

Comparación de Modelos Empíricos y de Transferencia Radiativa para Estimar Contenido de Humedad en Pastizales: Poder de Generalización.

Comparison of Empirical and Radiative Transfer Models for Water Content Estimation in Grassland: Generalizing Power

M. Yebra, E. Chuvieco e I. Aguado
marta.yebra@uah.es

Universidad de Alcalá
Calle Colegios, 2, 28801 Alcalá de Henares (Madrid)

Recibido el 12 de diciembre de 2007, aceptado el 19 de mayo de 2008

RESUMEN

El contenido de humedad de la vegetación (FMC) es una variable clave de diversas aplicaciones, muchas de las cuales precisan un conocimiento a nivel global. Por ello, se precisa calibrar modelos de estimación del FMC con alta representatividad espacial y poder de generalización. La teledetección espacial se muestra como una de las fuentes de información más idónea al respecto. Existen principalmente dos tipos de modelos que relacionan información extraída de imágenes satélite con el FMC: empíricos y teóricos. Los primeros son muy dependientes de los datos usados en la calibración y las condiciones bajo las cuales se tomaron, por lo que tienen escaso poder de generalización. Los teóricos, tienen una fuerte base física (generalmente la teoría de transferencia radiativa, de ahí que se denominen modelos de transferencia radiativa, RTM) por lo que permiten aplicarse a muy diversas condiciones. Sin embargo, para obtener estimaciones precisas, estos modelos deben ser adecuadamente parametrizados con datos de campo y considerar información auxiliar, lo que podría comprometer su potencial de generalización. El objetivo de este trabajo es comparar el modelo empírico y el RTM propuesto por Yebra *et al.* (2008) en términos de poder de generalización. Para ello, se ha

ABSTRACT

Fuel Moisture Content (FMC) is a key variable in various applications, many of which require a global knowledge. Because of that, the calibration of highly generalizing power models to estimate this variable is required. Remote sensing is one of the sources of information more suitable in that respect. There mainly exists two main kinds of models who relate remote sensed data to FMC: empirical and theoretical. The empirical models are highly dependent of the data used in the calibration phase and the conditions under which that data was collected. Therefore, these models have low generalizing power. The RTM have a strong physical (generally the radiative transfer theory, that is why they are so-called Radiative Transfer Models, RTM) so they can be applied to more diverse range of conditions. However, if accurate estimations want to be obtained, they must be properly parameterized with field data and include auxiliary information, what may affect their generalizing potential. The objective of this paper is to compare the performance of the empirical model and the RTM proposed by Yebra *et al.* (2008) in terms of generalizing power. To do this, a validation sample of 92 observations of field measured FMC and their corresponding MODIS data was used. These dataset correspond to seven grassland

empleado una muestra de validación compuesta por 92 observaciones de FMC y datos radiométricos tomados por el sensor MODIS, correspondientes a seis zonas de validación (dos en España y cuatro en Australia). Los resultados obtenidos muestran que cuando los modelos se aplican a pastizales similares a los de la zona de calibrado, las precisiones del modelo empírico y RTM son similares (RMSE=41,39 y 43,44% frente 38,23 y 33,83%, para el modelo empírico y RTM, respectivamente). Sin embargo, cuando dichos modelos se aplican a zonas con pastizales de diferentes características o a periodos del año diferentes, el RTM supera en precisión al modelo empírico (RMSE=38,93 y 61,66% frente 11,27 y 19,37%, para el modelo empírico y RTM, respectivamente), lo que demuestra el mayor poder de generalización del RTM.

PALABRAS CLAVE: Contenido en agua, FMC, Modelos empíricos, Modelos de Transferencia Radiativa, Teledetección.

plots located in Spain and eight in Australia. The results show that both models offer similar accuracy levels when applying to grassland with analogous types of vegetation to the calibration site (RMSE=41.39 y 43.44% against 38.23 and 33.83%, empirical and RTM, respectively). Nevertheless, the RTM offers greater accuracy than the empirical when the models are applied to grassland with different characteristics to those of the calibration site (RMSE=38.93 y 61.66% against 11.27 y 19.37%, empirical and RTM, respectively), which supports the hypothesis that the RTM has more generalizing power.

KEYWORDS: Water content, FMC, Empirical models, Radiative Transfer Models, Remote sensing.

INTRODUCCIÓN

La estimación del contenido de humedad de la vegetación tiene múltiples aplicaciones. Por ejemplo, en el ámbito de la agricultura, resulta clave para mejorar la gestión del riego (Sepulcre-Cantó *et al.*, 2006). En el campo del análisis del riesgo de incendios, el contenido en humedad del combustible (FMC, del inglés *Fuel Moisture Content*, (1)) es una de las variables más importantes en la estimación de condiciones de peligro, ya que afecta a la ignición y posterior propagación del fuego (Burgan *et al.* 1998; Van Wagner 1967). Asimismo, el FMC afecta notablemente a la aplicación de algunos tratamientos preventivos, como la reducción del combustible mediante fuegos prescritos (Mbow *et al.* 2004), y es clave para mejorar la estimación de emisiones, ya que está relacionado con la intensidad de la quema (Chuvieco *et al.* 2004a)

$$(1) \quad FMC(\%) = \frac{P_f - P_s}{P_s} \times 100$$

donde Pf = peso fresco y Ps = peso seco.

Este amplio abanico de aplicaciones implica escalas de estudio desde locales y regionales a globales. Así por ejemplo, la planificación de una quema pres-

crita implica el conocimiento del FMC a nivel local o regional, mientras que el análisis del riesgo de incendio para el establecimiento de directrices de gestión a nivel internacional, precisa una estimación global. Por tanto, resulta fundamental disponer de métodos de estimación de FMC que puedan ser aplicables a cualquier escala (Strahler *et al.* 1986).

La teledetección espacial se muestra como una de las fuentes de información más idónea para abordar la estimación de variables de la vegetación a nivel global, ya que proporciona una observación planetaria, repetitiva y consistente de la cubierta vegetal (Chuvieco 2008). Debido a que disminuciones en el FMC de los combustibles vivos tienen efectos directos e indirectos en la forma en la que éstos reflejan o emiten energía, imágenes de satélite tomadas por sensores remotos pueden ser empleadas para estimar FMC. Generalmente, los datos de la imagen más empleados para estimar FMC son índices de vegetación diseñados para minimizar la influencia de perturbaciones como las debidas al suelo y a las condiciones atmosféricas. Estos índices habitualmente se clasifican en:

- (i) *Índices de humedad*, basados en los efectos directos que una disminución del FMC tiene sobre la reflectividad y, por tanto, computados a partir del infrarrojo de onda corta (SWIR, del inglés *Short Wave Infrared*, 1,2 a 2,2 μm), donde el agua

presenta una fuerte absorción y el infrarrojo cercano (IRC, 0,7 a 1 μm) que se utiliza para normalizar, ya que es relativamente insensible al agua (Ceccato *et al.* 2002b; Gao 1996).

- (ii) *Índices de verdor*, basados en los efectos indirectos que una disminución en el FMC tiene sobre el contenido en clorofila de la vegetación y, por tanto, computados a partir de las bandas del rojo (0,6 a 0,7 μm) y el infrarrojo cercano (IRC, 0,7 a 1 μm), donde la clorofila tiene alta y baja absorptividad, respectivamente.

Ahora bien, es preciso obtener algún modelo que relacione estos índices extraídos de la imagen con el FMC. Existen principalmente dos tipos de modelos: empíricos y teóricos. En los últimos años se han publicado numerosos trabajos que utilizan modelos empíricos calibrados con medidas de FMC en campo y datos de reflectividad o índices de vegetación derivados de sensores remotos de alta resolución radiométrica o espacial (Chuvieco *et al.* 2002; Colombo *et al.* 2008; Jackson *et al.* 2004). También se han empleado imágenes de baja resolución espacial pero alta frecuencia, como las adquiridas por el AVHRR (del inglés *Advanced Very High Resolution Radiometer*) del satélite NOAA (Chuvieco *et al.* 2004b; Kogan *et al.* 2003) y, más recientemente, el MODIS (del inglés *Moderate Resolution Imaging Spectrometer*), a bordo de los satélites Terra y Aqua (Dennison *et al.* 2005). No obstante, el principal problema de estos modelos empíricos es su escaso poder de generalización, ya que son muy dependientes de los datos usados en la calibración y las condiciones bajo las cuales se tomaron. En este sentido, Roberts *et al.* (2006) demostraron que el ajuste lineal entre valores de FMC de especies de matorral de California y diversos índices derivados de imágenes MODIS variaba considerablemente dependiendo del tipo de vegetación dominante en la zona y las características climáticas del año considerado. Por ello, para poder obtener un modelo empírico generalizable sería necesario disponer de bases de datos de FMC globales que incluyesen la mayor cantidad posible de condiciones (años húmedos/secos, diferentes especies, etc.), lo que resulta muy complejo teniendo en cuenta el alto esfuerzo y presupuesto que precisa llevar a cabo muestreos de FMC. Por tanto, el empleo de modelos empíricos queda limitado a aplicaciones locales o regionales.

Los modelos teóricos pretenden establecer relaciones de validez general, lo más independiente posible de unas determinadas condiciones, a partir de la re-

lación física entre el FMC y la radiancia de la imagen. Por ello, tienen una fuerte base física y permiten aplicarse (adecuadamente parametrizados) a muy diversas condiciones (Privette *et al.* 1996). Dentro de la amplia gama de modelos desarrollados (Goel 1988), los más empleados son aquellos basados en la ecuación de transferencia radiativa (RTM, del inglés *Radiative Transfer Models*). 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. Tanto de forma directa como inversa, los RTM se han empleado en los últimos años para estimar contenido en humedad de la vegetación (Zarco-Tejada *et al.* 2003; Ceccato *et al.* 2002a). Generalmente, la forma directa ayuda a diseñar nuevos índices de vegetación sensibles a variaciones en el FMC, que posteriormente pueden ser utilizados para la estimación de dicha variable. 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. Ahora bien, para que dicho ajuste sea correcto y la estimación precisa, se debe emplear información auxiliar para controlar alguno de los parámetros del modelo, ya que, por naturaleza, la inversión no es singular (un determinado valor de reflectividad puede obtenerse a partir de distintas combinaciones de parámetros de entrada la inversión).

En resumen, cada modelo tiene sus ventajas e inconvenientes, por lo que resulta necesario realizar una comparación para verificar qué modelo es más robusto y preciso cualquiera que sea la zona de estudio en el que se aplique, es decir qué modelo es generalizable a otras áreas.

Yebra *et al.* (2008) compararon las estimaciones de FMC obtenidas con modelos empíricos y RTM para especies de pastizal y matorral mediterráneo mediante el empleo de datos de reflectividad del sensor MODIS. Dicha comparación se realizó en términos de robustez de los modelos calibrados y precisión de las estimaciones en 5 parcelas (3 de matorral y 2 de pastizal) ubicadas en el Parque Nacional de Cabaneros, (PNC). En lo que a la precisión de las estimaciones de FMC de pastizales se refiere, los autores concluyeron que sendos modelos proporcionan estimaciones de precisión similar (RMSE de 28,39 y 24,57%, empírico y RTM, respectivamente), si bien

el RTM tiende a subestimar el FMC mientras que el modelo empírico a sobreestimar. También señalaron que en los periodos estivales con $FMC < 30\%$, los modelos pueden estimar valores de FMC negativos que deben ser filtrados. Estas estimaciones negativas no fueron consideradas defectos del modelo debido a que con $FMC < 30\%$ los pastos se consideran combustible muerto y por lo tanto, la estimación del FMC debería llevarse a cabo mediante técnicas más adecuadas para este tipo de combustibles como el uso de índices meteorológicos (Aguado *et al.* 2007).

En consecuencia, Yebra *et al.* (2008) demostraron que el RTM estima el FMC de pastizales con precisión similar a los modelos empíricos, si bien las subestimaciones del primero eran preferibles a las sobrestimaciones del segundo, sobretudo desde el punto de vista de la estimación de condiciones de riesgo de incendio. Sin embargo, no verificaron si dicha afirmación seguía siendo cierta al validar los modelos en zonas de diferentes características a la de calibrado, lo que tampoco ha sido verificado en ningún otro trabajo.

El objetivo de este estudio es comparar los modelos empíricos y RTM calibrados en el citado trabajo en términos de poder de generalización empleando para ello mediciones de FMC y datos radiométricos tomados en zonas de pastizales caracterizadas por diferente composición de especies y estructura y durante diferentes estaciones del año. El objetivo final es determinar que modelo es el más adecuado para desarrollar una metodología global, operativa y precisa de estimación de FMC de pastizales.

MATERIAL Y MÉTODOS

Modelo empírico y RTM de estimación de FMC.

Para la estimación del FMC se ha seleccionado el modelo empírico y RTM propuesto por Yebra *et al.* (2008) para coberturas de pastizal.

El modelo empírico (2) fue calibrado mediante un análisis de regresión lineal múltiple entre valores de FMC y diversos índices de vegetación derivados de imágenes Terra-MODIS. Dichos valores fueron tomados en tres parcelas de pastizal ubicadas en el PNC durante los años 2001-2005 y los meses abril-septiembre (tabla 1).

$$(2) \quad FMC_{EMPIRICO} = -161,112 + 650,226 \times NDVI$$

donde NDVI (del inglés, *Normalized Difference Vegetation Index*) es un índice de verdor formulado como (Rouse *et al.* 1974):

$$NDVI = \frac{IRC - R}{IRC + R}$$

Por su lado, para establecer la relación teórica entre FMC e información radiométrica, se seleccionaron los modelos PROSPECT (Jacquemoud 1990) y SAILH (Verhoef 1984). El primero es un RTM que simula la reflectividad y transmisividad de la hoja en el espectro solar (entre 400 y 2500 nm.) a partir de cuatro parámetros de entrada (N, parámetro estructural; C_{a+b} , contenido en clorofila a y b; EWT, espesor equivalente de agua y DMC, contenido en materia seca). El segundo, permite simular la reflectividad a nivel de dosel teniendo en cuenta la reflectividad y transmisividad de la hoja (simulada por PROSPECT), la reflectividad del suelo, el índice de área foliar (LAI, del inglés *Leaf Area Index*), la distribución angular de las hojas (LADF, del inglés *Leaf Angle Distribution Function*), el aporte de radiancia difusa por parte de la atmósfera y los ángulos de observación e iluminación.

Los modelos PROSPECT y SAILH fueron calibrados para la estimación de FMC en tres etapas:

- *Parametrización* o definición del rango de variación de cada uno de los parámetros de entrada en base a mediciones realizadas en el PNC y otros valores de referencia encontrados en la bibliografía.
- *Uso directo* de los modelos para simular, dentro del rango anteriormente definido para cada parámetro, tantos espectros como combinaciones posibles entre parámetros.
- *Análisis de regresión lineal múltiple* con los datos simulados. En este caso el FMC correspondiente a cada espectro simulado fue calculado a partir de los parámetros EWT y DMC del modelo PROSPECT (3). Como variables independientes se consideraron la reflectividad simulada, diversos índices de vegetación derivados y el LAI. Este último parámetro del modelo SAILH se consideró en el ajuste con el objetivo de disminuir la posibilidad de estimaciones no singulares.

$$(3) \quad FMC(\%) = \frac{EWT}{DMC} \times 100$$

El modelo finalmente derivado de los RTM fue el siguiente:

$$(4) \quad FMC_{RTM} = -6,74 + 296,751 \times NDII_6 + 131,41 \times LAI$$

donde NDII₆ (del inglés, *Normalized Difference Infrared Index*) es el índice de humedad formulado como (Hunt y Rock 1989):

$$NDII_6 = \frac{IRC - SWIR}{IRC + SWIR}$$

Cabe resaltar que, si bien sendos modelos parecen similares, hay dos diferencias fundamentales:

- (i) El ajuste de los coeficientes del RTM tiene base física (la teoría de transferencia radiativa), ya que se realizó mediante un análisis de regresión múltiple con datos simulados con los modelos PROSPECT y SAILH, mientras que los coeficientes del modelo empírico, tienen base empírica por realizarse con datos de FMC y radiométricos observados.
- (ii) La estimación de FMC mediante el modelo empírico es indirecta y basada en cambios en el Ca+b que se producen cuando el pasto varía su FMC, ya que considera un índice de verdor, mientras que la estimación con el RTM, es directa y, en principio únicamente basada en cambios en el FMC per se, ya que incluye un índice de humedad y el LAI.

Parcelas y zonas de validación

Se localizaron 7 parcelas de pastizal en España y 8 en Australia todas ellas en zonas relativamente llanas y con extensión suficiente como para ser representativas de observaciones satélite de sensores de baja resolución espacial (tabla 1).

De las siete parcelas ubicadas en España, tres se encuentran en la Comunidad Autónoma de Castilla y León (CL), en las provincias de Ávila y Segovia, y cuatro en la Comunidad Autónoma de Madrid (CAM), lo que implica un alejamiento de 200 a 500 km. de la zona de calibrado de los modelos (PNC). Por su lado, las ocho parcelas de pastizales australianos, están ubicadas en los estados de Nueva Gales del Sur (NSW, del inglés *New South West*), Australia Occidental (WA, del inglés *Western Australia*) y en el Territorio de la Capital Australiana (ACT, del inglés *Australian Capital Territory*).

Con el objetivo de simplificar la presentación e interpretación de los resultados, las 15 parcelas fueron agrupadas en seis zonas de validación, en función del tipo de pastizal (similar composición de especies

y estructura) y la cercanía (similitud en cuanto a condiciones climáticas dentro de una misma zona). En la tabla 2 se presenta una breve descripción de las parcelas agrupadas en cada zona.

De esta manera, se contó con un abanico de pastizales suficientemente diverso como para llevar a cabo el ejercicio de validación.

Muestreos de campo

Los muestreos de campo en las zonas de validación 1 y 2 (España) fueron realizados en el marco del proyecto Firerisk del Grupo de Investigación en Teledetección Ambiental de la Universidad de Alcalá (<http://www.geogra.uah.es/firerisk/index.html>, mayo 2008) durante los años 2001 y 2002 y los meses de abril a septiembre. Todos los muestreos fueron realizados bajo el mismo protocolo seguido en el PNC. De esta forma, cada 8 ó 16 días y a la hora de mínimo FMC (entre las 12:00 y las 16:00 horas), se recolectaron tres muestras de pastizal de peso comprendido entre 50 y 100 gr. Las muestras así recogidas se introdujeron en sobres de papel, y se pesaron en campo (peso fresco). 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). Una descripción más detallada del trabajo de campo realizado puede encontrarse en (Chuvieco *et al.* 2004b).

Por su lado, los muestreos de FMC en los pastizales australianos (zonas de 3 a 6) fueron llevados a cabo durante los años 2006 y 2007 en el marco del proyecto de seguimiento de la senescencia del pasto ("*Grassland Curing Project*") por el Grupo de Investigación en Incendios Forestales del "CSIRO Forest Biosciences" (Canberra, ACT, Australia). En este caso, las muestras fueron recogidas durante los periodos de septiembre a marzo (primavera y verano en el hemisferio sur) en las zonas 3 y 4, y Abril a agosto (otoño e invierno) en las zonas 5 y 6. El protocolo de muestreo seguido en este proyecto fue similar al anteriormente explicado (frecuencia y hora de los muestreos, cantidad de muestras recogidas, tiempo de secado, cómputo de FMC, etc.) diferenciándose únicamente en que, en este caso, las muestras fueron recogidas en recipientes herméticos y pesadas en fresco en el laboratorio.

En consecuencia, el disponer de datos de FMC de 4 años y estaciones diferentes a las de calibrado permitió también verificar el poder de generalización de los modelos, a otras condiciones climáticas.

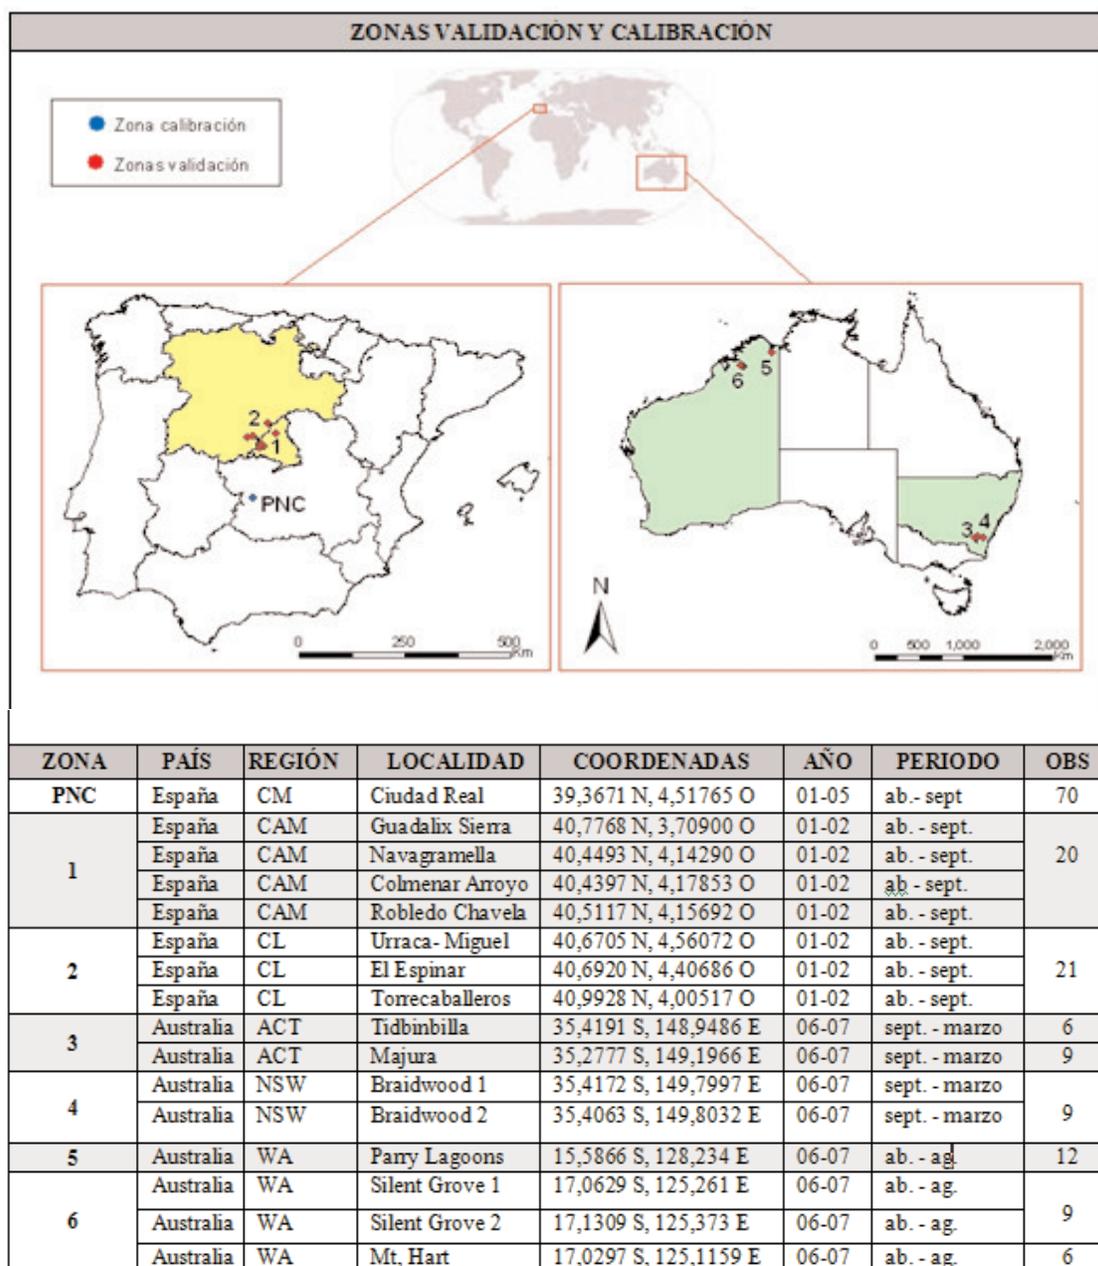


Tabla 1. Localización de las zonas de validación y calibración y descripción de los muestreos de campo.

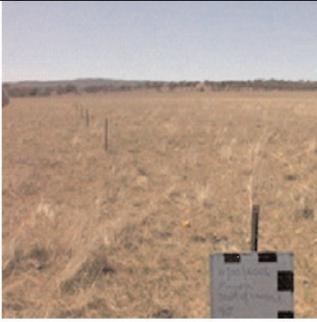
ZONA CALIBRACIÓN (PNC)		
Pastizales terofíticos constituidos mayoritariamente por especies anuales y adeshados con encinas.		
Abril 2005	Mayo 2005	Agosto 2005
		
ZONAS VALIDACIÓN		
ZONA 1 (Navalagamella, septiembre 2001) Pastizales similares a los del PNC si bien con mayor cobertura de encinas.	ZONA 2 (El Espinar, septiembre 2001) Pastizales de composición similar a los del PNC pero ocupando cultivos abandonados o barbechos (sin cobertura leñosa).	ZONA 3 (Majura, noviembre 2006) Pastizales pastoreados por canguros y con suelos ricos en nitrógeno. La fracción de cobertura es baja y las especies de pastizal son nitrófilas.
		
ZONA 4 (Braidwood, noviembre 2006) Pastizales similares a los de la zona 3 pero pastoreados por ganado vacuno. La fracción de cobertura es baja.	ZONA 5 (Parry Lagoons, mayo 2006) Pastizales similares a los del PNC si bien adeshados con eucaliptos.	ZONA 6 (Mt Hart Sandstone, mayo 2006) Pastizales similares a las de la zona 5 si bien alejados unos 370 km y con menor cobertura de eucaliptos.
		

Tabla 2. Descripción de las parcelas de la zona de calibrado (PNC) y las zonas de validación de los modelos. A modo ilustrativo, se muestra una fotografía de una de las parcelas de cada zona, excepto para la zona de calibrado que se muestran tres fotografías tomadas en tres fechas diferentes.

Imágenes satélite

Los datos radiométricos y de LAI necesarios para estimar FMC con los modelos anteriormente presentados se obtuvieron de los productos MOD09v004 (VerMOTE y VerMeulen 1999) y MOD15v004 (Knyazikhin *et al.* 1999) del sensor Terra-MODIS, respectivamente.

El producto MOD09 se trata de un compuesto de 8 días de las 7 primeras bandas de reflectividad del sensor MODIS (459-2155 nm) a 500m de resolución espacial, mientras que el MOD15 es también de un compuesto de 8 días pero a una resolución espacial de 1 km. El algoritmo de generación del producto de LAI está basado en la teoría de transferencia radiativa y en técnicas de inversión LUT (del inglés, *Look up Table*, tablas de referencia). El cómputo del LAI se realiza a partir de datos de reflectividad de las bandas 1 (rojo) y 2 (IRC) del producto MOD09 e información complementaria sobre las características de la superficie. Su solución es dependiente del tipo de vegetación y es sustituido por estimaciones empíricas en condiciones de observación extremas (<http://edcdaac.usgs.gov/modis/mod15a2v5.asp>, mayo 2008).

Sendos productos se descargaron del servidor LP DAAC (del inglés "*Land Processes Distributed Active Archive Center*") de la NASA y la agencia científica USGS (del inglés "*United States Geological Survey*") (<http://edcimswww.cr.usgs.gov/pub/ims-welcome/>, mayo 2008). Posteriormente, fueron re-proyectados de sinusoidal a UTM datum Europeo medio de 1950 (España) y WGS 84 (Australia). En el caso del producto LAI, las imágenes fueron además remuestreadas a una resolución 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 parcelas fueron extraídos de la imagen como la mediana de ventanas de 3 x 3 píxeles en torno al centro de cada parcela.

Validación

Previo al ejercicio de validación, se realizó un análisis exploratorio de los FMC medidos en las diferentes zonas.

Posteriormente, se estimaron los valores de FMC con el modelo empírico y RTM y se comprobó si di-

chas estimaciones seguían la tendencia estacional del pasto. Posteriormente se filtraron las estimaciones de FMC negativas y se compararon las exactitudes de las estimaciones basándose en coeficientes de determinación R^2 , pendiente y ordenada en el origen del ajuste lineal entre valores observados y estimados, así como en el error cuadrático medio (RMSE del inglés "*Root Mean Square Error*"). Este ejercicio de validación fue realizado por zonas con el objetivo de verificar si los modelos empíricos son únicamente generalizables a zonas de similares características a las de calibrado.

Posteriormente se realizó un ejercicio de validación global. El objetivo del mismo fue verificar si la precisión de las estimaciones con uno u otro modelo era dependiente del rango de FMC a estimar. Para ello, se ordenaron todas las observaciones en función del FMC observado y se agruparon en tres intervalos de FMC:

1. FMC >70%, este intervalo comprende valores de FMC en los que no es crucial que los modelos estimen FMC con alta precisión ya que a partir de dicho umbral, en aplicaciones de estimación de condiciones de riesgo la probabilidad de ignición es baja, mientras que en aplicaciones de gestión de riego en agricultura de precisión, la vegetación no muestra estrés.
2. 70% > FMC > 30%, este intervalo es crítico: la probabilidad de ignición y el nivel de estrés son altos, por lo que se deben detectar estas condiciones con la mayor precisión posible para tomar medidas al respecto.
3. FMC < 30%, este intervalo comprende las situaciones en las que el pastizal es considerado combustible muerto.

Dentro de cada intervalo, se calculó el RMSE entre valores observados y estimados con sendos modelos así como los residuales de cada estimación ($R = FMC_{\text{estimado}} - FMC_{\text{observado}}$). Debido a que los datos de FMC empleados para la validación presentaron un error de medida $\approx 22\%$ (cuantificado por la desviación típica de las tres réplicas de FMC tomadas para cada una de las parcelas y fecha), una estimación se consideró precisa siempre que $-22\% < RMSE \text{ ó Residual} < 22\%$.

RESULTADOS

Análisis exploratorio de los FMC de las zonas de validación

Las zonas de validación presentaron diversidad en cuanto a los contenidos de humedad de los pastizales (figura 1).

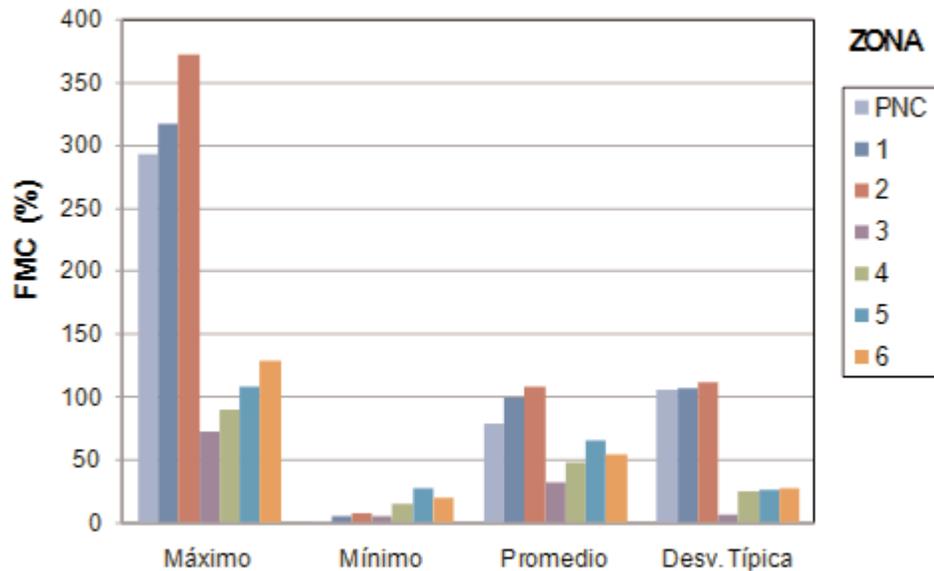


Figura 1. Resumen estadístico de los valores de FMC medidos en las zonas de validación y en la de cali-bración (PNC, años 2001-2002)

En primer lugar cabe mencionar la clara distinción entre los FMC de los pastizales ubicados en las zonas 1 y 2 (España) y aquellos ubicados en las zonas 3, 4, 5 y 6 (Australia). Los primeros, mostraron mayores FMC que los segundos. Así por ejemplo, las parcelas de la zona 1 y 2 registraron valores promedio de FMC de 108,38% y 99,59%, frente a valores promedios $\approx 50\%$ en el resto de las zonas. Por otro lado, las zonas 1 y 2 también presentaron los menores FMC mínimos y mayores desviaciones típicas que el resto de las zonas, lo que indica que presentaron mayor contraste estacional de FMC durante los periodos muestreados.

Los mayores FMC mínimos fueron registrados en las parcelas de las zonas 5 y 6, ya que éstas fueron muestreadas durante los periodos de otoño e invierno.

Merece la pena destacar que las zonas 1 y 2 presentaron FMC máximos, mínimos, promedios y desviaciones típicas, próximos a los medidos en el PNC para los mismos años y periodos, mientras que en el resto de zonas dichos valores fueron más distantes.

Validación por zonas

En líneas generales, sendos modelos estimaron correctamente la tendencia estacional del FMC de los pastizales de las 6 zonas (figura 2).

Así, en las zonas 1 y 2, los valores máximos se estimaron al comienzo de la primavera (alrededor del día 95) y los mínimos al final del periodo estival (a partir del día del año 193), lo que coincide con lo observado.

Las zonas 3 y 4, muestreadas durante los meses de septiembre a marzo presentaron también una tendencia hacia menores FMC durante la estación estival, si bien, el contraste fue menos acusado. Cabe destacar cómo, en la zona 3, el modelo empírico estima un incremento en FMC de primavera a verano (del día 9 al 281 del 2006), mientras que lo observado y estimado por el RTM es un decremento. Por su lado, en la zona 4 el modelo empírico estima mayores contrastes estacionales de FMC que los observados. Sin embargo, las estimaciones con el RTM se ajustan más a lo observado.

Para las zonas 5 y 6, muestreadas durante las estaciones de otoño e invierno, los máximos de FMC tanto observados como estimados con los modelos, coinciden con el periodo otoñal, mientras que los mínimos con la estación invernal. En la zona 6, estos contrastes no son tan claros, lo que queda bien reflejado por las estimaciones del RTM pero no por las del modelo empírico.

Respecto a la precisión de las estimaciones, el RTM resultó más preciso que el modelo empírico, independientemente de la zona de validación (tabla 3).

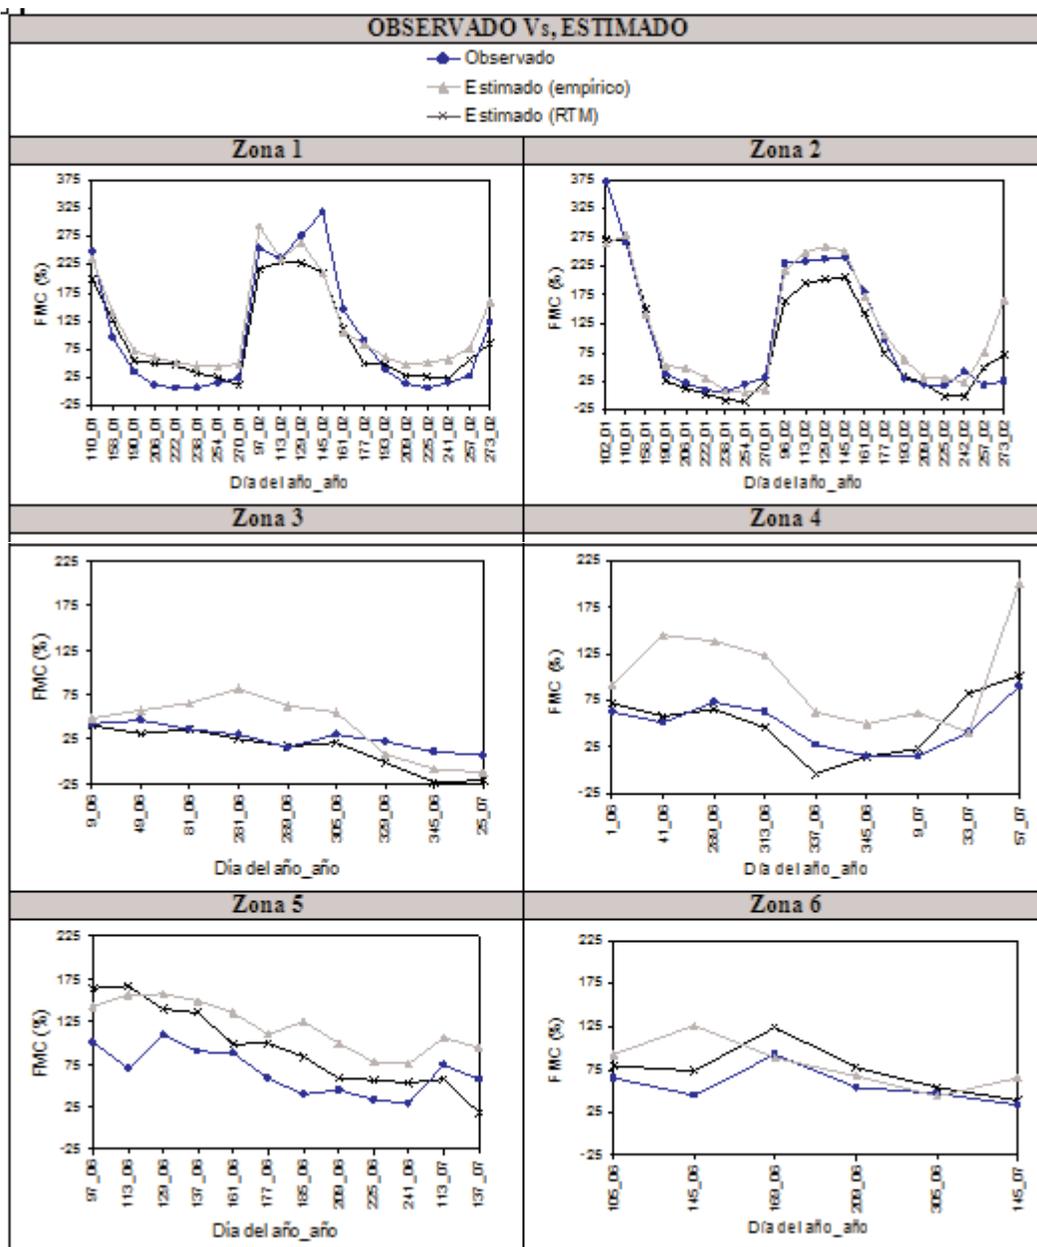


Figura 2. Evolución temporal de valores observados y estimados. Se muestran los valores promedio de FMC estimados y observados en las parcelas de cada una de las zonas.

ZONA	EMPÍRICO				RTM			
	R ²	Pendiente	Ordenada	RMSE(%)	R ²	Pendiente	Ordenada	RMSE(%)
1	0,90	0,74	42,96	41,39	0,92	0,70	22,99	38,23
2	0,85	0,82	29,35	43,44	0,93	0,77	12,74	33,83
3	0,56	1,56	9,81	38,93	0,84	0,84	0,03	11,27
4	0,75	1,79	14,06	61,66	0,66	0,9	11,72	19,37
5	0,67	0,75	59,62	55,23	0,48	1,25	11,87	43,85
6	0,05	0,30	43,81	15,35	0,92	0,68	-1,36	8,58

Tabla 3. Error cuadrático medio (RMSE) y ajuste lineal entre FMC observados y estimados para cada una de las zonas de validación. Las estimaciones negativas (18,48% del total de las estimaciones) fueron eliminadas para este análisis.

Los detalles para cada zona son:

Zona 1. Los coeficientes de determinación entre FMC observados y estimados fueron similares y elevados para sendos modelos ($R^2=0,9$ y $R^2=0,92$, empírico y RTM, respectivamente). No obstante, la recta de regresión fue más cercana a la ideal (1:1, pendiente ≈ 1 y ordenada en el origen ≈ 0) para las estimaciones con RTM, ya que, aunque las pendientes fueron $\approx 0,7$ para sendos modelos, la ordenada en el origen fue menor en el ajuste con los datos estimados con el RTM. A su vez, el RMSE también fue ligeramente menor para estas estimaciones.

Zona 2. El R^2 fue mayor para el RTM (0,93) que para el modelo empírico (0,85). Así mismo, la recta de regresión fue más cercana a la ideal para las estimaciones con el RTM ya que, como ocurría en el caso anterior, aunque la pendiente fue similar y cercana 1 en sendos casos ($\approx 0,8$), la ordenada en el origen fue más cercana a 0 en el caso de las estimaciones con el RTM. A su vez, el RMSE fue menor para las estimaciones con el RTM.

Zona 3. El R^2 fue mucho más fuerte, la recta de regresión más cercana a la ideal y el RMSE menor para las estimaciones realizadas con el RTM.

Zona 4. En esta zona el R^2 entre FMC observados y estimados fue mayor para el modelo empírico (0,75 y 0,66, empírico y RTM, respectivamente). Sin embargo, el RMSE fue mucho menor y la recta de regresión más cercana a la ideal para las estimaciones realizadas con el RTM.

Zona 5. El coeficiente de determinación R^2 fue mayor para el modelo empírico (0,67 y 0,48, empírico y RTM, respectivamente), mientras que el RMSE entre FMC observados y estimados menor y la recta de regresión más cercana a la ideal para las

estimaciones realizadas con el RTM. No obstante, cabe destacar que las estimaciones en esta zona arrojan los mayores RMSE independientemente del modelo empleado.

Zona 6. Tanto el R^2 como la relación lineal entre observados y estimados y los RMSE fueron más óptimos para las estimaciones realizadas con el RTM.

Validación global

La precisión de las estimaciones con el modelo empírico fue baja en todos los intervalos de FMC, ya que los RMSE fueron mayores a 22% (error de medición) (tabla 4). Sin embargo, el RTM estimó con precisión en los intervalos de FMC 70-30% y <30% (RMSE<20%) mientras que para el intervalo de FMC >70% el error de las estimaciones o RMSE duplicó el error de medición.

MODELO	RMSE			
	FMC>70%	FMC (70-30%)	FMC<30%	TODOS
Empírico	51,40	42,84	48,07	47,71
RTM	46,98	21,36	20,99	33,25

Tabla 4. RMSE entre los valores observados y estimados con el modelo empírico y el RTM para diferentes intervalos de FMC (se emplean las observaciones de todas las zonas, n=92).

En concordancia con los resultados del análisis de los RMSE, los residuales del modelo empírico fueron, en términos generales, mayores que los del RTM (Figura 3). Solo un 36% de las estimaciones realizadas con el modelo empírico fueron precisas. El 64% restante correspondieron fundamentalmente a sobreestimaciones (61%). Por el contrario, solo un 37% de las estimaciones realizadas con el RTM fueron imprecisas por presentar residuales mayores o menores que el error de medición. De ese 37%, un 20% correspondió a sobreestimaciones mientras que

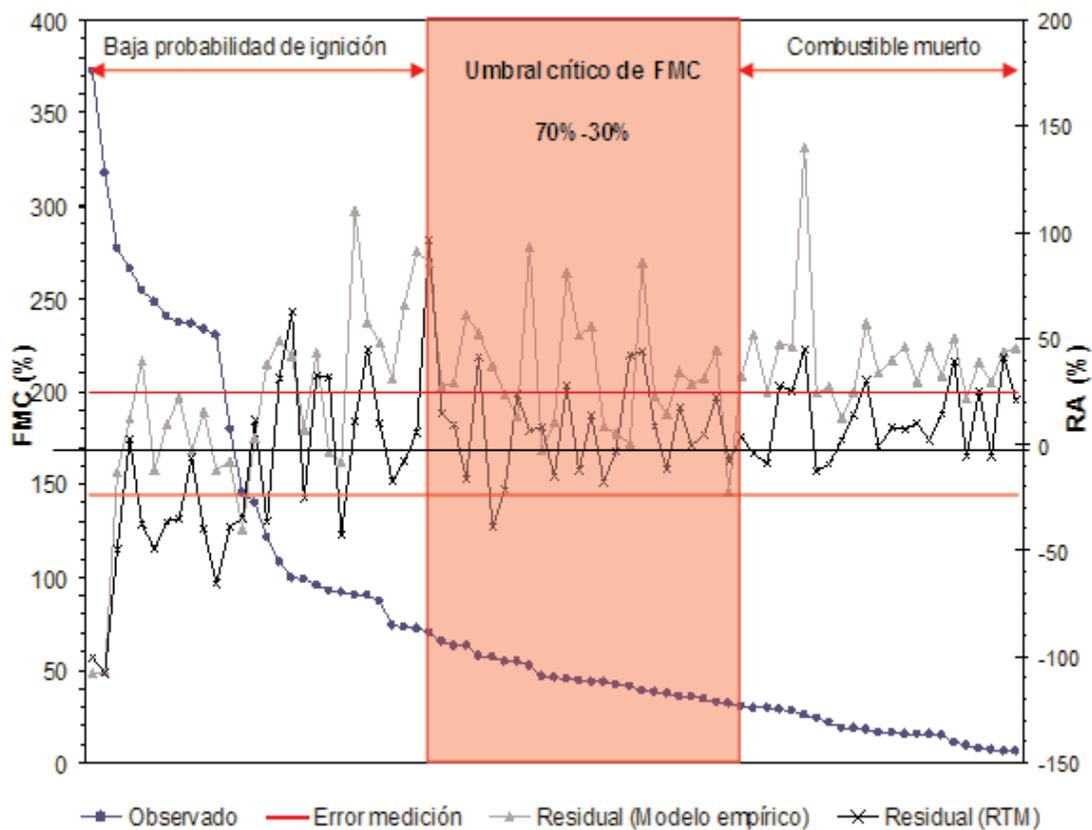


Figura 3. Valores de FMC observados (ordenados de mayor a menor) y residuales de las estimaciones realizadas con el modelo empírico y RTM. Se indican los tres intervalos de FMC previamente definidos y los errores de medición de FMC en campo.

un 17% a infraestimaciones.

Centrándose en los intervalos de FMC fijados y las estimaciones imprecisas se concluye:

1. $FMC > 70\%$. El modelo empírico sobrestima en todo el rango excepto en 2 casos puntuales correspondientes a las zonas 1 y 2. Dichas sobrestimaciones corresponden a observaciones de las zonas 4 y 5. Por el contrario, el RTM no presenta ninguna tendencia clara a subestimar o sobrestimar el FMC.
2. $70\% > FMC > 30\%$. El modelo empírico sobrestima siempre (casos de las zonas 3 y 4), mientras que el RTM sobrestima en 3 casos puntuales de las zonas de validación 5 y 6 e infraestima en un único caso correspondiente a la zona 5.
3. $FMC < 30\%$, el modelo empírico sobrestima siempre, mientras que el RTM sobrestima únicamente en 5 casos todos ellos correspondientes a las zonas de validación 1 y 2.

DISCUSION DE RESULTADOS

Los resultados de la validación del modelo empírico y el RTM con datos de FMC tomados durante diferentes épocas del año en seis zonas de pastizales caracterizadas por diferente composición de especies y estructura confirman la hipótesis de que los RTM tiene mayor poder de generalización que los modelos empíricos, ya que las estimaciones con el primero fueron más precisas que aquellas realizadas con el segundo, independientemente de la zona. No obstante, las diferencias de precisión fueron más evidentes en aquellas zonas que agruparon pastizales de composición y estructura distinta a los de la zona de calibrado y/o fueron muestreadas durante diferentes periodos, ya que, en estas zonas el modelo empírico incrementó considerablemente los errores de estimación. Estos altos errores eran de esperar según los resultados obtenidos por previos autores.

Así por ejemplo, Dilley *et al.* (2004) únicamente obtuvieron estimaciones precisas de FMC, basadas en modelos empíricos calibrados con el sensor NOAA-AVHRR en una localidad de Victoria (Australia), al aplicar el modelo a la muestra de validación extraída de dicha zona de calibrado. Cuando el modelo empírico lo aplicaban a pastizales de otras dos localidades del mismo estado con diferente composición y estructura se producían sobreestimaciones.

En lo que a este estudio se refiere, el modelo empírico tendió a estimar mayores contrastes estacionales que los que realmente se observaron, conllevando a grandes sobreestimaciones del FMC, en los FMC del intervalo crítico observados en las zonas 3 y 4. Sin embargo, el RTM fue preciso en sus estimaciones.

Las zonas 3 y 4, agrupan pastizales caracterizados por baja fracción de cobertura y LAI durante todo el periodo de muestreo, ya que están bastante pastoreados. Así mismo en el análisis exploratorio de los FMC se observó que estas zonas presentaban bajos FMC y desviaciones típicas. Por el contrario, los pastizales del PNC experimentan un fuerte contraste estacional, tanto de LAI como de FMC. Esta clara diferencia en cuanto a LAI y FMC puede ilustrarse por la correlación no significativa entre dichas variables en las zonas 3 y 4 ($R^2 = 0,25$, $p > 0,001$, $n = 24$) frente a la significativa en el PNC ($R^2 = 0,92$, $p < 0,001$, $n = 29$, de (Yebra *et al.*, 2008)). Las estimaciones de FMC con el modelo empírico estuvieron basadas en el índice de verdor NDVI y, por tanto en los cambios en la C_{a+b} que se producen cuando el pasto varía su FMC (Billore y Mall 1976). Como la

C_{a+b} están concentrada en las hojas, si el LAI disminuye y la fracción del suelo incrementa, el modelo empírico disminuye considerablemente su sensibilidad a variaciones de C_{a+b} , de ahí su alta imprecisión en estas zonas. Sin embargo, el RTM, fue ajustado teniendo en cuenta, además de un índice de humedad, el LAI, lo que explica las estimaciones mucho más precisas.

La zona 6, si bien agrupa pastizales similares en estructura a los del PNC, estos son diferentes en composición, ya que están adherados con eucaliptos. A su vez, fueron muestreados durante los periodos de otoño e invierno. En estas situaciones el modelo empírico sobreestimó altamente los FMC de otoño. En esta época del año, el C_{a+b} de pastizales alcanza los valores mínimos que se mantienen hasta el comienzo de primavera (Billore y Mall 1976). Por ello, el modelo empírico no puede ser sensible a variaciones de FMC en estos periodos, ya que el C_{a+b} es bajo y constante y posiblemente lo único que captura son variaciones en LAI o en la fracción de cobertura. De nuevo el RTM está exento de este problema por lo que fue mas preciso.

En la zona 5, de similar composición y estructura que la zona 4, las estimaciones fueron imprecisas con sendos modelos ($RMSE > 22\%$). La parcela muestreada en esta zona presentó alta cobertura de eucaliptos (figura 4), por lo que los espectros MODIS extraídos de la imagen para estimar FMC estuvieron altamente contaminados por la señal de los mismos, lo que condujo a sobreestimaciones del FMC con sendos modelos.



Figura 4. Imagen Quickbird en composición color natural de la parcela de pastizal de la zona 5. Fuente: Google Earth.

Por último, en las zonas 1 y 2, se obtuvieron resultados no esperados, ya que siendo estos pastizales los más parecidos a los del PNC, el modelo empírico debería haber estimado con mayor precisión. No obstante, estas zonas fueron las únicas en las que dicho modelo estimó correctamente la estacionalidad del FMC, lo que queda ilustrado en los gráficos de evolución estacional y respaldado por los elevados R^2 entre FMC observados y estimados. Estos resultados coinciden con los obtenidos con el sensor NOAA-AVHRR por Chuvieco *et al.* (2004b) en las mismas áreas de estudio. Los autores también obtuvieron R^2 y RMSE elevados cuando aplicaron la ecuación empírica calibrada en el PNC a las zonas de validación 1 y 2 ($R^2= 0,88$ y $0,90$, $RMSE=41.24\%$ y 34.46% , zona 1 y 2, respectivamente). Por su lado, el RTM también estimó correctamente la estacionalidad del FMC pero sus RMSE, si bien menores que los del modelo empírico, fueron superiores al error de medición.

Debido a que las estimaciones con el RTM también fueron imprecisas, debe haber algún factor externo que esté afectando la precisión de las estimaciones en estas zonas. Danson y Bowyer (2004) señalaron que la precisión de las estimaciones de FMC con índices de vegetación depende de la distribución de

los valores de FMC en la muestra de validación. Dichos autores emplearon relaciones empíricas entre índices de vegetación y FMC extraídos de la base de datos LOPEX (del inglés, “*Leaf Optical Properties Experiment*”) y encontraron mayores errores en las estimaciones cuando los $FMC > 100\%$. Los resultados del análisis global realizado en este estudio concuerda con lo señalado por estos autores, ya que los mayores RMSE correspondieron con las estimaciones realizadas en el intervalos de $FMC > 70\%$, ya fuese empleando el modelo empírico como el RTM.

Las zonas 1 y 2 presentaron un alto número de observaciones en dichos intervalos, lo que explica las imprecisiones obtenidas.

La causa de la falta de precisión de los modelos en la estimación de $FMC > 70\%$ puede radicar en la saturación de las variables independientes empleadas en los mismos en dicho intervalo de FMC. El NDVI, del modelo empírico, se satura cuando los valores de FMC son elevados (figura 5-a). Lo mismo ocurre con el LAI, índice incluido en el RTM (figura 5-b). Dicho índice se extrajo del producto MOD15 que, al estar basado en las bandas del rojo e IRC (mismas bandas empleadas en el cómputo del NDVI), también está afectado por el problema de saturación (Knyazikhin *et al.* 1999).

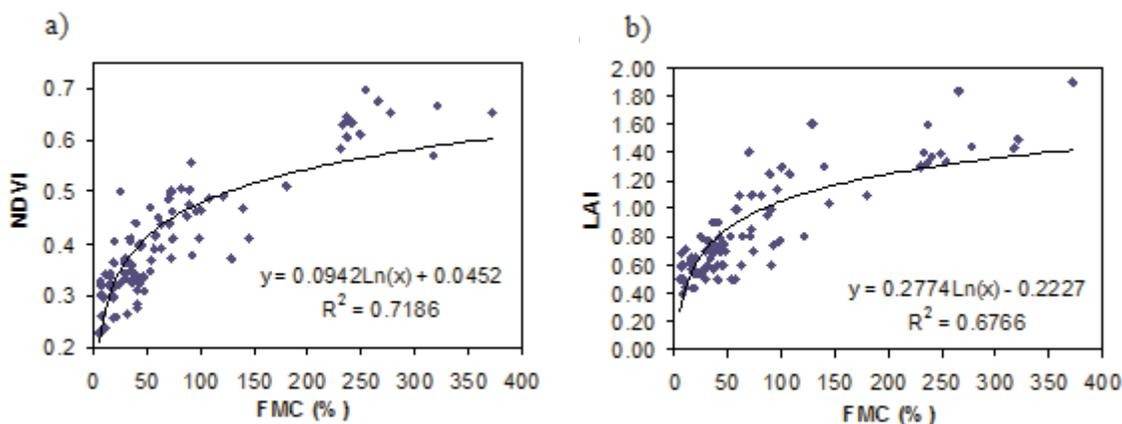


Figura 5. Relación entre FMC (%), y el índices de vegetación NDVI (a) y el LAI (b) para todo el conjunto de datos empleado en el estudio (n=92).

CONCLUSIONES

El contenido de humedad de la vegetación es una variable clave a considerar en diversas aplicaciones, muchas de las cuales precisan un conocimiento a nivel global. Por ello, se precisa de modelos que estimen dicha variable de forma precisa y robusta independientemente de la zona en la que se apliquen. En este marco, los datos recogidos por el sensor MODIS pueden ser empleados para derivar mapas de FMC de actualización semanal, fundamentalmente mediante el empleo de modelos empíricos o RTM. Cada uno de estos modelos tiene sus ventajas y limitaciones por lo que el objetivo de este trabajo fue determinar qué modelo es el más adecuado para desarrollar una metodología global, operativa y precisa de estimación de FMC.

En un estudio previo se compararon las precisiones en las estimaciones de sendos modelos empleando para ello una muestra de datos extraída de la zona

en la que los modelos fueron calibrados. Se concluyó que los modelos estiman el FMC de pastizales con precisión similar. En este trabajo se avanza en dicha comparación validando los modelos con datos tomados en seis zonas de pastizal de diversas características y durante diferentes estaciones del año. Se concluye que sendos modelos presentan precisiones similares en aquellas zonas más parecidas a la zona de calibrado, si bien en las zonas de diferentes composición o estructura del pastizal y/o en los periodos de otoño, el modelo empírico sobrestimó altamente los FMC mientras que el RTM estimó con precisión. Por ello se concluye que el RTM calibrado es generalizable a otras zonas y por tanto puede utilizarse para aplicaciones globales. Todas las conclusiones derivadas de este estudio así como del realizado por Yebra *et al.* (2008) se presentan en la tabla 5, lo que proporciona un balance final sobre el interés y los problemas que plantea el uso de modelos empíricos y RTM.

CRITERIO	RTM	MODELOS EMPIRICOS
DIFICULTAD	ALTA Precisa una parameterización detallada y conocimientos básicos de programación.	BAJA Procesamiento de las muestras recogidas en campo y metodológica de calibrado sencillo.
TIEMPO	ALTO Obtención de la información auxiliar a los datos de reflectividad ya sea con trabajo de campo o búsquedas bibliográficas.	MEDIO Necesidad de una serie de medidas de FMC de campo lo suficientemente larga para que las relaciones con los datos derivados de imágenes satélite sean significativas. Alto número de imágenes a procesar.
COSTE	MEDIO Disminuye la frecuencia de los muestreos de campo pero sigue precisando de los mismos para llevar a cabo la parametrización y validación de los modelos.	ALTO Muestreos frecuentes para la calibración y en lugares distantes para la validación (gastos de desplazamiento, dietas y alojamiento)
INDICES SELECCIONADOS	HUMEDAD: NIR-SWIR	VERDOR: Red-NIR
INFORMACIÓN AUXILIAR	MEDIA LAI	BAJA
ROBUSTED	ALTA	MEDIA
PRECISIÓN	ALTA para valores de FMC < 70%, saturación del LAI BAJA para valores de FMC > 70%	BAJA Tendencia a sobreestimar.
PODER GENERALIZACIÓN	ALTO	BAJO

Tabla 5. Balance final sobre el interés y los problemas que plantean el uso de los modelos empíricos y RTM.

Cabe destacar que aún siendo más preciso el RTM, los errores de estimación del mismo incrementaron considerablemente cuando los $FMC > 70\%$, debido a la saturación del LAI. Desde el punto de vista de la estimación de peligro de incendio o la gestión del riego en agricultura de precisión el conocer con precisión el FMC en este intervalo no es crítico, ya que el peligro de ignición es mínimo y la vegetación no presenta estrés y por lo tanto no necesitará riego. Cuando el FMC se encuentra en el intervalo crítico, $70\% > FMC > 30\%$, se obtuvieron precisiones $\approx 20\%$. Aunque no existe ningún estudio publicado sobre la precisión necesaria para aplicaciones operacionales se considera este nivel de precisión adecuado teniendo en cuenta que el error en las mediciones de FMC en campo (método de medida considerado como el más preciso) es de un 22%.

Por último, el RTM, tiene aún gran potencial de mejora mediante el uso de otras técnicas de inversión que consideren todo el rango espectral o el refinamiento de la parametrización de los modelos PROSPECT y SAILH. En futuros trabajos se explorará con mayor detalle las posibilidades de mejora citadas con anterioridad.

AGRADECIMIENTOS

Agradecer a Jim Gould del Grupo de Investigación en Incendios Forestales de “CSIRO Forest Bioscience” (Canberra, ACT) la acogida de Marta Yebra durante su estancia de 3 meses para la realización de este trabajo, facilitando todos los datos de FMC e información complementaria de los que disponía (fotografías, etc.). También agradecer a Elizabeth Botha del Grupo de Teledetección ambiental de CSIRO- “Land & Water” el facilitar los datos de reflectividad MODIS. Asimismo, reconocemos la valiosa colaboración de varias personas de nuestro departamento en las campañas de muestreo llevadas a cabo en España y destacamos el soporte financiero del Ministerio de Educación, Ciencia y Tecnología y del proyecto CICYT Firemap (CGL2004-060490C04-01/CLI).

REFERENCIAS

AGUADO, I., CHUVIECO, E., BORÉN, R. y NIETO, H. 2007. Estimation of dead fuel moisture content from meteorological data in Mediterranean areas. Applications in fire

danger assessment. *International Journal of Wildland Fire*. 16: 390-397.

- BILLORE, S.K. y MALL, L.P. 1976. Seasonal variation in chlorophyll content of a grassland community. *Journal of Tropical Ecology*. 17: 39-44.
- BURGAN, R.E., KLAVER, R.W. y KLAVER, J.M. 1998. Fuel models and fire potential from satellite and surface observations. *International Journal of Wildland Fire*. 8: 159-170.
- CECCATO, P., FLASSE, S. y GREGOIRE, J.M. 2002a. Designing a spectral index to estimate vegetation water content from remote sensing data: Part 2. Validation and applications. *Remote Sensing of Environment*. 82: 198-207.
- CECCATO, P., GOBRON, N., FLASSE, S., PINTY, B. y TARANTOLA, S. 2002b. 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. (Ed.). 2008. Earth Observation of Global Change. The Role of Satellite Remote Sensing in Monitoring Global Environment. *Springer Dordrecht*
- CHUVIECO, E., COCERO, D., AGUADO, I., PALACIOS-ORUETA, A. y PRADO, E. 2004a. Improving Burning Efficiency Estimates through Satellite Assessment of Fuel Moisture Content. *Journal of Geophysical Research - Atmospheres*. 109: 1-8.
- CHUVIECO, E., COCERO, D., RIAÑO, D., MARTÍN, M.P., MARTÍNEZ-VEGA, J., DE LA RIVA, J. y PÉREZ, F. 2004b. 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., RIAÑO, D., AGUADO, I. y COCERO, D. 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: 2145-2162.
- COLOMBO, R., MERONI, M., MARCHESI, A., BUSETTO, L., ROSSINI, M., GIARDINO, C. y PANIGADA, C. 2008. Estimation of leaf and canopy water content in poplar plantations by means of hyperspectral indices and inverse modeling. *Remote Sensing of Envi-*

- ronment 112:1820-1834.
- DANSON, F.M. y BOWYER, P. 2004. Estimating live fuel moisture content from remotely sensed reflectance. *Remote Sensing of Environment*. 92: 309-321.
- DENNISON, P.E., ROBERTS DAR, A., PETERSON, S.H. y RECHEL, J. 2005. Use of Normalized Difference Water Index for monitoring live fuel moisture content. *International Journal of Remote Sensing*. 26: 1035-1042.
- DILLEY, A.C., MILLIE, S., O'BRIEN, D.M. y EDWARDS, M. 2004. The relation between Normalized Vegetation Index and vegetation moisture content at three grassland locations in Victoria, Australia. *International Journal of Remote Sensing*. 25, 3913-3928.
- 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.
- GOEL, N.S. 1988. Models of vegetation canopy reflectance and their use in estimation of biophysical parameters from reflectance data. *Remote Sensing Review*. 4: 1-212.
- HUNT, E.R. y ROCK, B.N. 1989. Detection of changes in leaf water content using near and middle-infrared reflectances. *Remote Sensing of Environment*. 30: 43-54.
- JACKSON, T.J., CHEN, D., COSH, M., LI, F., ANDERSON, M., WALTHALL, C., DORIAS-WAMY, P. y HUNT, E.R. 2004. Vegetation water content mapping using Landsat data derived normalized difference water index for corn and soybeans. *Remote Sensing of Environment*. 92: 475-482.
- JACQUEMOUD, S. 1990. PROSPECT: a model to leaf optical properties spectra. *Remote Sensing of Environment*. 34: 74-91.
- KNYAZIKHIN, Y., GLASSY, J., PRIVETTE, J.L., TIAN, Y., LOTSCH, A., ZHANG, Y., WANG, Y., MORISETTE, J.T., VOTAVA, P., MYNENI, R.B., NEMANI, R.R. y RUNNING, S.W. 1999. MODIS Leaf Area Index (LAI) And Fraction Of Photosynthetically Active Radiation Absorbed By Vegetation (FPAR) Product (MOD15). Algorithm Theoretical Basis Document. <http://eosps0.gsfc.nasa.gov/atbd/modistables.html>.
- KOGAN, F., GITELSON, A., ZAKARIN, E., SPIVAK, L. y LEBED, L. 2003. AVHRR-Based spectral vegetation index for quantitative assessment of vegetation state and productivity: calibration and validation. *Photogrammetric Engineering and Remote Sensing*. 69: 899-906.
- MBOW, C., GOÏTA, K. y BÉNIÉ, G.B. 2004. Spectral indices and fire behavior simulation for fire risk assessment in savanna ecosystems. *Remote Sensing of Environment*. 91: 1-13.
- PRIVETTE, J.L., EMERY, W.J. y SCHIMEL, D.S. 1996. Inversion of a Vegetation Reflectance Model with NOAA AVHRR data. *Remote Sensing of Environment*. 58: 187-200.
- ROBERTS, D.A., PETERSON, S., DENNISON, P.E., SWEENEY, S. y RECHEL, J. 2006. Evaluation of Airborne Visible/Infrared Imaging Spectrometer (AVIRIS) and Moderate Resolution Imaging Spectrometer (MODIS) measures of live fuel moisture and fuel condition in a shrubland ecosystem in southern California. *Journal of Geophysical Research*. 111: GO4S02. doi: 10.1029/2005JG000113.
- ROUSE, J.W., HAAS, R.W., SCHELL, J.A., DEERING, D.H. y HARLAN, J.C. 1974. Monitoring the vernal advancement and retrogradation (Greenwave effect) of natural vegetation. In. Greenbelt, MD. USA: NASA/GSFC.
- SEPULCRE-CANTÓ, G., ZARCO-TEJADA, P.J., JIMENEZ-MUÑOZ, J.C., SOBRINO, J.A., DE MIGUEL, E., VILLALOBOS, F.J., 2006. Detection of water stress in an olive orchard with thermal remotesensing imagery. *Agricultural and Forest Meteorology*. 136 (1): 31-44.
- STRAHLER, A.H., WOODCOCK, C.E. y SMITH, J.A. 1986. On the nature of models in remote sensing. *Remote Sensing of Environment*. 20: 121-140.
- VAN WAGNER, C.E. (1967). Seasonal variation in moisture content of Eastern Canadian tree foliage and the possible effect on crown fires. In (p. 15): Forestry Branch, Canada.
- 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. y VERMEULEN, A. 1999. Atmospheric correction algorithm: Spectral Reflectances (MOD09). In (p. 109 pp): NASA.
- YEBRA, M., CHUVIECO, E. y RIAÑO, D. 2008. Estimation of live Fuel Moisture Content

from MODIS images for fire risk assessment. *Agricultural and Forest Meteorology*. 148: 523-536.
ZARCO-TEJADA, P.J., RUEDA, C.A. y USTIN,

S.L. 2003. Water content estimation in vegetation with MODIS reflectance data and model inversion methods. *Remote Sensing of Environment*. 85: 109-124.