías de observación mas adecuadas para la inversión</p> <p>Estudio de los sesgos de los modelos y alguna metodología para tenerlos en cuenta en las estimaciones.</p> <p>Operatividad del procedimiento de inversión.</p> <p>Eliminación de combinaciones no reales de los parámetros de entrada.</p>	<p>Intercambio científico de datos de FMC para validar. Se han realizado ajustes por muy diversos equipos de investigación y en diversas zonas. Se deberían realizar un intercambio de datos de FMC para validar los modelos que cada uno ha calibrado en sus respectivas zonas de estudio ya que realizar trabajos de campo para validación son muy costosos.</p>

**Tabla 4: Balance global sobre el interés y los problemas que plantean los RTM en la estimación del contenido de agua en vegetación mediterránea.**

## 5. REFERENCIAS

- Brown, A. A. and D. P. Kenneth (1979). Fire Danger Rating. *Forest Fire Control and Use*. A. A. Brown and K. P. Davis. New York, Mc Graw-Hill, Book Company: 217-235.
- Burgan, R. E., R. W. Klaver et al. (1998). "Fuel models and fire potential from satellite and surface observations." *International Journal of Wildland Fire* 8(3): 159-170.
- Camia, A., B. Leblon, et al. (2003). Methods Used to Estimate Moisture Content of Dead Wildland Fuels. *Wildland Fire Danger Estimation and Mapping. The Role of Remote Sensing Data*. E. Chuvieco. Singapore, World Scientific Publishing. Series in Remote Sensing, vol. 4: 91-117.

- Ceccato, P. (2001). *Estimation of vegetation water content using remote sensing for the assessment of fire risk occurrence and burning efficiency*. *Phylosophy*. Greenwich, University of Greenwich: 168.
- Ceccato, P., N. Gobron, et al. (2002). "Designing a spectral index to estimate vegetation water content from remote sensing data: Part 1 Theoretical approach." *Remote Sensing of Environment* 82: 188–197.
- Chuvieco, E., D. Cocero, et al. (2004). "Improving Burning Efficiency Estimates through Satellite Assessment of Fuel Moisture Content." *Journal of Geophysical Research - Atmospheres* 109, D14S07, doi:10.1029/2003JD003467: 1-8.
- Chuvieco, E., D. Cocero, et al. (2004). "Combining NDVI and Surface Temperature for the estimation of live fuel moisture content in forest fire danger rating." *Remote Sensing of Environment* 92: 322–331.
- Chuvieco, E., D. Riaño, et al. (2002). "Estimation of fuel moisture content from multitemporal analysis of Landsat Thematic Mapper reflectance data: applications in fire danger assessment." *International Journal of Remote Sensing* 23(11): 2145-2162.
- Combal, B., F. Baret, et al. (2002). "Retrieval of canopy biophysical variables from bidirectional reflectance Using prior information to solve the ill-posed inverse problem." *Remote Sensing of Environment* 84: 1-15.
- Danson, F. M., M. D. Steven, et al. (1992). "High-espectral resolution data for determining leaf water content." *International Journal of Remote Sensing* 13(3): 461-470.
- Dennison, P. E., A. Roberts Dar, et al. (2005). "Use of Normalized Difference Water Index for monitoring live fuel moisture content." *International Journal of Remote Sensing* 26(5): 1035-1042.
- Desbois, N., M. Deshayes, et al. (1997). Protocol for fuel moisture content measurements. *A review of remote sensing methods for the study of large wildland fires*. E. Chuvieco. Alcalá de Henares, Departamento de Geografía, Universidad de Alcalá: 61-72.
- Fensholt, R. and I. Sandholt (2003). "Derivation of a shortwave infrared water stress index from MODIS near- and shortwave infrared data in a semiarid environment." *Remote Sensing of Environment* 87: 111-121.
- Gao, B. C. (1996). "NDWI. A normalized difference water index for remote sensing of vegetation liquid water from space." *Remote Sensing of Environment* 58: 257-266.
- Huete, A., K. Didan, et al. (2002). "Overview of the radiometric and biophysical performance of the MODIS vegetation indices." *Remote Sensing of Environment* 83(1-2): 195–213.
- Huete, A. R. (1988). "A soil-adjusted vegetation index (SAVI)." *Remote Sensing of Environment* 25: 295-309.
- Hunt, E. R. and B. N. Rock (1989). "Detection of changes in leaf water content using near and middle-infrared reflectances." *Remote Sensing of Environment* 30: 43-54.
- Jackson, T. J., D. Chen, et al. (2004). "Vegetation water content mapping using Landsat data derived normalized difference water index for corn and soybeans." *Remote Sensing of Environment* 92(4): 475-482.

- Jacquemoud, S. (1990). "PROSPECT: a model to leaf optical properties spectra." *Remote Sensing of Environment* 34: 74-91.
- Jacquemoud, S. (1993). "Inversion of the PROSPECT+SAIL canopy reflectance model from AVIRIS equivalent spectra: theoretical study." *Remote Sensing of Environment* 44: 281-292.
- Justice, C. O., J. R. G. Townshend, et al. (2002). "An overview of MODIS Land data processing and product status." *Remote Sensing of Environment* 83: 3-15.
- Kogan, F., A. Gitelson, et al. (2003). "AVHRR-Based spectral vegetation index for quantitative assessment of vegetation state and productivity: calibration and validation." *Photogrammetric Engineering and Remote Sensing* 69(8): 899-906.
- Mbow, C., K. Goïta, et al. (2004). "Spectral indices and fire behavior simulation for fire risk assessment in savanna ecosystems." *Remote Sensing of Environment* 91: 1-13.
- Pinty, B. and M. M. Verstraete (1992). "GEMI: a non-linear index to monitor global vegetation from satellites." *Vegetation* 101: 15-20.
- Privette, J. L., W. J. Emery, et al. (1996). "Inversion of a Vegetation Reflectance Model with NOAA AVHRR Data." *Remote Sensing of Environment* 58: 187-200.
- Riaño, D., P. Vaughan, et al. (2005). "Estimation of Fuel Moisture Content by Inversion of Radiative Transfer Models to Simulate Equivalent Water Thickness and Dry Matter Content: Analysis at Leaf and Canopy Level." *IEEE Transactions on Geoscience and Remote Sensing* 43(4): 819-826
- Roberts, D. A., S. Peterson, et al. (2005). "Evaluation of AVIRIS and MODIS Measures of Live Fuel Moisture and Fuel Condition in a Shrubland Ecosystem in Southern California." *Submitted to Remote Sensing of Environment*.
- Rouse, J. W., R. W. Haas, et al. (1974). Monitoring the vernal advancement and retrogradation (Greenwave effect) of natural vegetation. Greenbelt, MD. USA, NASA/GSFC.
- Rueda, C. A. (2001). CSTARS Radiative Transfer Model Repository Project. Davis.
- Serrano, L., S. L. Ustin, et al. (2000). "Deriving Water Content of Chaparral Vegetation from AVIRIS Data." *Remote Sensing of Environment* 74: 570-581.
- Sims, D. A. and J. A. Gamon (2003). "Estimation of vegetation water content and photosynthetic tissue area from spectral reflectance: a comparison of indices based on liquid water and chlorophyll absorption features." *Remote Sensing of Environment* 84: 526-537.
- Slavik, B. (1974). *Methods for Studying Plant Water Relations*. Prague, Czechoslovak Academy of Sciences - Springer Verlag.
- SPSS (1999). *SPSS for Windows*.
- Van Wagner, C. E. (1967). Seasonal variation in moisture content of Eastern Canadian tree foliage and the possible effect on crown fires, *Forestry Branch, Canada*: 15.
- Verhoef, W. (1984). "Light scattering by leaf layers with application to canopy reflectance modeling: the SAIL model." *Remote Sensing of Environment* 16: 125-141.
- Vermote, E. F. and A. Vermeulen (1999). Atmospheric correction algorithm: Spectral Reflectances (MOD09), NASA: 109 pp.

- Weiss, M., Baret, F., Myneni, R.B., Pragnère, A., Knyazikhin, Y. (2000). "Investigation of a model inversion technique to estimate canopy biophysical variables from spectral and directional reflectance data." *Agronomie* 20: 3-22.
- Wellburn, A. R. (1994). "The Spectral Determination of Chlorophylls a and b, as well as Total Carotenoids, Using Various Solvents with Spectrophotometers of Different Resolution." *Journal of Plant Physiology* 144: 307-313.
- Woodcock, C. E. and A. H. Strahler (1987). "The factor of scale in remote sensing." *Remote Sensing of Environment* 21: 311-332.
- Zarco Tejada, P. J. and L. Ustin Susan (2001). *Modeling Canopy Water Content for Carbon Estimates from MODIS data at Land EOS. Validation Sites*. IGARRS Meeting, Sydney, Australia.
- Zarco-Tejada, P. J., C. A. Rueda, et al. (2003). "Water content estimation in vegetation with MODIS reflectance data and model inversion methods." *Remote Sensing of Environment* 85: 109-124