

Memorias



Sociedad Latinoamericana en
Percepción Remota y Sistemas
de Información Espacial
Capítulo Colombia

30
AÑOS

Medellín, Colombia
29 de Septiembre al 3 de Octubre de 2014



Evaluación sistemática de diferentes métodos para la estimación de parámetros biofísicos por teledetección. Oportunidades para Sentinel-2

Systematic evaluation of different retrieval methods for the estimation of biophysical parameters from remote sensing data. Opportunities for Sentinel-2.

Juan Pablo Rivera, Jochem Verrelst, Jesús Delegido,
Gustavo Camps-Valls, José Moreno

Laboratorio de Procesado de Imágenes, Universidad de Valencia. C/ Catedrático José Beltrán, 2. 46980 Paterna (Valencia), España.

juan.rivera@uv.es, jesus.delegido@uv.es, jochem.verrelst@uv.es,
gcamps@uv.es, jose.moreno@uv.es

RESUMEN

El futuro satélite Sentinel-2 del programa Copernicus de la Agencia Espacial Europea, que será lanzado en 2015, está diseñado especialmente para el monitoreo de la cobertura terrestre, principalmente vegetación, mejorando la resolución espacial, espectral y el tiempo de revisita. El Laboratorio de Procesado de Imágenes de la Universidad de Valencia ha desarrollado la herramienta informática ARTMO que integra un conjunto de modelos de transferencia radiativa y tres módulos específicos para la estimación de parámetros biofísicos: índices espectrales, tablas de búsqueda, y algoritmos de regresión estadísticos. En este trabajo se han evaluado de manera sistemática los principales algoritmos para la estimación de uno de los principales parámetros biofísicos, el LAI, adaptándolos a Sentinel-2. Para índices espectrales el menor NRMSE se obtuvo con índices de 4 bandas de tipo

diferencias normalizadas con un valor de NRMSE de 11%. Los métodos estadísticos no paramétricos se muestran como los más robustos, en especial Gaussian Processes, que obtuvo un NRMSE de 8%. 18 funciones de mérito se han evaluado con el método de tablas de búsqueda donde la propuesta por Geman and McClure obtuvo el menor NRMSE con un valor de 14%. ARTMO se presenta como una herramienta óptima para el estudio de la vegetación.

Palabras claves: Sentinel-2, Parámetros biofísicos, Leaf Area Index, tablas de búsqueda, Índices espectrales, Machine learning

ABSTRACT

The forthcoming Sentinel-2 satellite from the Copernicus programme of the European Space Agency is dedicated to the monitoring of land surface such as terrestrial vegetation. Sentinel-2 is equipped with improved spatial, spectral and temporal resolution. The Image Processing Laboratory of the University of Valencia has recently developed a software tool called ARTMO, which integrates a set of radiative transfer models and dedicated toolboxes for the estimation of biophysical parameters. By using these toolboxes, a broad range of retrieval algorithms have been systematically evaluated in view of Sentinel-2 leaf area index (LAI) estimation. For each method the same field dataset was used which allowed a systematic and quantitative comparison.

Regarding LAI estimation based spectral indices, lowest normalized errors were achieved with a 4-bands index according to a NDVI-type formulation with a NRMSE of 11%. Non-

parametric regression methods performed on the whole more robust; especially Gaussian processes regression, which yielded a NRMSE of 8%. Finally, given look-up table based inversion the one proposal by Geman and McClure obtained lowest NRMSE with a value of 14%. Altogether, this study concludes that ARTMO's retrieval toolboxes are powerful tools for optimizing and automating vegetation properties mapping from Sentinel-2 data as well other optical remote sensing data.

Keywords: Sentinel-2, Leaf Area Index, Biophysical parameter retrieval, Spectral indices, Machine learning, Look-up table based inversion.

INTRODUCCIÓN

El gran avance de la teledetección durante los últimos años ha mejorado la comprensión de la relación entre la vegetación y el ciclo del carbono y cómo éste puede ser afectado por los cambios en los niveles de CO₂ y los usos de suelo (IPCC 2007). Para el estudio de estas dinámicas a escala global y local, han sido desarrollados diversos modelos que, en muchos casos, usan variables de entrada que son obtenidas mediante medidas de teledetección. El Global Climate Observing System (GCOS) ha determinado un conjunto de 50 variables climáticas esenciales (GCOS, 2014). En esta lista está incluido el índice de área foliar LAI.

Para la obtención de información, son necesarios métodos de procesado y estimación de parámetros biofísicos, ya que el sensor solo mide los flujos de energía reflejados por las cubiertas vegetales distribuidos espacialmente. Por ello, han sido desarrollados diversos métodos para la determinación de parámetros biofísicos por teledetección, que van desde

complejos modelos con base física hasta modelos estadísticos o la combinación de los anteriores. Estos métodos se pueden clasificar en tres familias de estimadores: 1. Paramétricos, 2. No paramétricos y 3. de base física.

La disponibilidad de datos de calidad ha sido siempre uno de los retos de las agencias espaciales ya que el monitoreo de la vegetación requiere de datos espectrales de calidad, adquiridos de manera regular y con un amplio registro de datos históricos para analizar la evolución espaciotemporal de la vegetación. Para ello, la Agencia Espacial Europea en el marco del programa **Copernicus**, ha desarrollado la misión Sentinel-2 que está especialmente diseñada para el monitoreo de las propiedades de la vegetación, con las capacidades operativas que cumplen los requerimientos espectrales, espaciales y temporales (Drusch et al., 2012).

Para el procesamiento y la extracción de información de parámetros biofísicos han sido desarrollados diferentes paquetes computacionales. En este trabajo se han reunido los principales métodos de estimación que van desde las simples relaciones espectrales hasta los complejos modelos de transferencia radiativa (RTM) evaluándolas de manera sistemática para la estimación del LAI, parámetro fundamental para los estudios de vegetación pues proporciona la superficie total de hojas verdes por unidad de área de suelo. Dicha evaluación se ha realizado con la herramienta informática llamado ARTMO (por sus siglas en inglés Automated Radiative Transfer Models Operator) (Verrelst *et al.* 2011 y Rivera 2011). Esta herramienta cuenta con un completo conjunto de módulos para la estimación de los parámetros biofísicos, de forma que cada módulo está diseñado de

manera específica para cada método de estimación. El módulo de índices espectrales (Rivera *et al.* 2014a) permite la creación y evaluación de índices espectrales de hasta 10 combinaciones de bandas. El módulo de “Machine Learnig” (Rivera *et al.* 2014b) dispone de un conjunto de métodos estadísticos paramétricos y no paramétricos desarrollados para la estimación de parámetros biofísicos a partir de datos espectrales. Los algoritmos usados en este módulo están basados en el trabajo realizado por Camps *et al.* (2013). El módulo de tablas de búsqueda (Rivera *et al.* 2013), estima la información de los parámetros biofísicos a partir de las medidas espectrales simuladas por modelos de transferencia radiativos usando el funciones de mérito – FM que comparan la similitud entre los espectros evaluados. En este módulo se han implementado alrededor de 60 funciones de mérito tomando como base el trabajo de Leonenko *et al.* (2013).

ARTMO está disponible de manera gratuita, y para su descarga es necesario el registro en su web (<http://ipl.uv.es/artmo/>).

El objetivo de este trabajo es evaluar de manera sistemática los principales algoritmos de estimación paramétricos, no paramétricos y de base física para la estimación del índice de área foliar – LAI, usando los datos de la campaña SPARC. Y presentar además, las principales facilidades que entrega ARTMO para la estimación de parámetros biofísicos.

MATERIALES Y MÉTODOS

Datos de campo

Los datos para el entrenamiento y la validación de los diferentes métodos evaluados provienen de la campaña SPARC (SPectra bARrax Campaign) realizada por la ESA durante el 2003 en la zona de Barrax, Castilla la Mancha, España (30°3'N, 2°6'W, 700 m.s.n.m). Se contaron con 103 unidades elementales de muestreo (ESU por sus siglas en inglés, Elementary Sampling Units) donde se obtuvieron medidas del LAI con el instrumento digital LiCor LAI-2000. Las medidas espectrales se adquirieron con un sensor aerotransportado HyMAP que cuenta con 128 bandas en un rango espectral de 400 nm. a 2500 nm, con un ancho de bandas entre los 10 y 20 nm., y una resolución radiométrica y espacial de 12 bits y 5 m respectivamente.

Sentinel 2

Sentinel-2 (S2) es uno de las seis familias de satélites que integrarán el núcleo de la red de vigilancia medioambiental europea **Copernicus**. Su objetivo es el monitoreo y el estudio de las cubiertas vegetales. Su configuración de bandas, junto con el periodo de revisita proporcionará datos únicos para el estudio de la Biosfera (Drusch *et al.* 2012). Un resumen de la configuración de las bandas previstas para S2 se muestra en la Tabla 1. En el presente trabajo los datos de la campaña SPARC obtenidos a partir de las imágenes adquiridas por el sensor HyMap han sido remuestreadas espacial y espectralmente a la configuración de S2

usando el método del vecino más próximo y filtro gaussiano respectivamente. Las bandas usadas se encuentran resaltadas en la Tabla 1.

Tabla 1. Configuración espectral de S2

	ID bandas S2												
	B1	B2	B3	B4	B5	B6	B7	B8	B8a	B9	B10	B11	B12
Banda central (nm)	443	490	560	665	705	740	783	842	865	942	1375	1610	2190
Ancho banda (nm)	20	65	35	30	15	15	20	115	20	20	30	90	180
Resolución espacial (m)	60	10	10	10	20	20	20	10	20	60	60	20	20

Diseño experimental

Para la estimación de LAI se han empleado índices espectrales, métodos no paramétricos y tablas de consulta. Se han entrenado usando el 50% de los datos de la campaña SPARC y se han validado con el restante 50%. La evaluación de los métodos se realizó con los estadísticos de: error medio cuadrático medio (RMSE), error cuadrático medio normalizado (NRMSE) y coeficiente de determinación (R^2).

Métodos de estimación

Índices espectrales

Se evaluaron 4 índices espectrales genéricos usando el módulo de índices espectrales de ARTMO, uno de tipo ratio simple (Eq. 1), otro de tipo diferencias normalizadas (Eq. 2) y dos índices que mantienen la estructura de las diferencias normalizadas pero evalúan la

combinación de 3 (Eq. 3) y 4 (Eq.4) bandas. La ecuación de ajuste entre el índice espectral y el LAI fue de tipo lineal y se han evaluado todas las combinaciones de bandas.

$$\text{Ratio simple [SR]} = \frac{B_2}{B_1} \quad (1)$$

$$\text{Diferencias normalizada [ND]} = \frac{(B_2 - B_1)}{(B_2 + B_1)} \quad (2)$$

$$\text{Indice 3bandas[SR3B]} = \frac{(B_2 - B_1)}{(B_2 + B_3)} \quad (3)$$

$$\text{Indice 4bandas [SR4B]} = \frac{(B_2 - B_1)}{(B_3 + B_4)} \quad (4)$$

Donde, B_i es la banda espectral i de las simuladas para S2.

Métodos estadísticos no paramétricos

Se ha empleado el módulo de “Machine learning” – MLRA en ARTMO (Rivera et al. 2014b), para evaluar 11 algoritmos paramétricos y no paramétricos. La Tabla 2 muestra el listado de los algoritmos usado para la estimación de LAI.

Tabla 2. Métodos estadísticos no paramétricos evaluados para la estimación de LAI

Método estadístico de regresión
Kernel Ridge Regression
Gaussian Processes Regression
Neural Network
VH. Gaussians Processes Regression
Extreme Learning Machine
Bagging trees
Relevance vector Machine
Boosting trees
Partial least squares regression
Regression tree
Principal components regression

Tablas de búsqueda (LUT)

Se construyó una LUT de 100.000 simulaciones usando los modelos de transferencia radiativa PROSPECT-4 y 4SAIL (PROSAIL). La Tabla 3 muestra los valores usados para la parametrización de los modelos.

Tabla 3. Parametrización de los modelos PROSAIL.

	<i>Parámetro</i>	<i>Unid.</i>	<i>Rango</i>	<i>Distribución</i>
PROSPECT 4	Índice estructura	n.a.	1	n.a.
	Cont. clorofila	mg/cm ²	0-75	Gaussiana (m:35/std:30)
	Cont. mat. seca	g/cm ²	0,001-0,03	Uniforme
	Cont. agua	cm	0,002-0,05	Uniforme
4SAIL	Índice área foliar	m ² /m ²	0,1-7	Gaussiana (m:3/std:2)
	% Hum. suelo	n.a.	0-1	Uniforme
	Ang. incl. hojas	°C	40-70	Uniforme
	Factor Hot Sopt	m/m	0,05-0,5	Uniforme
	Fracc. rad. difusa	%	0,05	n.a
	Ang. solar zenital	°C	22,3	n.a
	Ang. zenital de obs.	°C	0	n.a
	Ang. Rel. azimutal	°C	0	n.a

En el método de inversión por LUT, la función de mérito (FM) permite medir la distancia entre los espectros simulados o medidos en campo/laboratorio (Q) y los medidos por un sensor remoto (P), donde $D[P,Q]$ representa la distancia entre dos espectros. Leonenko *et al.* (2013) ha presentado un conjunto de más de 60 FM agrupadas en tres familias: f-divergence, M-estimates y mínimo contraste. Un ejemplo de dichas FM se pueden ver en la Tabla 4. Verrelst *et al.* (2014) han evaluado el impacto de las FM juntos con diferentes opciones de ajuste.

Tabla 4. Ejemplos de FM por tipo de familia y su formulación matemática

Familia	Función de mérito	Ecuación
f-divergence	Kullback Leibler	$D[P, Q] = \sum_{\lambda_1=1}^{\lambda_n} p(\lambda_i) \ln \left(\frac{p(\lambda_i)}{q(\lambda_i)} \right)$
M-estimates	LSE	$D[P, Q] = \sum_{\lambda_1=1}^{\lambda_n} (p(\lambda_i) - q(\lambda_i))^2$
Mínimos contraste	$K(x) = x \log x - x$	$D[P, Q] = 1 + \sum_{\lambda_1=1}^{\lambda_n} \frac{q(\lambda_i)}{p(\lambda_i)} \left\{ \log \left(\frac{q(\lambda_i)}{p(\lambda_i)} \right) - 1 \right\}$

La Tabla 5 muestra el listado de las FM evaluadas en el presente trabajo, donde de manera sistemática se estudió la adicción de ruido gaussiano a los datos simulados con PROSAIL y el porcentaje de múltiples soluciones según la metodología presentada en Verrelst *et al.* (2014) y Rivera *et al.* (2013).

Tabla 5. Listado de FM evaluadas para la estimación de LAI

Función de Mérito	
Shannon (1948)	$K(x) = (\log(x))^2$
Laplace distribution	K-divergence Lin
Neyman chi-square	Shannon entropy
Pearson chi-square	Gen. Kullback-Leibler
Least absolute error	Neg. Exp. disparity
Geman and McClure	Kullback-leibler
RMSE	$K(x) = \log(x) + 1/x$
Exponential	Harmonique Toussaint
$K(x) = x(\log(x)) - x$	$K(x) = -\log(x) + x$

RESULTADOS

Índices espectrales

Se han evaluado 4 índices espectrales que combinan 2, 3 y 4 bandas (Eq. 1-2-3-4), usando funciones de ajuste lineal. La Tabla 6 muestra las mejores combinaciones espectrales que se han obtenido con el menor NRMSE para cada índice espectral evaluado.


Tabla 6. Combinación espectral con menor NRMSE para los índices espectrales evaluados

Índice Espectral	Bandas	RMSE	NRMSE	R ²
ND4B	B1=560;B2=2190;B3=490;B4=1610	0.50	10.80	0.84
ND3B	B1=1610;B2=2190;B3=490	0.51	11.26	0.83
SR	B1=2190;B2=1610	0.72	11.93	0.81
ND	B1=1610;B2=2190	0.73	12.21	0.80


Los resultados muestran que el aumentar la información espectral en los índices permite disminuir el NRMSE y mejorar el R². Se observa que los mejores resultados en todas las bandas vinculan las bandas del SWIR donde el impacto de los componentes bioquímicos como la celulosa y el contenido de agua en la cubierta es mayor.

La Figura 1 muestra algunas de las facilidades que ofrece el módulo de índices espectrales para el análisis de la estimación de parámetros biofísicos. La Fig. 1 (a) muestra la matriz de impacto, donde el eje x y el eje y representan las bandas espectrales que se combinan, el color de cada par (x, y) muestra el valor de R² obtenido para el índice espectral de diferencias normalizadas. La Fig. 1 (b) muestra el gráfico de dispersión entre los valores de

LAI medidos en SPARC (eje x) y los valores estimados (eje y) por el índice espectral de 4 bandas.



(a). Matriz de impacto índice ND



(b). Gráfico de dispersión de LAI con el índice ND4B

Figura 1. Herramientas de análisis disponibles en el módulo de índices espectrales

La Figura 2 muestra los mapas de LAI obtenidos con los índices ND, ND3B y ND4B. Una comparación visual de los mapas permite observar que ND sobre estima los valores bajos de LAI en comparación con los otros dos índices, mientras que subestima los valores altos. Comparando ND3B y ND4B se puede observar que los valores medios de LAI entre 2 y 3.5 son ligeramente sobre estimados en el índice ND3B.

Métodos estadísticos (paramétricos y no paramétricos)

La Tabla 7 muestra los resultados de la evaluación de 11 métodos estadísticos entre paramétricos y no paramétricos. La tabla muestra los estadísticos usados para la evaluación de la robustez de algoritmo.




Figura 2. Mapas de LAI estimados a partir de los índices espectrales ND, SR3N y SR4B


Tabla 7. Valores de RMSE, NRMSE y R^2 de los algoritmos en el módulo de MLRA

Método Estadístico	RMSE	NRMSE	R^2
Support Vector Regression	0.49	8.22	0.91
Kernel ridge Regression	0.50	8.38	0.91
VH. Gaussian Processes Regression	0.51	8.61	0.91
Gaussian Processes Regression	0.52	8.66	0.91
Extreme Learning Machine	0.57	9.53	0.89
Least squares linear regression	0.57	9.55	0.89
Bagging trees	0.59	9.92	0.88
Neural Network	0.60	10.04	0.88
Relevance vector Marchine	0.63	10.58	0.85
Regression tree	0.73	12.21	0.81
Boosting trees	0.75	12.55	0.81
Partial least squares regression	0.75	12.61	0.80
Principal components regression	0.80	13.31	0.78


Los resultados muestran que los métodos no paramétricas de tipo Kernel, ofrecen un menor error en la estimación del LAI. El mejor resultado se obtuvo con el algoritmo de Support

Vector Regression, con un NRMSE de 8%, pero no se aprecian diferencias significativas entre los demás métodos tipo Kernel.

Dentro de grupo de algoritmos tipo Kernel se destaca Gaussian Processes Regression – GPR, ya que al basarse en métodos bayesianos, entrega información adicional como la incertidumbre de la estimación y el valor de relevancia que tiene cada banda en la estimación del parámetro biofísico. La Figura 3 muestra un ejemplo de las facilidades que ofrece el módulo de MLRA. La Fig. 3 a muestra en forma de gráficos de barras el valor de sigma calculado por GPR para estimar la relevancia que tiene cada banda, donde los valores bajos indican las bandas más relevantes. (b) El gráfico de dispersión compara los valores de LAI medidos en la campaña SPARC en el eje x y los estimados por GPR en el eje y.



(a). Gráfico de barras de los valore de sigmas de las bandas de S2.



(b). Gráfico de dispersión GPR.

Figura 3. Facilidades para el análisis de resultados del módulo MLRA para la estimación de parámetros biofísicos.

La Figura 4 muestra los mapas de LAI, incertidumbre e incertidumbre relativa entregados por el algoritmo de GPR. Los datos de incertidumbre muestran que las zonas de cultivos bajo riego cuentan con menor incertidumbre, mientras que las zonas de barbecho, matorral y suelo desnudo presentan altos valores de incertidumbre, lo cual se justifica ya que los datos de la campaña SPARC están tomados principalmente en zonas de regadío, mientras que son pocos los datos de suelo desnudo, barbecho y matorral usados para este estudio.




Figura 4. Valor medio predicho, incertidumbre e incertidumbre relativa de la estimación de LAI con GPR.

Tabla de búsqueda (LUT)

La Tabla 8 muestra los resultados de la evaluación de 18 FM. En ella se muestra el porcentaje de ruido gaussiano aplicado a los datos simulados con PROSAIL, junto al porcentaje de los mejores resultados para promediar el valor estimado de LAI, además de

los estadísticos de RMSE, NRMSE y R^2 . Este método presenta los mayores errores relativos calculados llegando a valores de 35%. Los mejores resultados se encontraron con la FM Geman and McClure con un NRMSE de 14%.

Tabla 8. FM evaluadas para la estimación de LAI

FM	% Ruido	% Mejores resultados	RMSE	NRMSE	R^2
<i>Geman and McClure</i>	16	2	0.83	14.36	0.71
RMSE	16	2	0.83	14.37	0.71
Exponential	16	2	0.85	14.66	0.71
Laplace distribution	6	mejor estimado	0.86	14.74	0.74
Least absolute error	6	mejor estimado	0.89	15.28	0.72
Neyman chi-square	0	mejor estimado	0.89	15.31	0.74
Shannon (1948)	14	mejor estimado	0.96	16.56	0.76
$K(x)=(\log(x))^2$	0	2	1.01	17.4	0.69
Pearson chi-square	16	mejor estimado	1.03	17.74	0.73
Neg. Exp. disparity	0	4	1.04	17.96	0.58
$K(x)=x(\log(x))-x$	20	mejor estimado	1.06	18.25	0.7
Shannon entropy	6	2	1.15	19.82	0.6
Gen. Kullback-Leibler	10	2	1.2	20.63	0.58
Harmonique Toussaint	2	20	1.57	27.04	0.54
Kullback-leibler	4	18	1.66	28.62	0.57
$K(x)=-\log(x)+x$	2	2	1.77	30.52	0.49
$K(x)=\log(x)+1/x$	2	mejor estimado	2.07	35.65	0.55
K-divergence Lin	4	mejor estimado	2.6	44.84	0.64

La Figura 5 muestra el mapa estimado con la FM Geman and McClure junto con la configuración obtenida para la estimación de LAI. El mapa presenta una mayor variabilidad en las zonas de regadío, con valores de LAI altos en algunas zonas comparando con el resto de modelos. Las zonas de matorral, barbecho y suelo desnudo están subestimadas, presentando poca variabilidad.



Figura 5. Mapa de LAI estimado con la FM Geman and McClure

CONCLUSIONES

La evaluación de tres métodos de estimación de parámetros biofísicos, con datos simulados del satélite S2, a partir de datos de campo de la campaña SPARC tomados en 2003 en Barrax, España, confirma la óptima configuración de S2 para el monitoreo de la vegetación. Las bandas más relevantes para la estimación del LAI son las bandas de SWIR en especial la banda de 2190 nm. y en el visible las bandas de 490 nm. y 560 nm. La herramienta ARTMO junto con su conjunto de módulos diseñados especialmente para la estimación de parámetros biofísicos es una herramienta de una gran versatilidad que permite abarcar los principales y más novedosos métodos tanto estadísticos como de base física. Cada método evaluado presenta sus ventajas e inconvenientes. Los métodos de índices espectrales y MLRA son más rápidos y precisos pero necesitan datos para el entrenamiento de los

modelos. El método de LUT es más lento en la inversión ya que lo hace pixel a pixel y aunque no necesita datos para entrenar, la parametrización de los datos de entrada son claves para la estimación de los parámetros biofísicos.

AGRADECIMIENTOS

Este trabajo ha sido posible gracias al Proyecto AYA2010-21432-C02-01 del Ministerio de Economía y Competitividad de España.

REFERENCIAS

Camps-Valls, G., Gómez-Chova, L., Muñoz-Marí, J., Lázaro-Gredilla, M., and Verrelst, J. (2013). simpleR: A simple educational Matlab toolbox for statistical regression. V2.1. <http://www.uv.es/gcamps/code/simpleR.html>

Drusch, M., Del Bello, U., Carlier, S., Colin, O., Fernandez, V., Gascon, F., Hoersch, B., Isola, C., Laberinti, P., Martimort, P., Meygret, A., Spoto, F., Sy, O., Marchese, F., and Bargellini, P. (2012). Sentinel-2: ESA's optical high-resolution mission for GMES operational services. *Remote Sensing of Environment*, 120, 25–36.

Drusch, M., Del Bello, U., Carlier, S., Colin, O., Fernandez, V., Gascon, F., Hoersch, B., Isola, C., Laberinti, P., Martimort, P., Meygret, A., Spoto, F., Sy, O., Marchese, F. & Bargellini, P. (2012). Sentinel-2: ESA's Optical High-Resolution Mission for GMES Operational Services. *Remote Sensing of Environment*, 120, 25-36.

GCOS (2014). GCOS essential climate variables. visitado el 19 de Julio de 2014, en <http://www.wmo.int/pages/prog/gcos/index.php?name=EssentialClimateVariables>

IPCC (2007). Climate change 2007: the physical science basis. Contribution of Working Group I to the Fourth Assessment Report of the Intergovernmental Panel on Climate Change, page 996.

Leonenko, G., North, P. & Los, S. (2013). Statistical distances and their applications to biophysical parameter estimation: Information measures, M-estimates, and minimum contrast methods. *Remote Sensing*, 5, 1355-1388.

Rivera, J. (2011). Desarrollo de una herramienta informática para el estudio de la interacción de la radiación solar con las cubiertas vegetales. Master's thesis, Image Processing Laboratory (IPL), University of Valencia, Spain.

Rivera, J., Verrelst, J., Leonenko, G., and Moreno, J. (2013). Multiple cost functions and regularization options for improved retrieval of leaf chlorophyll content and LAI through inversion of the PROSAIL model. *Remote Sensing*, 5(7), 3280–3304.

Rivera, J.P., Verrelst, J., Delegido, J., Veroustraete, F., Moreno, J., (2014a). On the semiautomatic retrieval of biophysical parameters based on spectral index optimization. *Remote Sens.* 6(6), 4927-4951

Rivera, J.P., Verrelst, J., Muñoz-Marí, J., Moreno, J., Camps-Valls, G., (2014b). Toward a semiautomatic machine learning retrieval of biophysical parameters. *IEEE Journal of*

Selected Topics in Applied Earth Observation and Remote Sensing, vol.7, no.4, pp.1249,1259

Verrelst, J., Rivera, J., Alonso, L., and Moreno, J. (2011). ARTMO: an Automated Radiative Transfer Models Operator toolbox for automated retrieval of biophysical parameters through model inversion. Proceedings of EARSeL 7th SIG-Imaging Spectroscopy Workshop 2011, 11-13 April, Edinburgh, UK.

Verrelst, J., Rivera, J., Leonenko, G., Alonso, L., and Moreno, J. (2014). Optimizing LUT-Based RTM Inversion for Semiautomatic Mapping of Crop Biophysical Parameters from Sentinel-2 and -3 Data: Role of Cost Functions. IEEE Transactions on Geoscience and Remote Sensing, 52(1), 257–269.