

# Estimación de la *f*APAR sobre la Península Ibérica a partir de la inversión del modelo de transferencia radiativa 4SAIL2

Martínez, B.\*<sup>1</sup>, Albargues, E.<sup>2</sup>, Camacho, F.<sup>2</sup>, Moreno, A.<sup>1</sup>, Gilabert, M.A.<sup>1</sup>

<sup>1</sup>Dpt. Física de la Terra i Termodinàmica, Universitat de València, C/ Dr. Moliner, 50. 46100 Burjassot, València.

<sup>2</sup>EOLAB. Parc Científic Universitat de València P.O. Box 22085, E-46071, València.

---

**Resumen:** El objetivo de este trabajo consiste en la estimación de la *f*APAR en la Península Ibérica a partir de datos MODIS. En primer lugar, se ha simulado un conjunto de datos de reflectividades y de *f*APAR a partir de los modelos de transferencia radiativa de hoja (PROSPECT) y de cubiertas heterogéneas (4SAIL2). En segundo lugar, se ha entrenado un conjunto de redes neuronales artificiales (RNAs) para obtener mediante inversión la relación entre la *f*APAR y las reflectividades simuladas y así calcular, por último, la *f*APAR de la Península Ibérica a partir de imágenes de reflectividad de MODIS. Además, se ha analizado la influencia de la configuración de observación e iluminación, nadir y oblicua. La *f*APAR estimada se ha comparado con otros productos ya validados. Los resultados ponen de manifiesto que la *f*APAR estimada a partir de la combinación (PROSPECT+4SAIL2+Nadir) proporciona, en general, diferencias alrededor del umbral requerido por los usuarios (0,1). Esta combinación se plantea como una alternativa para estimar la *f*APAR en la Península Ibérica por su capacidad para caracterizar distintos tipos de cubiertas, así como por la alta variabilidad intra-anual observada en algunos casos.

**Palabras clave:** *f*APAR, 4SAIL2, inversión, RNAs.

## ***f*APAR estimates over the Iberian Peninsula by the inversion of the 4SAIL2 radiative transfer model**

**Abstract:** This work aims to the estimation of *f*APAR over the Iberian Peninsula using MODIS data. First, the 4SAIL2 and PROSPECT radiative transfer models have been used to simulate a data set of reflectance and *f*APAR. Second, an artificial neuronal network (ANN) has been trained using the simulated data and finally, it has been inverted to derive *f*APAR estimates over the Iberian Peninsula from MODIS reflectances images. Moreover, the impact that the observation and illumination configuration have on the *f*APAR estimates has been assessed. The *f*APAR estimates from MODIS have been compared with other validated *f*APAR products. The results confirm an overall error around the user requirements (0.1) when the *f*APAR estimated from the (PROSPECT+4SAIL2+Nadir) combination is compared with the selected products. This combination is proposed as an alternative to estimate *f*APAR over the Iberian Peninsula due to the ability to characterize different land cover types as well as the high intra-annual variability of particular canopies.

**Key words:** *f*APAR, 4SAIL2, inversion, ANNs.

---

## 1. Introducción

La fracción de radiación fotosintéticamente activa absorbida por la cubierta vegetal (*fraction of absorbed photosynthetic active radiation*,

*f*APAR) es comúnmente aceptada como un parámetro biofísico fundamental en el contexto de las disciplinas relacionadas con el cambio global, siendo considerada como variable climática esencial (*Essential Climate Variables*, ECVs) (*Global*

\* Autor para la correspondencia: [beatriz.martinez@uv.es](mailto:beatriz.martinez@uv.es)

*Climate Observing System*, GCOS, 2010) del sistema terrestre, clave en la estimación del flujo de carbono asociado con la fotosíntesis. En general, depende de la arquitectura de la cubierta vegetal, de las propiedades de las hojas y suelo y de la irradiancia solar (Baret y Guyot, 1991).

Los datos de satélite de observación de la Tierra permiten monitorizar la *f*APAR a escala global con una alta frecuencia temporal (desde diaria hasta aproximadamente 10 días). Actualmente, existe una amplia variedad de productos de *f*APAR a diferentes resoluciones temporal y espacial proporcionados por las agencias espaciales *National Aeronautics and Space Administration* (NASA), *European Space Agency* (ESA) y *European organization for the exploration of METeorological SATellites* (EUMETSAT), así como organismos oficiales (Comisión Europea, *Joint Research Centre*). Por ejemplo, podemos encontrar el producto *Moderate Resolution Imaging Spectroradiometer* (MODIS) (Knyazikhin et al., 1998), *Medium Resolution Imaging Spectrometer* (MERIS) (Gobron et al., 1999; Bacour et al., 2006), *Sea-viewing Wide Field-of-view Sensor* (SeaWiFS) (Gobron et al., 2006), *Spinning Enhanced Visible and Infrared Imager Meteosat Second Generation* (SEVIRI-MSG) (García-Haro et al., 2008), varios productos derivados con datos VEGETATION en el contexto del proyecto *Carbon cYcle and Change in Land Observational Products from an Ensemble of Satellites* (CYCLOPES) (Baret et al., 2007) o el producto GEOV1 (Baret et al., 2013; Camacho et al., 2013) desarrollado en el marco del proyecto Geoland2.

Estos productos se obtienen a partir de metodologías diferentes, como es el caso del producto MERIS y SeaWiFS que se derivan a partir de la relación entre la *f*APAR y un índice de vegetación optimizado a partir de datos simulados por un modelo de transferencia radiativa (MTR) (Roujean y Bréon, 1995; Gobron et al., 2006), el producto GEOV1 que se deriva a partir la técnica de inversión red neuronal artificial (RNA) (Bishop, 1996) entrenada también con datos simulados (Baret et al., 2007) o el producto MODIS que se calcula a partir de un MTR combinado con *Look-up-tables* (LUTs) (Knyazikhin et al., 1998). Esta diversidad en productos, ha dado lugar a diferentes estudios de intercomparación donde se ponen

de manifiesto discrepancias muy importantes entre ellos (McCallum et al., 2010; Martínez et al., 2013) que superan en muchas zonas el umbral de incertidumbre requerido por los usuarios (i.e. 0,1) (GCOS, 2006, Camacho et al., 2013) y que corresponde al error absoluto establecido para la *f*APAR (GCOS, 2006). Estas diferencias observadas entre productos son mayores en las zonas de bosques, llegando a ser de hasta el 65% en términos de producción primaria bruta (GPP) cuando se estima a partir de un modelo de producción de ecosistemas (*Production Ecosystem Models*, PEM) (Martínez et al., 2013).

Los MRTs que han alcanzado mayor difusión durante los últimos años a nivel de hoja y cubierta se corresponden con los llamados PROSPECT (Jacquemoud y Baret, 1990) y SAIL (*Scattering by Arbitrarily Inclined Leaves*) (Verhoef, 1984). Otros modelos a nivel de hoja son el LIBERTY (*Leaf Incorporating Biochemistry Exhibiting Reflectance and Transmittance Yields*) (Dawson et al., 1998) para el caso particular de coníferas o el LEAFMOD (*Leaf Experimental Absorptivity Feasibility MODEL*) (Ganapol et al., 1998), que permiten también la simulación de las propiedades ópticas de la hoja en función de la estructura de la hoja y los constituyentes bioquímicos. A nivel de cubierta destacan también el modelo de dos capas MCRM (*Markov-Chain Canopy Reflectance Model*) (Kuusk, 1995) o el modelo específico para bosques FLIM (Rosema et al., 1992). Respecto al SAIL, este modelo presupone dos consideraciones ideales de la cubierta: (i) considera la cubierta como una capa horizontal infinitamente extendida, formada por elementos dispersores infinitesimales que se encuentran distribuidos de forma homogénea por toda la cubierta y (ii) asume una distribución aleatoria de los ángulos acimutales de las hojas. Sin embargo, este modelo de transferencia no parece apropiado para caracterizar superficies heterogéneas donde se esperan diferencias en el tipo de cubierta y también en la propia estructura vertical.

Uno de los problemas que nos planteamos con este trabajo es la estimación de la *f*APAR diaria adaptada a las características de la Península Ibérica en el contexto del proyecto ARTEMIS (*A remote sensing study of forests to estimate biophysical indicators and monitoring CO<sub>2</sub> fluxes in Spain*) y RESET CLIMATE (*Remote Sensing of terrestrial*

*essential climate variables: Water stress effect on carbon flux assessment*) para el año 2008. En concreto, se pretende evaluar las mejoras que ofrece en la estimación de la fAPAR el uso de un modelo de cubierta heterogéneo como es el 4SAIL2 (Verhoef y Bach, 2007) y comparar las estimaciones con otros productos de fAPAR en la Península Ibérica. Para ello, se generará un conjunto amplio de datos simulados de reflectividades y de fAPAR. Para encontrar la relación entre el parámetro biofísico fAPAR y las reflectividades proporcionadas por los MRTs se utilizará el modelo de inversión de RNAs para, posteriormente, obtener imágenes de fAPAR a partir de imágenes de reflectividad de MODIS. Las RNAs han emergido en los últimos años como una buena alternativa a las técnicas clásicas (modelos lineales auto-regresivos, modelos paramétricos, etc.) y presentan importantes ventajas, como su capacidad para encontrar relaciones complejas en problemas con una alta dimensionalidad y sin un conocimiento *a priori* de cómo se relacionan las variables.

En este trabajo nos centraremos sólo en la fracción de la radiación absorbida entre 400 y 700 nm por los elementos verdes de la vegetación, conocida como *green fAPAR* y a la que nos referiremos a partir de ahora como fAPAR. Además, se analizarán las diferencias debidas a dos configuraciones de geometría de observación, la configuración nadir utilizada en la mayoría de los algoritmos de fAPAR (Knyazikhin *et al.*, 1998; Gobron *et al.*, 2006) y la observación oblicua ( $\theta_s=60^\circ$ ,  $\theta_o=45^\circ$ ,  $\varphi=0^\circ$ ) propuesta por Roujean y Breon (1995). Esta observación se utiliza en el proyecto LSA SAF (*Land Surface Analysis Satellite Applications Facility*) para estimar la fAPAR con datos SEVIRI-MSG (García-Haro *et al.*, 2008) y también en el proyecto ARTEMIS para estimar la fAPAR a partir de datos MODIS. Finalmente, se presenta una discusión de los resultados aplicados a datos de satélite y se comparan nuestras estimaciones de fAPAR con otros productos ya validados.

## 2. Descripción de modelos

### 2.1. Modelos de transferencia radiativa

Para describir la reflectividad de la cubierta se ha considerado el modelo de reflectividad de la hoja

PROSPECT y el modelo de reflectividad de la cubierta, 4SAIL2. La combinación de los modelos de hoja y cubierta permiten un mejor conocimiento de los procesos físicos que controlan la reflectividad de la cubierta teniendo en cuenta diferentes variables de la hoja, arquitecturas de la cubierta y configuraciones de observación de manera que permiten su utilización para diversas áreas y períodos. El modelo PROSPECT ha alcanzado una gran difusión durante los últimos años a nivel de hoja (Jacquemoud *et al.*, 2009), mientras que el modelo 4SAIL2 es una versión del SAIL adaptada para mejorar el tratamiento de cubierta heterogéneas.

#### 2.1.1. PROSPECT

Para obtener las propiedades ópticas de las hojas se ha considerado la versión PROSPECT5 (Féret *et al.*, 2008), la cual proporciona la reflectividad ( $\rho_{hoja}$ ) y la transmisividad ( $\tau_{hoja}$ ) de la hoja a partir de 6 parámetros de entrada: la concentración de pigmentos de clorofila ( $C_{a+b}$ ), el contenido de pigmentos marrones ( $C_{bp}$ ), el contenido de agua ( $C_w$ ), el contenido de materia seca ( $C_m$ ), concentración de pigmentos carotenoides ( $C_{ar}$ ) y el índice de estructura mesófila ( $N$ ). Uno de los parámetros más interesantes de este modelo, es el parámetro  $N$  el cual está relacionado con el número de capas que forman la hoja. Valores superiores a 2,5 representan hojas senescentes con una estructura interna desorganizada, por lo que este parámetro puede ser usado para separar o identificar tipos de vegetación. Otro aspecto importante a destacar del modelo PROSPECT es que considera por separado la influencia debida a los pigmentos y al contenido en agua para describir el proceso de absorción que se produce en la hoja. La diferencia más notable de la versión PROSPECT5 es el tratamiento por separado de la concentración de pigmentos de clorofila y carotenoides. A continuación se presentan los parámetros de los que depende el modelo.

$$(\rho_{hoja}, \tau_{hoja}) = PROSPECT(N, C_{a+b}, C_m, C_{bp}, C_{ar}) \quad (1)$$

#### 2.1.2. 4SAIL2

El modelo 4SAIL2 es una versión del modelo de cubiertas homogéneas SAIL cuyo nombre hace referencia a la contribución de cuatro componentes del flujo de radiación para una cubierta heterogénea que presenta un comportamiento no

lambertiano y puede estar compuesta por dos capas, una componente verde y otra marrón. Una importante mejora del 4SAIL2 para nuestro estudio, es que considera el efecto de agrupamiento (*crown clumping*) a partir de la fracción de cubierta vegetal ( $C_v$ ) y el factor de forma de los árboles ( $\xi$ ).

La aproximación de cuatro componentes del flujo de radiación, dos directos (*direct solar irradiance*,  $E_s$ , y *flux-equivalent radiance in the observation direction*,  $E_o$ ) y dos flujos de radiación difusa (*hemispherical diffuse downward irradiance* y *hemispherical diffuse upward irradiance*) proporciona una solución más realista de la interacción de la radiación entre la superficie y la atmósfera, siendo además computacionalmente más eficiente. El 4SAIL2 proporciona la reflectividad bidireccional ( $\rho$ ) y la absorptividad ( $\alpha$ ) de la cubierta para un conjunto de geometrías de observación y de iluminación en el rango espectral comprendido entre 400 y 2500 nm.

Los parámetros de entrada del modelo son la reflectividad ( $\rho_g, \rho_b$ ) y la transmisividad ( $\tau_g, \tau_b$ ) de la hoja verde y marrón, respectivamente, obtenidas a partir del modelo PROSPECT, la reflectividad del suelo ( $\rho_s$ ), la función de distribución de inclinación foliar para controlar la pendiente media de las hojas (LIDFa), la función de distribución de inclinación foliar para controlar la distribución bimodal (LIDFb), el parámetro de *hot spot* (*Hot*), la fracción de hojas marrones ( $f_b$ ), el factor de disociación de las dos capas ( $D$ ), la fracción de cubierta vegetal ( $C_v$ ), el factor de forma de los árboles ( $\xi$ ), el ángulo cenital solar ( $\theta_s$ ), el ángulo cenital de observación ( $\theta_o$ ) y ángulo acimutal relativo ( $\varphi$ ). A continuación se presentan los parámetros de los que depende el modelo.

$$(\rho, \alpha) = 4SAIL2(\rho_g, \tau_g, \rho_s, \rho_b, \tau_b, LAI, LIDF_a, LIDF_b, Hot, f_b, D, C_v, \xi, \theta_s, \theta_o, \varphi) \quad (2)$$

## 2.2. Redes neuronales artificiales (RNAs)

Las filosofía de funcionamiento de una RNA está inspirada en estudios sobre el cerebro y el sistema nervioso (Bishop, 1996). Una RNA imita estas estructuras biológicas distribuyendo los cálculos en unidades de procesamiento simples, llamadas neuronas artificiales o nodos. La principal característica de un sistema de red neuronal es la habilidad para aprender de forma iterativa. De acuerdo al método de aprendizaje, hemos considerado RNAs no

supervisadas, dado que no requieren conocer las relaciones entre los datos de entrada y de salida.

Las neuronas dentro de una red están organizadas formando niveles, o capas, de un cierto número de unidades o neuronas. En general, se distinguen tres capas fundamentales, (i) capa de entrada, constituida por aquellas neuronas que introducen los patrones de entrada en la red, (ii) capas ocultas, formada por aquellas neuronas cuyas entradas provienen de capas anteriores y cuyas salidas pasan a neuronas de capas posteriores y, (iii) capa de salida, la cual coincide con el número de variables a modelar.

En este trabajo, se ha utilizado el clásico perceptrón multicapa (*Multilayer Perceptron*, MLP) de forma recurrente, lo que implica que existen lazos de realimentación entre neuronas de diferentes capas, neuronas de la misma capa o, sencillamente, entre una misma neurona. Este tipo de red neuronal es el más comúnmente usado (Haykin, 2009) dado que permite resolver problemas lineales y no lineales. El MLP se ha aplicado con éxito a muchos problemas de predicción de variables biofísicas con datos de satélite, como es el algoritmo CYCLOPES (Baret et al., 2007), productos MERIS (Bacour et al., 2006) o productos MODIS (Verger et al., 2008).

Un MLP está compuesto por un conjunto de neuronas,  $y_i$ . Cada una de estas neuronas recibe las entradas de las neuronas vecinas y calcula un valor de salida, que es transferido a las neuronas de las siguientes capas. El valor de salida,  $y_j$ , es, en general, una transformación no lineal de sus entradas. Dicha transformación puede ser descrita mediante la siguiente expresión:

$$y_j = \phi\left(\sum_{i=1}^m w_{ij} j_{yi} + b_j\right) \quad (3)$$

donde  $m$  es el número de entradas a la neurona  $i$ -ésima,  $w_{ij}$  son los pesos sinápticos (parámetros del sistema),  $b_j$  es el coeficiente de sesgo (*bias*) (parámetro a determinar) y  $\phi$  es una función de activación que transforma la combinación de las entradas a la neurona con los correspondientes pesos sinápticos.

En este trabajo se ha utilizado la estructura de red neuronal propuesta por Cernicharo (2010) que consiste en la utilización de una capa oculta con

5 neuronas con la función de activación tangente hiperbólica sigmodial no lineal y una capa de salida con una única neurona y función de activación lineal. La función sigmodial presenta la ventaja de que es prácticamente lineal cerca del origen y casi constante en los extremos, lo que la hace adecuada para modelar comportamientos tanto lineales como no lineales, proporcionando una gran versatilidad a las RNAs.

El MLP se ha entrenado empleando el algoritmo iterativo de optimización de Levenberg-Marquardt (LM) (Madsen *et al.*, 2004; Lourakis, 2005), en el que el método iterativo es optimizado respecto al método tradicional de Gauss-Newton (GN). Los algoritmos de entrenamiento asociados a la red utilizan la técnica de descenso de gradiente (Snyman, 2005) que minimizan el error de la función de evaluación (definida como el error cuadrático medio entre el valor de fAPAR simulado y el devuelto por la red) para determinar qué ajuste de los pesos ofrece un mejor resultado. Durante el proceso iterativo de aprendizaje, cuando la solución está lejos de ser la correcta, el algoritmo LM emplea el método de descenso de gradiente. Este método es lento pero garantiza la convergencia. Por el contrario, si nos encontramos muy cerca de la solución correcta, se emplea el algoritmo GN (usa un modelo cuadrático para encontrar el mínimo con mayor rapidez). Este método de entrenamiento ha demostrado ser óptimo para redes

neuronales recurrentes de tamaño moderado, garantizando una convergencia eficiente y fácil implementación.

### 3. Procedimiento experimental

La Figura 1 muestra un breve esquema de las etapas en las que se divide el procedimiento experimental llevado a cabo. La obtención de imágenes de fAPAR a partir de reflectividades MODIS consiste en: (i) la simulación de datos de reflectividad y fAPAR a partir de los modelos de transferencia radiativa PROSPECT y 4SAIL2 en el rango espectral entre 400 y 2500 nm (ii) inversión del modelo a partir de la técnica de RNAs y, (iii) la aplicación del método de inversión a reflectividades obtenidas a partir de los productos MODIS (MCD43A1 y MCD43A2) (Schaff *et al.*, 2002). Por último, se presenta una comparación de las imágenes de fAPAR obtenidas a partir de datos MODIS con dos productos derivados de satélite, el producto oficial de NASA (MOD15A2 colección 5) y la fAPAR utilizada en el proyecto ARTEMIS.

#### 3.1. Datos simulados

En primer lugar, se obtendrán 10000 datos simulados de reflectividades y de fAPAR a partir de los modelos PROSPECT y 4SAIL2, tomando como *inputs* los valores de la Tabla 1. Los parámetros de

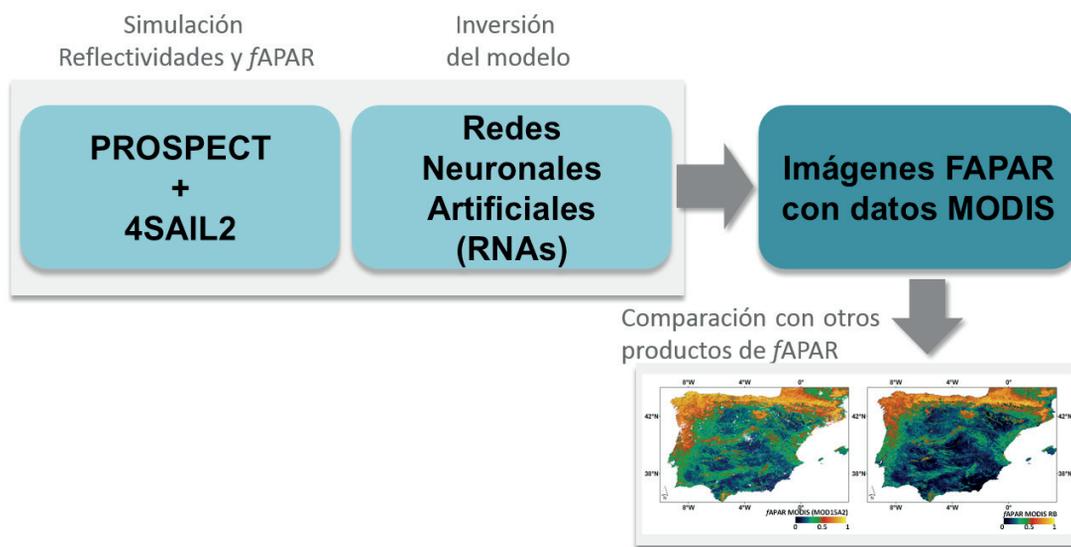


Figura 1. Descripción del procedimiento experimental llevado a cabo.

entrada se han escogido en base a datos que aparecen en la bibliografía intentando simular un amplio rango de cubiertas. Se han variado todos los parámetros excepto el LIDFa, LIDFb,  $f_B$  y  $D$  que se han mantenido constantes. El resultado serán 10000 espectros de reflectividad y absorptividad en el rango espectral comprendido entre los 400 y 2500 nm para dos geometrías distintas: una para la denominada geometría NADIR ( $\theta_s=60^\circ$ ,  $\theta_o=0^\circ$ ,  $\varphi=0^\circ$ ) y otra para la geometría Roujean-Bréon (RB) ( $\theta_s=60^\circ$ ,  $\theta_o=45^\circ$ ,  $\varphi=0^\circ$ ). Posteriormente, se calculará la  $fAPAR$  a partir de la expresión propuesta por Verhoef y Bach (2007):

$$fAPAR = \frac{\sum_{400}^{700} (\alpha_s E_{sun} + \alpha_d E_{sky})}{\sum_{400}^{700} E_{tot}} \quad (4)$$

donde  $E_{sun}$  y  $E_{sky}$  corresponden a la irradiancia solar directa y difusa a nivel del suelo entre 400 y 700 nm,  $\alpha_s$  es la absorción por parte de la cubierta del flujo solar incidente directo y  $\alpha_d$  la absorción del flujo solar incidente de la componente difusa que se obtienen de los modelos de transferencia radiativa. En nuestro caso, asumimos que la  $fAPAR$  diaria se aproxima a la fracción de absorción de la radiación por la vegetación en unas condiciones de *black-sky* (sin iluminación difusa) a las 10:00 hora local de un píxel centrado en la zona de estudio, en nuestro caso Madrid (40,418 N, 3,691 W). Esta  $fAPAR$  es una aproximación al valor diario integrado para días no nublados (Baret et al., 2006).

El ángulo cenital solar que se ha escogido para las 10:00 hora local en Madrid corresponde

aproximadamente a la media anual en Madrid ( $\theta_s=60^\circ$ ) para esa hora local, y que, junto el ángulo de observación y el ángulo acimutal relativo determinarán la geometría utilizada: geometría NADIR ( $\theta_s=60^\circ$ ,  $\theta_o=0^\circ$ ,  $\varphi=0^\circ$ ) y geometría RB ( $\theta_s=60^\circ$ ,  $\theta_o=45^\circ$ ,  $\varphi=0^\circ$ ). Por último y para tener únicamente en cuenta los elementos verdes de la vegetación, se han fijado a 0 los parámetros  $C_b$  (pigmentos marrones) y  $f_B$  (fracción de la componente marrón).

En los modelos de cubierta se ha utilizado como datos de suelo de fondo la contribución de dos espectros de suelos, uno brillante y otro más oscuro perteneciente a una zona de 125 km×125 km situada entre Castilla la Mancha y la Comunidad Valenciana, que consideramos como representativa de toda España (Eberle, 2007). El espectro del suelo utilizado depende de una variable llamada brillo ( $c$ ), que determina la contribución de los dos espectros. Si el brillo es 1, el espectro del suelo utilizado corresponde exactamente al suelo más brillante, mientras que si es 0, corresponde exactamente al suelo más oscuro. Un valor de 0,5 sería la media de los dos espectros. Para la base de datos, la variable brillo sigue una distribución uniforme entre los valores 0 y 1.

### 3.2. Inversión del modelo a partir de las RNAs

Una vez se tienen los valores simulados de  $fAPAR$  asociados a un conjunto de reflectividades se calculan las reflectividades en los canales del rojo

**Tabla 1.** Características y valores de los parámetros de entrada del modelo PROSPECT5 y 4SAIL2.

	Unidad	Mínimo	Media	Máximo	Desviación Estándar	Distribución	Fuente
<b>PROSPECT5</b>							
$N$	-	1	1,5	2,5	1	Gauss	Baret et al., (2007)
$C_{a+b}$	$\mu\text{g cm}^{-2}$	30	50	90	30	Gauss	Baret et al., (2007)
$C_m$	$\mu\text{g cm}^{-2}$	0,002	0,075	0,02	0,075	Gauss	Cernicharo (2010)
$C_w$	$\mu\text{g cm}^{-2}$	0	0,03	0,08	0,02	Gauss	Feret et al., (2008)
$C_b$	-	-	0	-	-	Gauss	Baret et al., (2007)
$Car$	$\mu\text{g cm}^{-2}$	0,6	5	15,8	-	Uniforme	Baret et al., (2007)
<b>4SAIL2</b>							
LAI	-	0	3	6	-	Uniforme	Baret et al., (2007)
LIDFa	-	-	-0,035	-	-	Constante	Baret et al., (2007)
LIDFb	-	-	-0,015	-	-	Constante	Baret et al., (2007)
Hot	-	0,001	0,01	1	0,3	Gauss	Baret et al., (2007)
$f_B$	-	-	0	-	-	Constante	Verhoef and Bach (2007)
$D$	-	-	0	-	-	Constante	Verhoef and Bach (2007)
$C_v$	-	0	0,5	1	0,2	Gauss	Baret et al., (2007)
$\xi$	-	0	0,5	1	-	Uniforme	Verhoef and Bache (2007)

(620-670 nm) e infrarrojo cercano (841-876 nm) de MODIS y se construye una base de 10000 datos con su fAPAR asociada. De esta nueva base de datos se utilizarán la mitad (5000) para entrenar la red.

La inversión a partir de las RNAs utilizando el conjunto de datos de simulación (5000) consistirá en un conjunto de entrenamiento (50%), un conjunto de hiperespecialización (25%) y un conjunto de validación (25%), con el fin de valorar la capacidad de generalización de la red y disponer de un elemento independiente para su verificación. En el proceso de entrenamiento se define el conjunto de datos a partir del cual se irá ajustando la red en función de la tasa de error escogida. El conjunto de hiperespecialización permite valorar la capacidad de generalización deteniendo el entrenamiento cuando los resultados dejen de mejorar y, por último, el conjunto de validación, no tendrá efecto en el entrenamiento pero ofrecerá un test independiente sobre el comportamiento y ajuste de la red. Los elementos asociados a cada uno de ellos se distribuirán aleatoriamente antes de cada lanzamiento. Cada ejecución consistirá en el lanzamiento de cinco redes eligiendo la que presente el menor error cuadrático medio promedio de los tres conjuntos. Este proceso se ha realizado un total de 3 veces para asegurar la estabilidad de los resultados de nuestra red neuronal.

Por último, a partir de los pesos y *bias* obtenidos de este proceso, se calculará la fAPAR con el resto de reflectividades (5000) no utilizadas de la base de datos inicial ( $fAPAR_{RNA}$ ). La  $fAPAR_{RNA}$  se comparará con los valores de fAPAR de la base de datos inicial ( $fAPAR_{PROSPECT+4SAIL2}$ ). La eficiencia del modelo de inversión se evaluará para las distintas geometrías a partir del error cuadrático medio (RMS) según la expresión 5, donde  $n$  representa el conjunto de 5000 datos. También se ha utilizado el parámetro *Signal-to-Noise Ratio* (SNR) definido por Leprieur *et al.* (1994) y utilizado comúnmente para evaluar la eficiencia de modelos e índices de vegetación. En nuestro caso, el SNR se ha calculado según la expresión 6 como la diferencia del valor medio entre la  $fAPAR_{RNA}$  y  $fAPAR_{PROSPECT+4SAIL2}$  para los valores máximo y mínimo proporcionados en el modelo, dividido por el RMS. El SNR incrementa a medida que lo hace la eficiencia del modelo, mientras que el RMS disminuye.

$$RMS = \sqrt{\frac{1}{n} \sum_{i=1}^n (fAPAR_{RNA_i} - fAPAR_{(PROSPECT+4SAIL2)_i})^2} \quad (5)$$

$$SNR = \frac{(fAPAR_{RNA}, fAPAR_{(PROSPECT+4SAIL2)})_{max}}{RMS} - \frac{(fAPAR_{RNA}, fAPAR_{(PROSPECT+4SAIL2)})_{min}}{RMS} \quad (6)$$

### 3.3. Aplicación a datos de satélite y comparación

Finalmente, una vez obtenidos los parámetros ajustados (pesos, *bias* y coeficientes) de la RNA se aplicará a imágenes de reflectividad para el año 2008 obtenidas a partir de los productos MCD43A1 y MCD43A2. Estos productos corresponden a las componentes isótropa ( $k_0$ ), geométrica ( $k_1$ ) y volumétrica ( $k_2$ ) para cada canal espectral proporcionados a 500 m cada 8 días con una composición temporal de 16 días. A partir de estos coeficientes se construye la reflectividad bidireccional (*Bidirectional Reflectance Distribution Function*, BRDF) utilizando el modelo BRDF de Ross-Li (Lutch y Roujean, 2000) para cada canal y píxel. Finalmente, se considera información incluida en las bandas de calidad (*Quality Flag*, QF) proporcionadas por el producto MCD43A2 para descartar píxeles contaminados por nubes y obtener la fAPAR diaria a partir de datos MODIS.

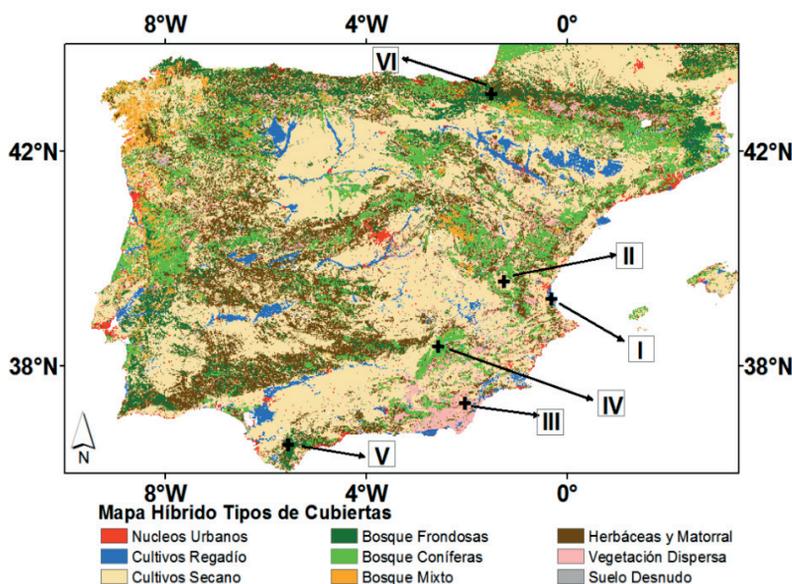
Se han considerado dos productos de fAPAR para comparar con el producto de fAPAR obtenido en este trabajo. El primero es el producto oficial de NASA (MOD15A2 colección 5) a 1 km, obtenido a partir de un algoritmo principal basado en un modelo tridimensional (3D) de transferencia radiativa para las condiciones espectrales y angulares de MODIS, así como para diferentes propiedades de suelo y vegetación (Knyazikhin *et al.*, 1998). En el algoritmo se comparan las reflectividades MODIS con las reflectividades simuladas y recogidas en una serie de LUTs específicas para 6 clases de vegetación. Cuando el algoritmo principal falla, se activa el algoritmo *backup*, el cual estima la fAPAR a partir de una relación con el NDVI que depende de la clasificación de vegetación (Myneni *et al.*, 1997). Este producto presenta una banda de calidad asociada que proporciona información sobre la presencia de nubes o la fiabilidad de las estimaciones.

El segundo producto considerado es la *f*APAR a 1 km utilizada en el proyecto ARTEMIS y calculada a partir del índice de vegetación RDVI (*Renormalized Difference Vegetation Index*) utilizando los parámetros ( $k_0$ ,  $k_1$  y  $k_2$ ) de la BRDF de MODIS (MCD43A1) y la geometría óptima en el plano principal RB ( $\theta_s=60^\circ$ ,  $\theta_v=45^\circ$ ,  $\varphi=0^\circ$ ) que reduce las incertidumbres debidas al tipo de cubierta y al suelo de fondo (Roujean y Bréon, 1995; Moreno, 2014). Este producto presenta también una banda de calidad asociada calculada a partir del producto MCD43A2 (Moreno, 2014). Esta metodología está basada en resultados obtenidos de la simulación con el modelo homogéneo SAIL. Este producto se ha validado de forma directa, con datos *in-situ*, e indirecta, a través de una inter-comparación con otros productos operacionales (Martínez et al., 2013). Esta metodología se utiliza actualmente para obtener el producto oficial de *f*APAR a partir de imágenes SEVIRI-MSG.

Para poder realizar una comparación de los tres productos de *f*APAR, se transformaron las imágenes de la proyección original MODIS (ISIN, *Integerized Sinusoidal*) al sistema de coordenadas geográficas WGS84 (*World Geodetic System 84*) y, excepto para el producto oficial de MODIS, se re-muestraron a una resolución espacial de 1 km.

La resolución temporal de los tres productos es cada 8 días. Además, cabe destacar que se han descartado en los tres productos de *f*APAR aquellos píxeles que presentaban un número de observaciones inferior al 75% en todo el año, bien por problemas en el algoritmo de RB y de MODIS o por presencia de nubes y nieve.

Además, se ha considerado un mapa híbrido de tipos de cubierta para evaluar los resultados obtenidos. Este mapa se deriva de la combinación de cuatro de los productos más utilizados en la actualidad (CGL2000, CORINE, MODIS y GlobCover) (Figura 2). El método aplicado para derivar este mapa se basa esencialmente en un esquema de votación donde se introducen dos propiedades importantes (Pérez-Hoyos et al., 2012): (1) el uso de la precisión de cada clase en cada uno de los productos considerados, lo que permite reducir las fuentes de error de cada producto individual, y (2) el uso del *Land Cover Classification System (LCCS)* como sistema de traducción entre leyendas, lo que permite reconciliar la ambigüedad entre las clases. La principal ventaja del mapa híbrido (Figura 2) generado es una mejor representación de los tipos de cubiertas en nuestra zona de estudio (Pérez-Hoyos et al., 2012).



**Figura 2.** Mapa híbrido de tipos de cubierta obtenido a partir de la combinación de los productos más utilizados en la actualidad (CGL2000, CORINE, MODIS y GlobCover). Además se ha incluido la localización de seis tipos de cubiertas consideradas en el estudio temporal. (Para la correcta interpretación del color en las gráficas, se remite al lector a la versión online. <http://dx.doi.org/10.4995/raet.2014.3177>).

**Tabla 2.** Localización y características de seis localizaciones seleccionadas.

Localización	Coordenadas	Clase	Composición	Región
I	39,26 N,-0,32 E	Cultivo regadío	<i>Oryza sativa</i>	Parque natural de la Albufera, Valencia
II	39,58 N,-1,26 E	Cultivo secano	<i>Vitis vinifera</i>	Utiel (Valencia)
III	36,94 N,-2,03 E	Herbáceas	<i>Alpha-steppes</i>	Balsa Blanca, Almería
IV	38,37 N,-2,57 E	Bosque coníferas	<i>Pinus nigra</i>	Parque natural de Cazorla, Jaén
V	36,54 N,-5,56 E	Bosque frondosas perenne	<i>Quercus suber</i>	Parque natural de los Alcornocales, Cádiz y Málaga
VI	43,07 N,-1,51 E	Bosque frondosas Caduca	<i>Fagus sylvatica</i>	Selva de Irati, Navarra

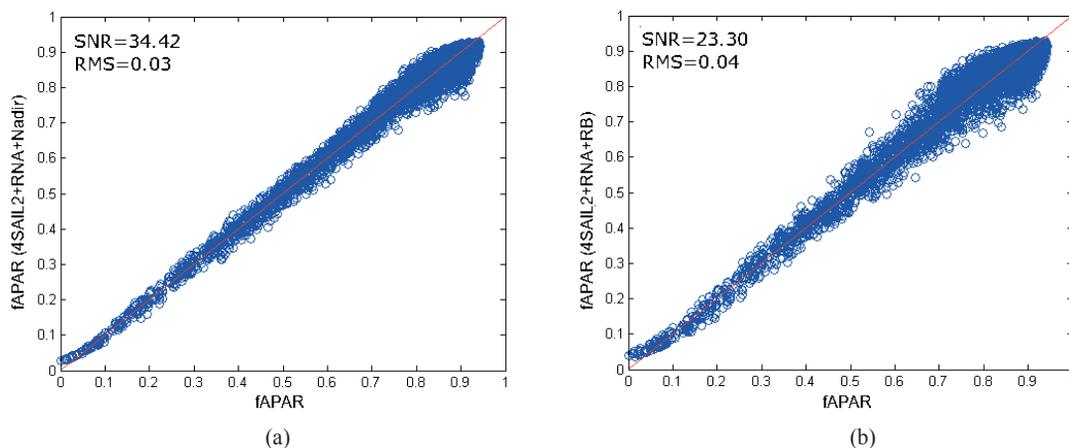
Por último y a falta de un conjunto extenso de medidas *in-situ* en la zona de estudio, se ha evaluado la consistencia temporal entre los tres productos de fAPAR en seis localizaciones caracterizadas por diferentes tipos de cubiertas (Figura 2 y Tabla 2). Las diferentes localizaciones se han elegido de forma que representen diferentes tipos de cubierta y de estructura de la planta (y por tanto diferente comportamiento radiativo). Se han escogido dos tipos de cultivos, uno de regadío (I) y otro de secano (II). El cultivo de regadío corresponde a una cubierta de arroz caracterizado por una cubierta verde muy densa y homogénea a finales de verano y suelo desnudo a principios de año, mientras que el cultivo de secano se localiza en la estación de validación VAS (*Valencia Anchor Station*) localizada en la meseta de Utiel-Requena donde se han realizado medidas *in-situ* de fAPAR. Además, se ha seleccionado una cubierta perteneciente a la clase de herbáceas (III), característica de una zona típica mediterránea con una alta respuesta a

factores climáticos (Bolle *et al.*, 2006) y tres cubiertas naturales correspondientes a diferentes tipos de bosques como, bosque de coníferas (IV) en el parque natural de Cazorla (Jaén), bosque de frondosas de hoja perenne (V) en el parque natural de los Alcornocales (Cádiz y Málaga) y bosque de hoja caduca (VI) en la Selva de Irati (Navarra).

## 4. Resultados y discusión

### 4.1. Simulación e inversión

La Figura 3 muestra el diagrama de dispersión de la fAPAR obtenida a partir del 4SAIL2 con las geometrías nadir y RB. Se ha obtenido un mayor SNR (34,42) y menor RMS (0,03) cuando se considera la observación nadir con respecto a la de RB (SNR=23,3, RMS=0,04). Además, se observa una mayor dispersión cuando se pasa de la geometría nadir a RB sobre todo para valores altos de fAPAR. En base a estos resultados,



**Figura 3.** Diagramas de dispersión entre la fAPAR obtenida a partir de la RNA y la fAPAR de la base de datos simulada con los modelos PROSPECT + 4SAIL2 para las dos geometrías de observación e iluminación propuestas: (a) Nadir y (b) RB.

la combinación de (PROSPECT+4SAIL2+Nadir) será la que utilizaremos para estimar la  $fAPAR$  a partir de los datos de reflectividad MODIS y así compararla con el producto ARTEMIS que sí que utiliza la configuración RB. En el apéndice A se pueden encontrar los valores de los pesos y *bias* de las redes neuronales para la  $fAPAR$  con esta combinación.

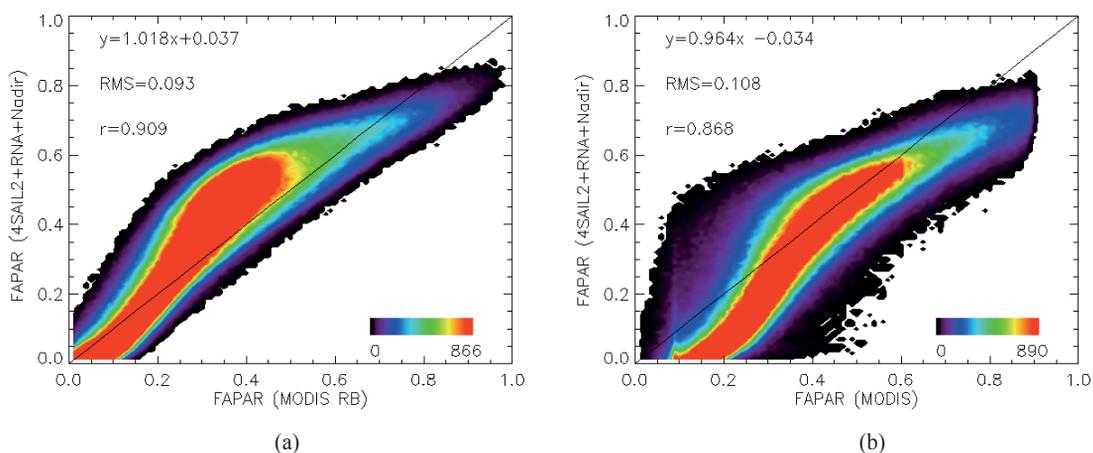
## 4.2. Aplicación a datos de satélite y comparación

La Figura 4 muestra los diagramas de dispersión entre el producto de  $fAPAR$  (4SAIL2+RNA+Nadir) con el producto MODIS RB (a) y con el producto MODIS (b). En ambos casos las correlaciones son altas con errores medios alrededor del exigido por los usuarios (0,1). Se observa un comportamiento no lineal en ambos casos con una tendencia a saturar en el caso del producto  $fAPAR$  de (4SAIL2+RNA+Nadir) para valores altos. Sin embargo, sí que se observa un mayor acuerdo para valores bajos de  $fAPAR$  entre los productos  $fAPAR$  (4SAIL2+RNA+Nadir) y MODIS RB, y para valores altos entre los productos  $fAPAR$  (4SAIL2+RNA+Nadir) y MODIS.

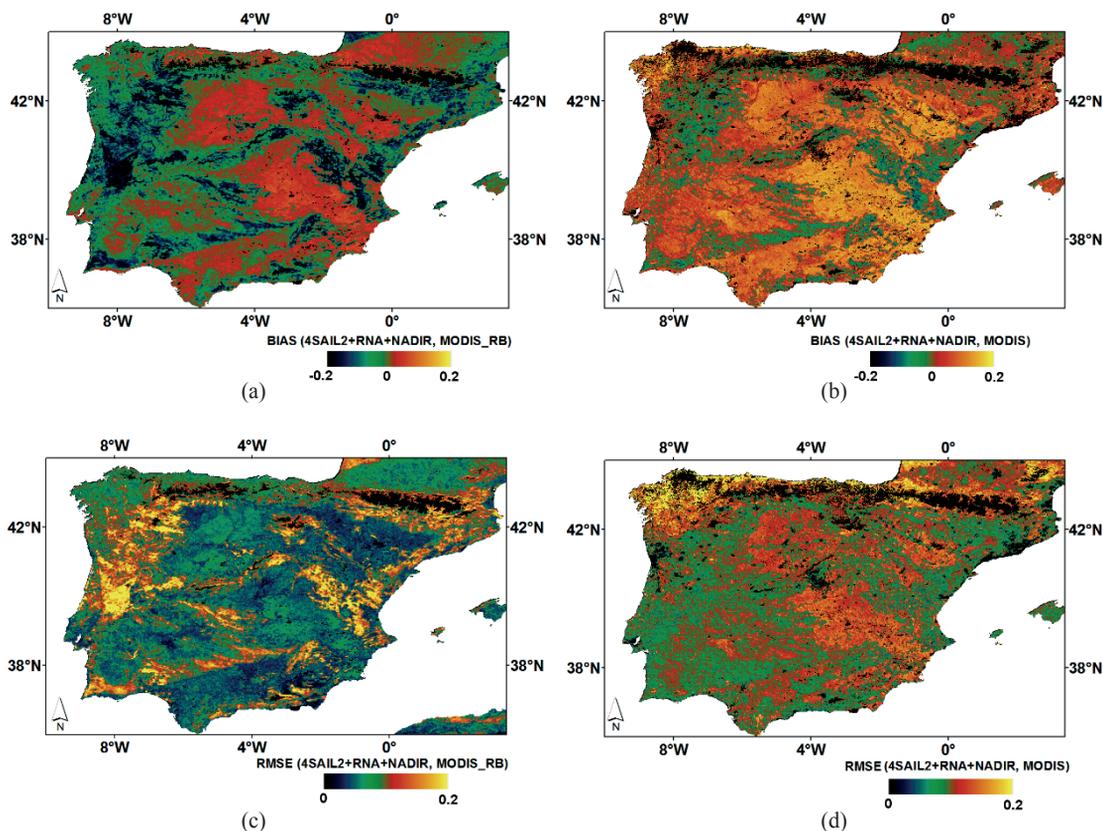
Las diferencias existentes entre las estimaciones del modelo (4SAIL2+RNA+Nadir) aplicado a datos MODIS y los dos productos de satélite elegidos, MODIS  $fAPAR$  y MODIS RB, se han evaluado a partir de la raíz cuadrada del error cuadrático medio (RMSE) y el error medio (*bias*) para

el año 2008 (Figura 5). En general, se observan valores más bajos del producto  $fAPAR$  MODIS RB (*bias*<0) con respecto al propuesto en la mayoría de la península, excepto para las zonas de cultivo donde el error sistemático es alrededor de cero. El error absoluto entre ambos productos para este periodo presenta valores menores de 0,1 para la mayoría de la península excepto en las clases de coníferas donde se llegan a alcanzar errores de hasta 0,2. Por el contrario, en el caso del producto  $fAPAR$  MODIS se observan valores más altos en la mayoría de la península, excepto en las principales zonas de bosques de coníferas (*bias*<0). El error absoluto de  $fAPAR$  MODIS con respecto al producto  $fAPAR$  (4SAIL2+RNA+Nadir) varía alrededor de 0,1 mostrando errores mayores (RMSE>0,1) sobre todo en las clases de bosque mixto y frondosas del norte de la península. En negro se muestran aquellos píxeles que se han enmascarado de acuerdo a la información de la calidad de cada producto. En ambos casos, se observa para el producto MODIS cómo estos píxeles afectan sobre todo al norte de la península, particularmente a la clase de frondosas.

Si evaluamos las diferencias por clases (Figura 6) se observa, tal como se ha visto en la Figura 5, errores absolutos mayores para el  $fAPAR$  MODIS, excepto en la clase de coníferas donde el producto  $fAPAR$  MODIS RB presenta mayores diferencias (RMSE>0,15). Los valores más altos de RMSE se han obtenido para las clases de bosque de frondosas y bosque mixto. Cabe destacar la



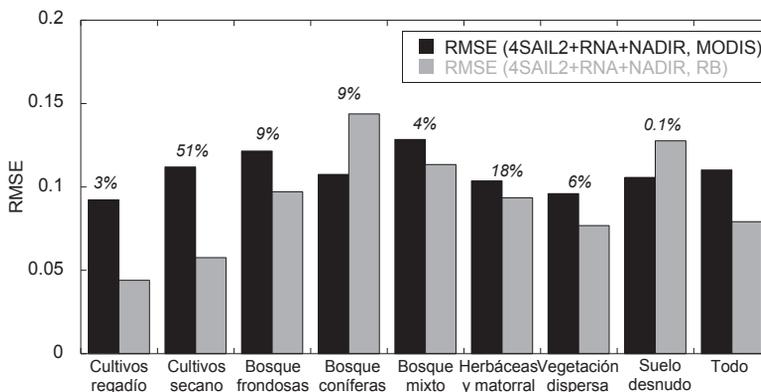
**Figura 4.** Diagramas de dispersión del producto  $fAPAR$  (4SAIL2+RNA+Nadir) con respecto a MODIS RB (a) y MODIS (b). Se ha representado en color la distribución de los datos. (Para la correcta interpretación del color en las gráficas, se remite al lector a la versión online. <http://dx.doi.org/10.4995/raet.2014.3177>).



**Figura 5.** RMSE entre la *f*APAR estimada con el modelo (4SAIL2+RNA+Nadir) y MODIS RB (a) y MODIS (b). *Bias* entre la *f*APAR estimada con el modelo (4SAIL2+RNA+Nadir) y MODIS RB (c) y MODIS (d). Ambos estadísticos se han calculado como la diferencia de los productos *f*APAR MODIS RB y *f*APAR MODIS frente al producto *f*APAR (4SAIL2+RNA+Nadir). (Para la correcta interpretación del color en las gráficas, se remite al lector a la versión online. <http://dx.doi.org/10.4995/raet.2014.3177>).

alta influencia del algoritmo *backup* de MODIS sobre todo en la clase de bosque de frondosas. En este caso, se ha observado que un 22% de los valores de *f*APAR emplean el algoritmo de *backup* de MODIS y que cuando estos valores no se consideran el producto MODIS disminuye su RMSE de 0,13 a 0,10 con respecto al producto *f*APAR (4SAIL2+RNA+Nadir). Por último, el producto *f*APAR MODIS presenta diferencias de hasta el doble con respecto al producto *f*APAR MODIS RB (RMSE=0,1) en las clases de cultivos de secano y regadío. El error absoluto considerando todas las clases es menor entre *f*APAR (4SAIL2+RNA+Nadir) y *f*APAR MODIS RB (RMSE=0,08) que cuando se compara con *f*APAR MODIS (RMSE=0,11).

La figura 7 muestra los perfiles correspondientes a los productos de *f*APAR (4SAIL2+RNA+Nadir), MODIS RB y MODIS para el año 2008 y los seis tipos de cubiertas descritos en la Tabla 2. Los perfiles corresponden a una media de 3×3 píxeles alrededor de las coordenadas del píxel central (Tabla 2) para evitar problemas de georreferenciación. Se han eliminado aquellos valores donde la información de calidad indicaba que había una alta presencia de nubes. Además, en el caso del producto MODIS se ha representado con un cuadrado aquellas fechas donde el valor de *f*APAR emplea el algoritmo *backup*. En general, se distinguen estos valores en los perfiles temporales de MODIS por presentar un comportamiento diferente al resto de las observaciones (e.g., una disminución brusca en la *f*APAR).



**Figura 6.** RMSE por clases obtenido al comparar el producto  $fAPAR$  (4SAIL2+RNA+Nadir) con los productos  $fAPAR$  MODIS RB (gris) y  $fAPAR$  MODIS (negro).

En el caso particular de la cubierta de arroz, los tres productos reproducen el aumento en la vegetación que ocurre en los meses de junio a agosto debido a la alta actividad fotosintética de la cubierta en su periodo de maduración (Gilabert y Meliá, 1990). Las principales diferencias entre los tres productos se observan desde el periodo de siega (de septiembre a noviembre) hasta el periodo de inundación (de noviembre a diciembre), donde  $fAPAR$  MODIS presenta valores más altos seguido de  $fAPAR$  (4SAIL2+RNA+Nadir). Ambos productos,  $fAPAR$  (4SAIL2+RNA+Nadir) y MODIS RB, reproducen el máximo relativo que se observa a finales de invierno donde la cubierta presenta principalmente suelo desnudo. Este máximo relativo se localiza entre dos mínimos de  $fAPAR$  asociados con la inundación de los campos en los meses de noviembre a diciembre y de abril a mayo. En este caso, el producto  $fAPAR$  MODIS proporciona valores poco realistas de hasta 0,2, ya que los campos están inundados.

Este comportamiento también se observa en la localización II correspondiente al cultivo de viña. En este caso, el producto  $fAPAR$  (4SAIL2+RNA+Nadir) proporciona valores de  $fAPAR$  muy próximos a cero como cabe esperar en el periodo de enero a abril, cuando la presencia de suelo desnudo en la zona es dominante. Los tres productos presentan un comportamiento similar en los meses de crecimiento de la planta, sin embargo, el producto MODIS es el que proporciona valores ligeramente superiores y una

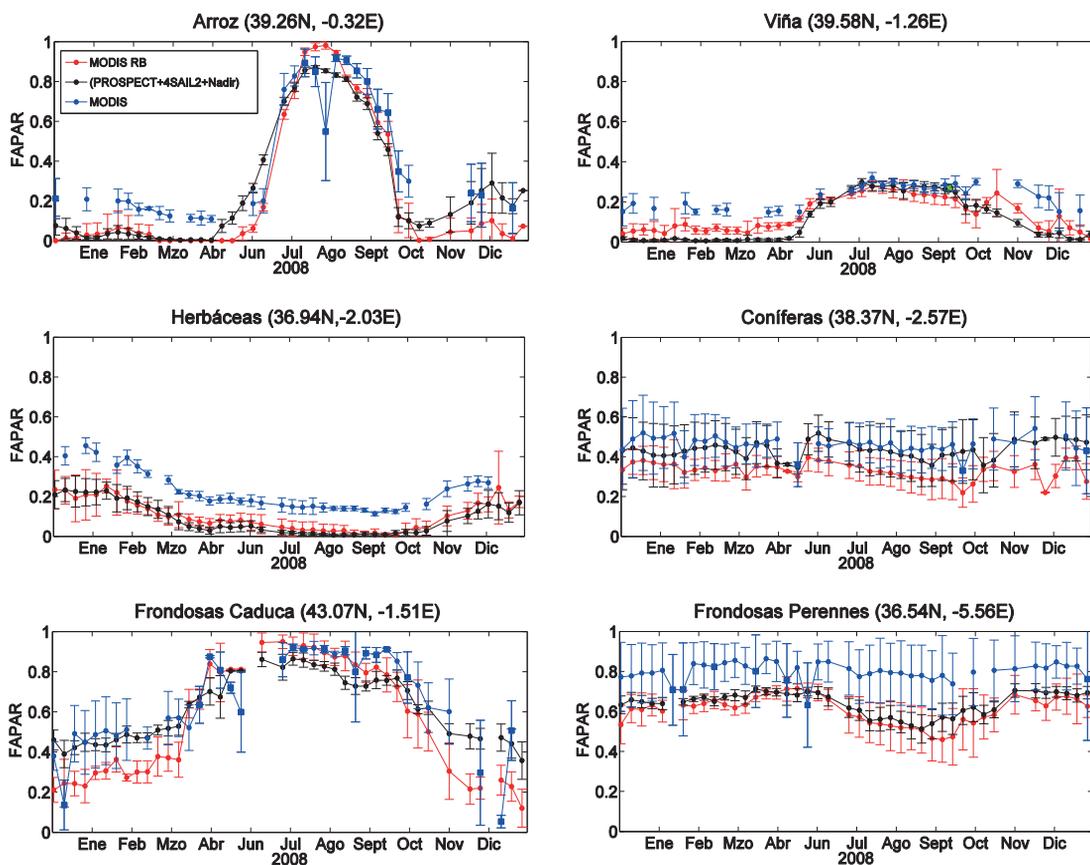
menor variabilidad en todo el periodo analizado. En esta localización se ha añadido un valor de  $fAPAR$  obtenido a partir de datos *in-situ* en el contexto de la validación de productos SMOS. La medida de  $fAPAR$  se localiza alrededor del máximo desarrollo de la cubierta (septiembre) y muestra un alto acuerdo con los tres productos de  $fAPAR$ , aunque ligeramente mejor con respecto a  $fAPAR$  (4SAIL2+RNA+Nadir) y  $fAPAR$  MODIS.

En el caso de la cubierta de herbáceas, los tres productos muestran una variabilidad intra-anual esperada asociada a factores climáticos; valores mínimos de  $fAPAR$  en los meses de verano y valores máximos en los meses de primavera y otoño. El producto  $fAPAR$  (4SAIL2+RNA+Nadir) muestra una alta similitud con el producto  $fAPAR$  MODIS RB con valores alrededor de 0,2, mientras que el producto  $fAPAR$  MODIS presenta valores más altos y menos realistas para esta clase de vegetación sobre todo en los meses de verano.

En el caso de la cubierta de bosque de coníferas, los tres productos muestran una baja variabilidad intra-anual debido a la alta adaptabilidad de este tipo de cubiertas al clima mediterráneo. Sin embargo, se observa una mayor discrepancia del producto  $fAPAR$  (4SAIL2+RNA+Nadir) con el de MODIS RB con respecto al resto de cubiertas, tal y como se ha visto en la Figura 6. Por último, las dos cubiertas correspondientes a bosques de frondosas muestran los valores más altos de  $fAPAR$  debido a su alta densidad en la cubierta lo

que lleva a una mayor absorción e intercepción de la PAR. En ambas cubiertas el producto  $fAPAR$  MODIS es el que presenta un perfil temporal con valores más altos de  $fAPAR$ , un mayor error y un descenso brusco de la  $fAPAR$  debido a diferencias en el algoritmo utilizado y en la detección de nubes. De hecho, la mayoría de los valores de  $fAPAR$  donde se observa este descenso brusco presentan una alta contribución de píxeles derivados a partir del algoritmo *backup* (diferenciado con un cuadrado azul en el perfil temporal). En el caso de la cubierta caduca de la selva de Irati, la serie temporal muestra el ciclo típico de una cubierta estacional ubicada en un espacio donde el régimen térmico no es excesivamente frío y el pluviométrico elevado. Esta combinación da lugar a un ciclo vegetativo prolongado, cuya

actividad fotosintética aumenta en los meses de abril a junio seguido de un suave descenso hacia julio y agosto. Esto es debido fundamentalmente a la falta de recursos hídricos y a un descenso más acusado en el periodo de senescencia. Los tres productos muestran una alta variabilidad intra-anual, más acusada en el caso de MODIS RB y con mayor ruido en el caso de  $fAPAR$  MODIS. El producto  $fAPAR$  (4SAIL2+RNA+Nadir) presenta una mayor similitud con el  $fAPAR$  MODIS, pero una mayor homogeneidad en los píxeles considerados en la zona de  $3 \times 3$  km<sup>2</sup> (menor barra de error). En el caso del bosque de hoja perenne se observa un ciclo vegetativo más corto, con una alta similitud entre los productos  $fAPAR$  MODIS RB y  $fAPAR$  (4SAIL2+RNA+Nadir). Ambos productos reflejan una leve disminución



**Figura 7.** Perfiles temporales de las localizaciones seleccionadas en la Tabla 2, correspondientes a los productos MODIS RB (rojo), MODIS (azul) y (4SAIL2+RNA+Nadir) (negro). El cuadrado representa los valores de MODIS obtenidos a partir del algoritmo *backup*. Se han eliminado aquellos valores que presentan más de un 50% de datos con presencia de nubes o no procesado. Las barras de error indican la desviación estándar alrededor del píxel central para una ventana de  $3 \text{ km} \times 3 \text{ km}$ . En verde se ha añadido una medida *in-situ* de  $fAPAR$  en la zona de Utiel. (Para la correcta interpretación del color en las gráficas, se remite al lector a la versión online. <http://dx.doi.org/10.4995/raet.2014.3177>).

de la  $fAPAR$  en el periodo estival con errores más altos en el caso del producto  $fAPAR$  MODIS RB.

## 5. Conclusiones

El objetivo de este trabajo ha consistido en la estimación de la  $fAPAR$  a partir de la combinación del modelo de transferencia radiativa de hoja PROSPECT y de cubiertas heterogéneas 4SAIL2 aplicados a la Península Ibérica. El trabajo está motivado por las diferencias encontradas en los diferentes productos operacionales de  $fAPAR$  globales y por la necesidad, como usuarios, de elegir un producto de  $fAPAR$  que se adapte a diferentes tipos de cubiertas presentes en la Península Ibérica para obtener estimaciones precisas de producción primaria bruta. Por ello, este estudio propone un método de estimación de la  $fAPAR$  a partir del modelo 4SAIL2 que considera el efecto de agrupamiento en la cubierta a partir de la fracción de cubierta vegetal ( $C_v$ ) y el factor de forma de los árboles ( $\zeta$ ) y, de este modo, no considera sólo cubiertas homogéneas como es el caso del MTR SAIL. Además, se han evaluado las diferencias debidas a dos configuraciones de geometría de observación e iluminación dado que son dos geometrías utilizadas por dos productos operacionales, como es el caso de MODIS y MSG.

Por lo que respecta a los resultados de la simulación podemos concluir que se ha observado poca influencia de la geometría de observación e iluminación en los valores de  $fAPAR$  simulados con el modelo de transferencia 4SAIL2, sobre todo en valores bajos de  $fAPAR$ . En nuestro caso, se ha optado por la combinación (PROSPECT+4SAIL2+Nadir) al mostrarse una reducción de la dispersión en valores altos de la  $fAPAR$ .

Las estimaciones de  $fAPAR$  a nivel de imagen presentan diferencias con respecto al producto oficial  $fAPAR$  de MODIS y al producto MODIS RB propuesto en ARTEMIS según el tipo de cubierta. En general, se ha observado un mayor ajuste del producto  $fAPAR$  (PROSPECT+4SAIL2+Nadir) con MODIS RB para valores bajos de  $fAPAR$  y con el producto oficial MODIS para valores altos. Espacialmente, se ha confirmado este comportamiento obteniéndose una mayor similitud con el producto MODIS RB sobre todo en las zonas de

cultivos. Este tipo de cubiertas presentan una distribución más homogénea y por tanto las diferencias entre los MTR utilizados en los dos productos (4SAIL2 y SAIL) se reducen. Sin embargo, se han observado diferencias más significativas con el producto MODIS RB en los bosques de coníferas, donde las diferencias entre un modelo homogéneo (SAIL) y heterogéneo (4SAIL2) se esperan mayores. Este tipo de cubiertas presentan un efecto de acoplamiento alto (Chen *et al.*, 2003) que el modelo homogéneo SAIL no considera, al contrario que el modelo 3D utilizado en el producto MODIS.

El estudio temporal realizado sobre las seis localizaciones ha puesto de manifiesto la capacidad del producto  $fAPAR$  (4SAIL2+RNA+Nadir) para caracterizar un amplio rango de tipos de cubiertas con diferentes comportamientos en la  $fAPAR$ . Al no disponer de datos *in-situ* en todas las zonas seleccionadas, es imposible extraer conclusiones sobre la exactitud de la variable estimada. Sin embargo, podemos decir que en el caso de vegetación dispersa y escasa, el producto  $fAPAR$  (4SAIL2+RNA+Nadir) se adapta muy bien, respondiendo a los rápidos crecimientos de las cubiertas y asemejándose más al producto MODIS RB. Mientras que el caso de cubiertas densas, el producto  $fAPAR$  (4SAIL2+RNA+Nadir) presenta en general un mayor acuerdo con el producto MODIS, sobre todo en los bosque de coníferas.

Por último y dada las diferencias obtenidas entre los productos MODIS y MODIS RB (alrededor de 0,1 en la mayoría de las cubiertas), podemos concluir que el producto derivado a partir de la combinación (4SAIL2+RNA+Nadir) ha demostrado ser una alternativa para estimar la  $fAPAR$  en la Península Ibérica. Sin embargo, las diferencias entre los productos de  $fAPAR$  propuestos no pueden ser atribuibles únicamente al modelo de transferencia radiativa para estimar la  $fAPAR$ , puesto que los productos se han derivado a partir de técnicas de inversión diferentes. Por lo que se requiere en un futuro de estudios más detallados que permitan evaluar las diferencias según el modelo de transferencia o la técnica de inversión con un mismo conjunto de datos. Finalmente, remarcar la necesidad de disponer de un conjunto de medidas *in-situ* con el fin de evaluar la incertidumbre de cada producto en el área de estudio.

## Apéndice A

**Tabla A.1.** Valores de los pesos y *bias* de la red neuronal para los datos simulados derivados con la combinación (4SAIL2+Nadir).

Neuronas	Capa oculta		Capa salida	
	5		1	
Función	Tansig	Tansig	Tansig	Tansig
Bias	B1	-3,54	B1	0,98
	B2	-3,60		
	B3	-0,52		
	B4	-7,19		
	B5	7,73		
Pesos	W11	1,13	W1	-15,6
	W12	-1,54		
	W21	-3,30	W2	0,19
	W22	-3,25		
	W31	-0,89	W3	0,93
	W32	1,15		
	W41	0,58	W4	-0,009
	W42	-20,6		
	W51	5,89	W5	15,7
	W52	0,23		

## Agradecimientos

Este trabajo ha sido financiado por los proyectos ARTEMIS (CGL2008–00381), RESET CLIMATE (CGL2012–35831) y LSA SAF de Eumetsat. Los autores agradecen los comentarios de los revisores que han ayudado a mejorar significativamente el trabajo. Los productos MCD43A1, MCD43A2 y MOD17A2 han sido proporcionadas por el centro de datos *Data Pool at the NASA Land Processes Distributed Active Archive Center (LP DAAC)*, *USGS/Earth Resources Observation and Science (EROS) Center*, Sioux Falls, South Dakota.

## Referencias

Bacour, C., Baret, F., Beal, D., Weiss, M., Pavageau, K. 2006. Neural network estimation of *LAI*, *fAPAR*, *fCover* and  $LAI \times C_{ab}$  from top of canopy MERIS reflectance data: principles and validation. *Remote Sensing of Environment*, 105(4): 313-325. <http://dx.doi.org/10.1016/j.rse.2006.07.014>

Baret, F., Guyot, G. 1991. Potentials and limits of vegetation indices for *LAI* and *APAR* assessment. *Remote Sensing of Environment*, 35(2-3): 161-173. [http://dx.doi.org/10.1016/0034-4257\(91\)90009-U](http://dx.doi.org/10.1016/0034-4257(91)90009-U)

Baret, F., Hagolle, O., Geiger, B., Bicheron, P., Miras, B., Huc, M. *et al.* 2007. *LAI*, *fAPAR* and *fCover* CYCLOPES global products derived from *VEGETATION*. Part 1: Principles of the algorithm. *Remote Sensing of Environment*, 110(3): 275-286. <http://dx.doi.org/10.1016/j.rse.2007.02.018>

Baret, F., Weiss, M., Lacaze, R., Camacho, F., Makhmara, H., Pacholczyk, P., Smets, B. 2013. *GEOV1: LAI* and *FAPAR* essential climate variables and *FCOVER* global time series capitalizing over existing products. Part1: Principles of development and production. *Remote Sensing of Environment*, 137: 299-309. <http://dx.doi.org/10.1016/j.rse.2012.12.027>

Bishop, C.M. 1996. *Neural networks: a pattern recognition perspective*. Clarendon press, 482 pp.

Bolle, H.-J., Eckardt, M., Koslowsky, D., Maselli, F., Meliá-Miralles, J., Menenti, M. 2006. *Mediterranean land-surface processes assessed from space*. Berlin: Springer, 760 pp. <http://dx.doi.org/10.1007/978-3-540-45310-9>

Camacho, F., Cernicharo, J., Lacaze, R., Baret, F., Weiss, M. 2013. *GEOV1: LAI, FAPAR Essential Climate Variables and FCOVER global time series capitalizing over existing products*. Part 2: validation and intercomparison with reference products. *Remote Sensing of Environment*, 137: 310-329. <http://dx.doi.org/10.1016/j.rse.2013.02.030>

Cernicharo, J. 2010. *Estimación del contenido de agua de la vegetación mediante inversión de modelos de transferencia radiativa a partir de redes neuronales*. Proyecto final de carrera, Escuela Técnica Superior de Ingenieros de Telecomunicación, Universidad Politécnica de Valencia. 65 pp.

Chen, J.M., Liu, J., Leblanc, S.G., Lacaze, R., Roujean, J.L. 2003. Multi-angular optical remote sensing for assessing vegetation structure and carbon absorption. *Remote Sensing of Environment*, 84(4): 516-525. [http://dx.doi.org/10.1016/S0034-4257\(02\)00150-5](http://dx.doi.org/10.1016/S0034-4257(02)00150-5)

Dawson, T.P., Curran, P.J., Plummer, S.E. 1998. *LIBERTY - Modeling the Effects of Leaf Biochemical Concentration on Reflectance Spectra*. *Remote Sensing of Environment*, 65(1): 50-60. [http://dx.doi.org/10.1016/S0034-4257\(98\)00007-8](http://dx.doi.org/10.1016/S0034-4257(98)00007-8)

Eberle, A. 2007. *Design of an optimized spectral index to estimate vegetation water content for the Iberian Peninsula using MODIS data*. Proyecto fin de carrera. Università degli Studi di Trento, 108 pp.

Féret, J.B., François, C., Asner, G.P., Gitelson, A.A., Martin, R.E., Bidet, L.P.R., Ustin, S.L., Le Maire, G., Jacquemoud, S. 2008. *PROSPECT-4* and *5: advances in the leaf optical properties model separating photosynthetic pigments*, *Remote Sensing of Environment*, 112(6): 3030-3043. <http://dx.doi.org/10.1016/j.rse.2008.02.012>

- Ganapol, B.D., Johnson, L.F., Hlavka, C.A., Peterson, D.L., Bond, B. 1998. LCM2: A coupled leaf/canopy radiative transfer model. *Remote Sensing of Environment*, 70(2): 153-166. [http://dx.doi.org/10.1016/S0034-4257\(99\)00030-9](http://dx.doi.org/10.1016/S0034-4257(99)00030-9)
- García-Haro, F.J., Camacho, F., Meliá, J. 2008. Vegetation Parameters Validation Report (VEGA VR), SAF/LAND/UV/VR VEGA/2.1, January 2008, 91 pp. Available on-line at <http://landsaf.meteo.pt> (accessed on 11 Novembre 2014).
- GCOS. 2006. Systematic observation requirements for satellite-based products for climate. (GCOS-107. WMO/TD No. 1338). September 2006. 103 pp. Geneve (Switzerland) Disponible en <http://www.wmo.int/pages/prog/gcos/Publications/gcos-107.pdf> (accessed on 11 Novembre 2014).
- GCOS. 2010. Implementation Plan for the Global Observing System for Climate in Support of the UNFCCC (2010 Update). GCOS-138 (GOOS-184, GTOS-76, WMO-TD/No. 1523), 180 pp. Geneve (Switzerland) Disponible en <http://www.wmo.int/pages/prog/gcos/Publications/gcos-138.pdf> (accessed on 11 Novembre 2014).
- Gilbert, M.A., Meliá, J. 1990. Usefulness of the temporal analysis and the normalized difference in the study of rice by means of Landsat-5 TM images: identification and inventory of rice fields. *Geocarto International*, 5(4): 17-26. <http://dx.doi.org/10.1080/10106049009354278>
- Gobron, N., Pinty, B., Verstraete, M., Govaerts, Y., 1999. The MERIS Global Vegetation Index (MGVI): description and preliminary application. *International Journal of Remote Sensing*, 20(9): 1917-1927. <http://dx.doi.org/10.1080/014311699212542>
- Gobron, N., Pinty, B., Aussedat, O., Chen, J.M., Cohen, W.B., Fensholt, R., et al. 2006. Evaluation of fraction of absorbed photosynthetically active radiation products for different canopy radiation transfer regimes: methodology and results using Joint Research Center products derived from SeaWiFS against ground-based estimations. *Journal of Geophysical Research*, 111 (D13):110, <http://dx.doi.org/10.1029/2005JD006511>.
- Haykin. S.S., 2009. *Neural networks and learning machines*, Vol. 10. 2009: Prentice Hall Upper Saddle River, NJ.
- Jacquemoud, S., Baret, F., 1990. PROSPECT: a model of leaf optical properties spectra. *Remote Sensing of Environment*, 34(2): 75-91. [http://dx.doi.org/10.1016/0034-4257\(90\)90100-Z](http://dx.doi.org/10.1016/0034-4257(90)90100-Z)
- Jacquemoud, S., Verhoef W., Baret, F., Bacour, C., et al., 2009. PROSPECT + SAIL Models: a review of use for vegetation characterization, *Remote Sensing of Environment*, 113: S56-S66. <http://dx.doi.org/10.1016/j.rse.2008.01.026>
- Knyazikhin, Y., Martonchik, J.V., Myneni, R.B., Dine, D.J., Running, S.W. 1998. Synergistic algorithm for estimating vegetation canopy leaf area index and fraction of absorbed photosynthetically active radiation from MODIS and MISR data. *Journal of Geophysical Research*, 103(D24): 32257-32275. <http://dx.doi.org/10.1029/98JD02462>
- Kuusk, A. 1995. A Markov chain model of canopy reflectance. *Agricultural and Forest Meteorology*, 76(3-4): 221-236. [http://dx.doi.org/10.1016/0168-1923\(94\)02216-7](http://dx.doi.org/10.1016/0168-1923(94)02216-7)
- Leprieur, D., Verstraete, M.M., Pinty, B. 1994. Evaluation of the performance of various vegetation indices to retrieve cover from AVHRR data. *Remote Sensing Reviews*, 10(4): 265-284. <http://dx.doi.org/10.1080/02757259409532250>
- Lourakis, M.I.A. 2005. A Brief Description of the Levenberg–Marquardt Algorithm Implemented by Levmar. Disponible en <http://users.ics.forth.gr/~lourakis/levmar/levmar.pdf> (accessed on 11 Novembre 2014).
- Lutch, W., Roujean, J.L. 2000. Considerations in the parametric modeling of BRDF and albedo from multiangle satellite sensor observations. *Remote Sensing Reviews*, 18(2-4): 343-380. <http://dx.doi.org/10.1080/02757250009532395>
- Madsen, K., Nielsen, H.B., Tingleff, O. 2004. Methods for Non-linear Least Squares Problems, second ed. IMM, Technical University of Denmark, 50 pp. Disponible en [http://www2.imm.dtu.dk/pubdb/views/publication\\_details.php?id=3215](http://www2.imm.dtu.dk/pubdb/views/publication_details.php?id=3215) (accessed on 11 Novembre 2014).
- Martínez B., Camacho, F., Verger, A., García-Haro, F.J., Gilbert, M.A. 2013. Intercomparison and quality assessment of MERIS, MODIS and SEVIRI FAPAR products over the Iberian Peninsula. *International Journal of Applied Earth Observation and Geoinformation*, 21: 463-476. <http://dx.doi.org/10.1016/j.jag.2012.06.010>
- Mccallum, I., Wagner, W., Schmulius, C., Shvidenko, A., Obersteiner, M., Fritz, S., Nilsson, S. 2010. Comparison of four global FAPAR datasets over Northern Eurasia for the year 2000. *Remote Sensing of Environment*, 114(5): 941-949. <http://dx.doi.org/10.1016/j.rse.2009.12.009>
- Moreno, A., 2014. *Retrieval and assessment of CO<sub>2</sub> uptake by Mediterranean ecosystems using remote sensing and meteorological data*. Tesis Doctoral, Universidad de Valencia, 172 pp.
- Myneni, R.B., Nemani, R.R., Running, S.W. 1997. Estimation of global leaf area index and absorbed par using radiative transfer models. *IEEE Transaction on Geoscience and Remote Sensing*, 35(6): 1380-1393. <http://dx.doi.org/10.1109/36.649788>

- Pérez-Hoyos, A., García-Haro, F.J., San Miguel Ayanz, J. 2012. A methodology to generate a synergetic land-cover map by fusion of different land-cover products. *International Journal of Applied Earth Observation and Geoinformation*, 19: 72-87. <http://dx.doi.org/10.1016/j.jag.2012.04.011>
- Rosema, A., Verhoef, W., Noorbergen, H., Borgesius, J.J. 1992. A new forest light interaction model in support of forest monitoring. *Remote Sensing of Environment*, 42(1): 23-41. [http://dx.doi.org/10.1016/0034-4257\(92\)90065-R](http://dx.doi.org/10.1016/0034-4257(92)90065-R)
- Roujean, J.L., Bréon, F.M. 1995. Estimating PAR absorbed by vegetation from bidirectional reflectance measurements. *Remote Sensing of Environment*, 51(3): 375-384. [http://dx.doi.org/10.1016/0034-4257\(94\)00114-3](http://dx.doi.org/10.1016/0034-4257(94)00114-3)
- Schaaf, C.B., Gao, F., Strahler, A.H., Lucht, W., Li, X., Tsang T., *et al.* 2002. First operational BRDF, albedo and Nadir reflectance products from MODIS. *Remote Sensing of Environment*, 83(1-2): 135-148. [http://dx.doi.org/10.1016/S0034-4257\(02\)00091-3](http://dx.doi.org/10.1016/S0034-4257(02)00091-3)
- Snyman, J.A. 2005. *Practical Mathematical Optimization: An introduction to basic optimization theory and classical and new gradient-based algorithms*. Springer Publishing, 257 pp.
- Verger, A., Baret, F., Weiss, M. 2008. Performances of neural networks for deriving LAI estimates from existing CYCLOPES and MODIS products, *Remote Sensing of Environment*, 112(6): 2789-2803. <http://dx.doi.org/10.1016/j.rse.2008.01.006>
- Verhoef, W. 1984. Light scattering by leaf layers with application to canopy reflectance modeling: The SAIL model. *Remote Sensing of Environment*, 16(2): 125-141. [http://dx.doi.org/10.1016/0034-4257\(84\)90057-9](http://dx.doi.org/10.1016/0034-4257(84)90057-9)
- Verhoef, W., Bach, H. 2007. Coupled soil-leaf-canopy and atmosphere radiative transfer modeling to simulate hyperspectral multi-angular surface reflectance and TOA radiance data. *Remote Sensing of Environment*, 109(2): 166-182. <http://dx.doi.org/10.1016/j.rse.2006.12.013>