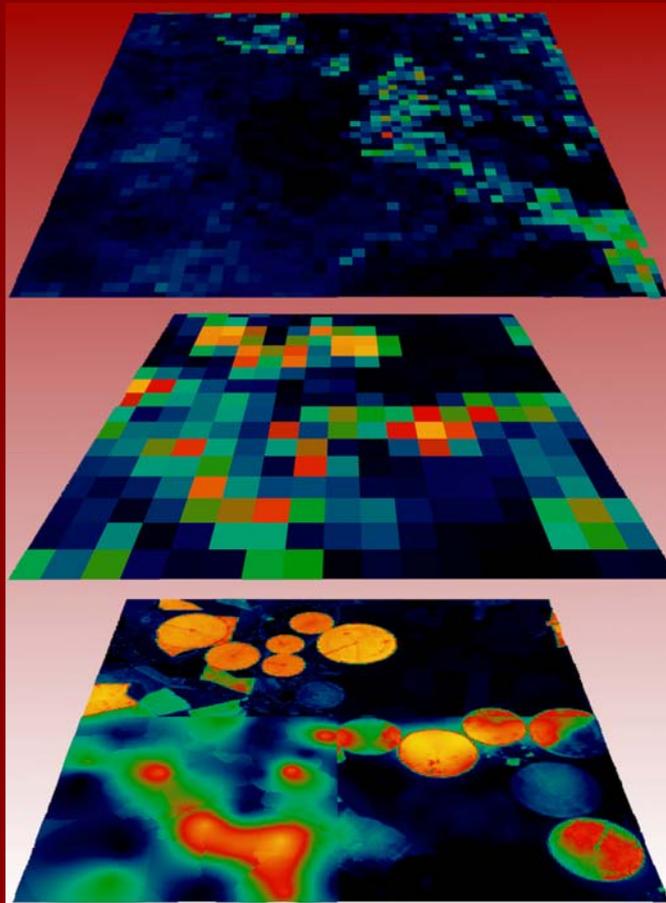




Caracterización espacial de parámetros biofísicos  
de la cubierta vegetal para la validación de productos  
derivados mediante teledetección.  
Aplicación de técnicas geoestadísticas



# VNIVERSITAT Đ VALÈNCIA



Facultad de Física  
Departament de Física de la Terra i  
Termodinàmica

---

**Caracterización espacial de parámetros biofísicos  
de la cubierta vegetal para la validación de  
productos derivados mediante teledetección.  
Aplicación de técnicas geoestadísticas**

---



Unidad de Investigación  
de Teledetección

Tesis Doctoral  
**Beatriz Martínez Díaz**  
Abril, 2006



**D. Franciso Javier García Haro**, Ramón y Cajal de Física de la Tierra de la Universitat de València y

**D. Fernando Camacho de Coca**, Doctor en Física por la Universitat de València.

**CERTIFICAN:**

Que la presenta memoria **Caracterización espacial de parámetros biofísicos de la cubierta vegetal para la validación de productos derivados mediante teledetección. Aplicación de técnicas geoestadísticas**, ha sido realizada bajo nuestra codirección por D<sup>a</sup>. Beatriz Martínez Díaz, durante el periodo **2003-2006** en el Departament de Física de la Terra i Termodinàmica de la Universitat de València, y que constituye su Tesis Doctoral.

Y para que así conste, en cumplimiento de la legislación vigente, firmamos el presente certificado en Burjassot (Valencia), a 28 de Abril de 2006.

D. Francisco Javier García Haro

D. Fernando Camacho de Coca



Este trabajo ha sido posible gracias a la financiación de:

**EUMETSAT:**

Proyecto: **Satellite Application Facilities for Land Surface Analysis (LSA SAF)**,  
periodo: 1999-2003.

**ESA:**

Proyecto: **Spectra Barrax Campaign (SPARC) 2003 y 2004**

**UE:**

Proyecto: **A Surveillance System for Assessing and Monitoring of Desertification (DESURVEY)**,  
periodo: 2005-2008.



---



---

**ÍNDICE**


---



---

|  |               |
|--|---------------|
| <b>INTRODUCCIÓN</b> .....  | <b>- 23 -</b> |
| <b>CAPÍTULO I: FUNDAMENTO TEÓRICO</b> .....  | <b>- 35 -</b> |
| <b>I.1 El problema físico: la validación de productos derivados mediante teledetección</b> ..... | <b>- 36 -</b> |
| I.1.1 Concepto de calibración y validación.....  | - 38 -        |
| <b>I.2 Estrategia de validación</b> .....  | <b>- 39 -</b> |
| <b>I.3 Problemática de la validación directa</b> .....   | <b>- 42 -</b> |
| I.3.1 Errores asociados a la estimación del producto .....                                       | - 43 -        |
| I.3.2 Errores asociados a la caracterización <i>in-situ</i> .....                                | - 45 -        |
| I.3.3 Errores asociados al proceso de escalado.....  | - 46 -        |
| <b>I.4 Parámetros biofísicos de la cubierta vegetal</b> .....                                    | <b>- 46 -</b> |
| I.4.1 El índice de superficie foliar (LAI) .....   | - 47 -        |
| I.4.2 La fracción de cobertura vegetal (FVC).....  | - 48 -        |
| I.4.3 Fracción de radiación fotosintéticamente activa absorbida (FAPAR).....                     | - 49 -        |
| <b>I.5 Caracterización <i>in-situ</i> de LAI, FVC y FAPAR</b> .....                              | <b>- 50 -</b> |
| I.5.1 Instrumentos de medida basados en la <i>gap fraction</i> .....                             | - 53 -        |
| I.5.2 Técnicas de muestreo .....   | - 57 -        |
| <b>I.6 Caracterización de parámetros biofísicos a alta resolución</b> .....                      | <b>- 59 -</b> |
| I.6.1 Revisión de modelos para la estimación de variables biofísicas.....                        | - 59 -        |
| I.6.2 Técnica de regresión multivariada.....   | - 62 -        |
| I.6.3 Técnicas geoestadísticas.....  | - 63 -        |
| <b>I.7 Cambio de resolución espacial</b> .....   | <b>- 75 -</b> |
| <b>I.8 Programas Internacionales de Validación</b> .....   | <b>- 76 -</b> |
| I.8.1 Principales programas de validación.....   | - 77 -        |
| I.8.2 Red de zonas de estudio .....  | - 79 -        |
| I.8.3 Campañas de campo .....  | - 79 -        |
| <b>CAPÍTULO II: EXPERIMENTO Y MÉTODOS</b> .....  | <b>- 83 -</b> |
| <b>II.1 Área de Estudio</b> .....  | <b>- 84 -</b> |
| II.1.1 Campaña de campo SPARC .....  | - 87 -        |
| II.1.2 Imágenes de satélite.....   | - 89 -        |

|   |                |
|---|----------------|
| II.1.3 Clasificación de la zona de estudio.....                                     | - 90 -         |
| II.1.4 Estudio de la heterogeneidad de la zona .....                                | - 92 -         |
| <b>II.2 Instrumentación y condiciones de adquisición .....</b>                      | <b>- 93 -</b>  |
| II.2.1 LICOR LAI2000 Plant Canopy Analyzer .....                                    | - 94 -         |
| II.2.2 Cámara hemisférica .....   | - 95 -         |
| <b>II.3 Procesado de los datos .....</b>  | <b>- 96 -</b>  |
| II.3.1 LICOR LAI2000 .....  | - 97 -         |
| II.3.2 Cámara hemisférica .....   | - 98 -         |
| <b>II.4 Caracterización de LAI, FVC y FAPAR a alta resolución.....</b>              | <b>- 102 -</b> |
| II.4.1 Técnica de regresión multivariada.....                                       | - 102 -        |
| II.4.2 Técnicas geoestadísticas .....   | - 103 -        |
| <b>CAPÍTULO III: CARACTERIZACIÓN IN-SITU DE LAI, FVC Y FAPAR... ..</b>              | <b>- 105 -</b> |
| <b>II.1 Muestreo espacial.....</b>  | <b>- 106 -</b> |
| <b>III.2 Procesado de los datos .....</b>   | <b>- 109 -</b> |
| III.2.1 LICOR LAI2000.....  | - 109 -        |
| III.2.2 Cámara digital hemisférica.....   | - 111 -        |
| <b>III.3 Influencia del operador en el procesado de fotografías hemisféricas .-</b> | <b>- 116 -</b> |
| <b>III.4 Comparación entre LICOR LAI2000 y cámara hemisférica .....</b>             | <b>- 118 -</b> |
| <b>III.5 Conclusiones.....</b>  | <b>- 120 -</b> |
| <b>CAPÍTULO IV: CARACTERIZACIÓN DE LAI, FVC Y FAPAR A ALTA RESOLUCIÓN .....</b>     | <b>- 123 -</b> |
| <b>IV.1 Técnica de regresión multivariada .....</b>                                 | <b>- 125 -</b> |
| IV.1.1 Cámara hemisférica.....  | - 126 -        |
| IV.1.2 LICOR LAI2000.....   | - 132 -        |
| IV.1.3 Evaluación de la función de transferencia .....                              | - 136 -        |
| IV.1.4 <i>Quality Flag</i> (QF) .....   | - 139 -        |
| IV.1.5. Evaluación de la FT en el área 50×50 km <sup>2</sup> . .....                | - 145 -        |
| <b>IV.2 Técnicas geoestadísticas .....</b>  | <b>- 148 -</b> |
| IV.2.1 Análisis de la continuidad espacial.....                                     | - 149 -        |
| IV.2.2 Variable secundaria.....   | - 151 -        |
| IV.2.3 Estimación mediante KO, CKC y KDE.....                                       | - 152 -        |
| <b>IV. 4 Conclusiones.....</b>  | <b>- 168 -</b> |

|   |                |
|---|----------------|
| <b>CAPÍTULO V: VALIDACIÓN DE PRODUCTOS DE BAJA RESOLUCIÓN .....</b> | <b>- 171 -</b> |
| <b>V.1 Validación de productos a baja resolución.....</b>           | <b>- 173 -</b> |
| V.1.1 Validación directa .....                                      | - 175 -        |
| V.1.2 Validación indirecta.....                                     | - 185 -        |
| <b>V.2 Conclusiones .....</b>                                       | <b>- 197 -</b> |
| <b>CONCLUSIONES GENERALES Y PERSPECTIVAS FUTURAS.....</b>           | <b>- 199 -</b> |
| <b>ANEXO A.....</b>   | <b>- 211 -</b> |
| <b>ANEXO B .....</b>  | <b>- 213 -</b> |
| <b>ANEXO C .....</b>  | <b>- 217 -</b> |



## *Agradecimientos*

Durante estos años son muchas las personas que han colaborado para que este trabajo se haga realidad y a quienes quiero expresar mi gratitud por el apoyo y la confianza que me han prestado.

En primer lugar a los directores de la tesis, F. Javier García-Haro y Fernando Camacho-de Coca por todo su apoyo. A Javier por su aporte científico, valiosas críticas al discutir los resultados de este trabajo y apoyo en los momentos más críticos. Fernando, gracias por tu dedicación, permanente disposición y consejos en los momentos más críticos que han hecho que este trabajo se haga realidad. Gracias por todo tu amor.

A Joaquín Meliá por darme la oportunidad de trabajar en la Unidad de Teledetección y haberme facilitado la formación necesaria para desarrollar mi labor investigadora. Gracias por sus correcciones y consejos durante estos años.

A M<sup>a</sup> Amparo Gilabert por darme la oportunidad de iniciar mi labor investigadora, por el aporte científico durante estos años y por sus valiosas sugerencias durante el desarrollo de este trabajo. Muchas gracias por todo.

A Eduardo Cassiraga por su importante contribución científica en este trabajo, sobre todo en lo referente a las técnicas geoestadísticas. Gracias por todas las facilidades, por tu generosidad científica y tu calidez.

A Alfonso Calera por todo el apoyo científico durante estos años, por brindarme la oportunidad de formarme en el campo de los Sistemas de Información Geográfica. Gracias por todas las facilidades que me has ofrecido, sugerencias de trabajo y trato muy amigable junto con todos los miembros que forman el equipo de GIS y Teledetección, especial atención a José González Piqueras y Eva Rubio.

A José Moreno por la oportunidad de participar en las campañas SPARC, las cuales han constituido un aporte científico muy valioso y han permitido la realización de este trabajo.

A Frédéric Baret y Marie Weiss, por su aportación científica en el tema de la validación y los consejos durante las campañas de campo y procesados de los datos. Ha sido un placer trabajar con vosotros.

A Jesús San Miguel y Paulo Barbosa por darme la oportunidad de trabajar con vosotros y conocerlos.

A mis chicas. Gracias Gloria por tu constante apoyo y tu aporte de energía. Gracias enormemente por todo tu amor y humor que me ha dado tantas fuerzas. Gracias a M<sup>a</sup> Ángeles y a Txell, por su inagotable paciencia, por su constante atención, por su amistad...por estar ahí.

A Demetrio, Alex y al resto de miembros del Departament de Física de la Terra y Termodinàmica que han hecho el día a día más agradable.

A mi familia y a Paco, quienes han sufrido de cerca el desarrollo de la tesis. Gracias por todo vuestro apoyo, por los buenos y malos momentos que os he hecho pasar, por aguantarme y por escucharme. Un beso.

De todo corazón, gracias.

---



---

## LISTADO DE FIGURAS

---



---

- Figura I.1.** Metodología seguida para validar sensores de media y baja resolución a partir de medidas *in-situ*. Imagen obtenida del proyecto de validación MODLAND..... - 40 -
- Figura I.2.** Ejemplo del muestreo realizado en el contexto del proyecto *BigFoot*. El área de 5×5 km<sup>2</sup> se divide en áreas de muestreo con dimensiones de 1 km<sup>2</sup>. En cada área de muestreo se distribuyen una serie de unidades elementales de medida (ESU) con dimensiones de 25×25 m<sup>2</sup>. ..... - 41 -
- Figura I.3.** Comportamiento de la radiación al paso por la atmósfera. Esta figura describe los diferentes procesos que afectan a la radiación incidente a su paso por la atmósfera..... - 44 -
- Figura I.4.** Diferentes pasos de los que se compone el proceso de registrar y georeferenciar una imagen..... - 45 -
- Figura I.5.** Comportamiento del LAI con el NDVI para diferentes cubiertas vegetales. Tal como se expone en la literatura, se observa un comportamiento lineal con el NDVI hasta valores de LAI igual a 2 y asintótico a partir de 3 y 4. .... - 48 -
- Figura I.6.** Rango de variación diaria de FAPAR medido *in-situ* cada 10 minutos donde se observan valores máximos al amanecer y atardecer. Estos resultados se adquirieron en un área semiárida de Senegal con un alta presencia de Sabana (Fensholt et al 2004). ..... - 50 -
- Figura I.7.** Representación gráfica de la influencia de la arquitectura de la cubierta en la FAPAR y FIPAR (a) y la variación de la FAPAR diaria (b)..... - 53 -
- Figura I.8.** Ejemplo de la configuración angular que corresponde a una imagen hemisférica (a), donde  $\theta$  y  $\alpha$  corresponden al ángulo cenital y acimutal, respectivamente. La figura (b) muestra las funciones de proyección más utilizadas. .... - 55 -
- Figura I.9.** Imagen obtenida desde abajo con la cámara hemisférica en una cubierta de maíz. La figura muestra un ejemplo del procedimiento para calcular la *gap fraction* a partir de la división en secciones. .... - 56 -
- Figura I.10.** Diferentes diseños de distribución de medidas dentro de una ESU propuestos en VALERI (Baret et al 2003)..... - 57 -
- Figura I.11.** Ejemplo de la forma típica que presenta el variograma junto con sus parámetros característicos, el alcance (a), la meseta (c) y el efecto pepita ( $c_0$ ) ..... - 65 -

- Figura I.12.** Descripción gráfica de los parámetros necesarios para calcular el variograma a partir de un conjunto de datos distribuidos irregularmente. .... - 66 -
- Figura I.13.** Descripción gráfica del comportamiento de los modelos más utilizados, modelo pepita, esférico, exponencial y gaussiano. .... - 67 -
- Figura I.14.** Ejemplo de la metodología propuesta por CEOS/WGCV. Estos datos están disponibles para todos los *test sites* propuestos por CEOS a través de la Universidad de Maryland..... - 76 -
- Figura I.15** Zonas de validación seleccionadas por CEOS/LPV..... - 77 -
- Figura II.1.** Localización del área de estudio sobre una imagen SPOT. El área de estudio (50×50 km<sup>2</sup>) abarca parte de la provincia de Albacete e incluye la zona piloto de Barrax (5×5 km<sup>2</sup>) donde se llevó a cabo la campaña de campo SPARC en Julio del 2003..... - 84 -
- Figura II.2.** Aspecto de algunos cultivos (e.g. Patata y Alfalfa) muestreados en la zona de estudio de Barrax durante la campaña de SPARC donde se pone de manifiesto su gran extensión (aprox. 800 m de diámetro)..... - 85 -
- Figura II.3.** Variación anual del coeficiente de cultivo, Kc, para los cultivos dominantes en la zona de Barrax (e.g. regadío de verano, invierno, secano, Alfalfa, Viña y Girasol)..... - 86 -
- Figura II.4.** Variabilidad mostrada por diferentes tipos de cubiertas de la zona de estudio, como el Ajo (a), Cebolla (b), Alfalfa (c) y (d), Remolacha (e) y Patata (f)..... - 87 -
- Figura II.5.** Área de estudio de la campaña de campo SPARC junto con la localización de las diferentes medidas e información sobre los usos del suelo que se recogió durante la campaña. La imagen de fondo corresponde a la imagen HRVIR2/SPOT4 adquirida el 3 de Julio de 2003..... - 89 -
- Figura II.6.** Clasificación de la zona de estudio realizada a partir de las bandas espectrales de la imagen SPOT. La imagen se ha clasificado en 10 clases según el método de clasificación supervisada.....- 91 -
- Figura II.7.** Descripción de los pasos seguidos por el programa CAN\_EYE para procesar las fotografías hemisféricas..... - 99 -
- Figura III.1.** Esquemas de muestreo espacial utilizado en la adquisición de medidas *in-situ*. El muestreo (a) se llevó a cabo en aquellos cultivos que presentaban una distribución homogénea mientras que el muestreo (b) se aplicó en los cultivos que presentaban una distribución por filas..... - 107 -
- Figura III.2.** Unidades Elementales de Medida (ESUs) adquiridas por la cámara hemisférica (cruces) y por el LICOR LAI2000 (puntos) sobre el área de

- estudio. La imagen de fondo corresponde a la composición RGB de las bandas NIR, R y G..... - 108 -
- Figura III.3.** Imágenes hemisféricas adquiridas en los cultivos más representativos del área de estudio durante la campaña de SPARC'03. Las imágenes de la fila inferior corresponden a los mismos cultivos de arriba adquiridos con la cámara en modo *downward* para los cultivos de Remolacha, Maíz, Patata, Alfalfa y Ajo. .... - 109 -
- Figura III.4.** (a) Valores medios de LAI junto con la desviación estándar de las medidas realizadas en los campos donde también se realizaron medidas con la cámara hemisférica, Alfalfa (A9, A1 y A10), Patata (P1), Maíz (C2, C1), Ajo (G1), Remolacha (B3) y Cebollas (ON1). (b) Coeficientes de variación para esos campos. .... - 110 -
- Figura III.5.** Relación entre el LAI y la FVC estimados a partir del LICOR LAI2000. El comportamiento entre ambas variables se ha ajustado a una relación exponencial con un coeficiente de correlación  $r=0.96$ . .... - 111 -
- Figura III.6.** Fracción media de vegetación en función del ángulo de observación cenital y azimutal para las ESUs de Maíz y Cebolla. En cada ejemplo, la imagen de la izquierda muestra una de las 12 fotografías adquiridas dentro de la ESU y la imagen de la derecha muestra la fracción media de vegetación de las 12 imágenes que componen la ESU. .... - 112 -
- Figura III.7.** *Gap fraction* monodireccional para los cultivos más representativos del área de estudio en función del ángulo cenital de observación, Maíz (C), Alfalfa (A), Patata (P) y Ajo (G). La línea discontinua se refiere a las imágenes adquiridas en modo *upward* y la línea continua a las adquiridas en modo *downward*. .... - 114 -
- Figura III.8.** Relación entre los parámetros LAI, FVC y FAPAR estimados a partir de la cámara hemisférica. La FVC y la FAPAR se relacionan linealmente (a) mientras que el LAI y la FAPAR lo hacen a partir de una función exponencial (b)..... - 116 -
- Figura III.9.** Comparación entre el LAI (a), la FVC (b) y la FAPAR (c) derivada a partir del procesado con el programa CAN\_EYE por dos usuarios diferentes, el grupo de la Universidad de Valencia (UV) y el grupo INRA-CSE (Avignon). .... - 117 -
- Figura III.10.** Diferencia entre los valores medios de LAI (a) y FVC (b) estimados por los dos instrumentos relativa al valor medio estimado por el LAI2000 para cada cultivo. .... - 118 -
- Figura III.11.** Diferencia en las estimaciones de LAI para una misma ESU entre cámara hemisférica y LICOR (a) y LICORs (b). .... - 119 -

- Figura III.12.** Ejemplo de dos ESUs, Girasol (izquierda) y Maíz (derecha), adquiridas en modo *upward* y *downward* durante la campaña de SPARC'04. El error relativo cometido en la estimación del LAI al realizar la adquisición en modo *downward* se sitúa entre un 37% y 57%..... - 120 -
- Figura IV.1.** RW (línea discontinua) y RC (línea continua) asociados a las FTs correspondientes al LAI (a), FVC (b) y FAPAR (c) estimados a partir de las DHPs. En abscisas se representan la combinación de las bandas espectrales utilizadas G (1), R (2), NIR (3) y MIR (4) respectivamente. .... - 128 -
- Figura IV.2.** Valor medio (izquierda) y RMSE (derecha) de las estimaciones proporcionadas por las funciones con RW y RC mínimo, máximo e intermedio para los parámetros LAI (a), FVC (b) y FAPAR (c) derivados de la cámara hemisférica. .... - 130 -
- Figura IV.3.** Representación de las medidas *in-situ* con la cámara hemisférica frente a las estimadas por la FT para el LAI (a), la FVC (b) y la FAPAR (c). En cada caso se han incluido los coeficientes de la función junto con el RMSE, RW y RC. .... - 131 -
- Figura IV.4.** RW (línea discontinua) y RC (línea continua) asociados a las FTs para el LAI<sub>LICOR</sub> (a) y FVC<sub>LICOR</sub>. .... - 133 -
- Figura IV.5.** (a) Valor medio y (b) RMSE de las estimaciones derivadas de las funciones con RW y RC mínimo, máximo e intermedio para el LICOR LAI2000. .... - 134 -
- Figura IV.6.** Coeficientes asociados a la FT para estimar los parámetros LAI y FVC a partir de las medidas *in-situ* realizadas con el LICOR LAI2000. .... - 135 -
- Figura IV.7.** Mapas de LAI, FVC y FAPAR obtenidos a partir de las funciones del LAI<sub>LICOR</sub> (a), LAI<sub>DHP</sub> (b), FVC<sub>DHP-NDVI</sub> (c) y FAPAR<sub>DHP-NDVI</sub> (d). .... - 137 -
- Figura IV.8.** Histograma, RMSE y bias obtenido entre las siguientes parejas de funciones: (LAI<sub>DHP</sub> , LAI<sub>LICOR</sub>), (FVC<sub>DHP</sub> , FVC<sub>LICOR</sub>), (FVC<sub>DHP-BANDAS</sub> , FVC<sub>DHP-NDVI</sub>) y (FAPAR<sub>DHP-BANDAS</sub> , FAPAR<sub>DHP-NDVI</sub>). .... - 139 -
- Figura IV.9.** *Convex hulls* bidimensionales obtenidos a partir de los valores de radiancias colocados con las medidas *in-situ* LAI<sub>DHP</sub> (a) y LAI<sub>LICOR</sub> (b). Los tres *convex hull* pertenecen a las combinaciones (R, G), (NIR, G) y (NIR, R). En gris se muestran los píxeles de la imagen que se localizan dentro de la mínima región convexa. .... - 141 -
- Figura IV.10.** Imágenes de QF correspondientes a las FTs obtenidas para el LAI<sub>DHP</sub> (a) y el LAI<sub>LICOR</sub> (b). Los píxeles en negro corresponden a QF=1, en negro a los valores de QF=0 y en azul a los píxeles con QF=1 al considerar el *convex hull* añadiendo el error relativo. .... - 142 -

- Figura IV.11.** Porcentaje de píxeles no interpolados por las funciones LAI<sub>DHP</sub> (a), LAI<sub>LICOR</sub> (b), FVC<sub>DHP</sub> (c), FVC<sub>LICOR</sub> (d) y FAPAR<sub>DHP</sub> (e). ..... - 144 -
- Figura IV.12.** Mapas de LAI<sub>LICOR</sub> para tres zonas de 10×10 km<sup>2</sup> dentro del área de 50×50 km<sup>2</sup>. Las zonas corresponden a un área con (a) alta presencia de cultivos, (b) predominio de bosque y cultivos y (c) alta presencia de bosque y suelo desnudo..... - 146 -
- Figura IV.13.** Distribución de píxeles no interpolados por las funciones LAI<sub>LICOR</sub> (a), FVC<sub>LICOR</sub> (b) y FAPAR<sub>DHP</sub> (c) en función del rango de variabilidad mostrado por cada parámetro. .... - 147 -
- Figura IV.14.** Variogramas omnidireccionales y estudio de la anisotropía para el parámetro LAI obtenido de los conjuntos de datos LAI<sub>LICOR</sub> (a) y LAI<sub>DHP</sub> (b)..... - 150 -
- Figura IV.15.** Variable primaria, LAI<sub>LICOR</sub> y LAI<sub>DHP</sub> frente al valor colocalizado de NDVI. En cada caso se presenta el coeficiente de correlación que será incluido en los modelos KDE y CKC..... - 152 -
- Figura IV.16.** Localización de las ESUs para los datos LAI<sub>LICOR</sub> ((a) izquierda) y LAI<sub>DHP</sub> ((a) derecha) sobre el mapa de LAI derivado a partir de la FT, junto con las estimaciones al aplicar los algoritmos de KO (b), CKC (c) y KDE (d). ..... - 153 -
- Figura IV.17.** Histogramas de los mapas derivados con cada modelo aplicado a los dos conjuntos de datos LAI<sub>LICOR</sub> (a) y LAI<sub>DHP</sub> (b). ..... - 155 -
- Figura IV.18.** RMSE y *bias* en función del NDVI calculado a partir de los mapas derivados con CKC (a) y KDE (b) respecto al mapa derivado con la FT LAI<sub>LICOR</sub>..... - 157 -
- Figura IV.19.** Coeficiente de correlación (a) y RMSE (b) correspondientes a las estimaciones obtenidas a partir de los modelos KO, CKC y KDE respecto a las estimadas mediante el método FT para las resoluciones espaciales de 20 m, 300 m y 1000 m. .... - 158 -
- Figura IV.20.** Muestreos diseñados a partir del mapa de LAI<sub>LICOR</sub>, SP1 (a), SP2 (b), SP3 (c) y SP4 (d) sobre la imagen de NDVI. Las figuras de la derecha corresponden a la imagen QF obtenida para cada muestreo a partir de la combinación de bandas espectrales (G, R, NIR) de la imagen SPOT.... - 161 -
- Figura IV.21.** Variogramas omnidireccionales obtenidos para los muestreos espaciales SP1 (a), SP2 (b), SP3 (c), SP4 (d). ..... - 163 -
- Figura IV.22.** Estimaciones del LAI derivadas de los modelos KO (izquierda), CKC (centro) y KDE (derecha) para los cuatro muestreo espaciales SP1 (a), SP2 (b), SP3 (c) y SP4 (d). ..... - 165 -

- Figura IV.23.** Histogramas correspondientes a los mapas obtenidos a 20 m con los modelos FT, KO, CKC y KDE para los muestreos SP1 (a), SP2 (b), SP3 (c) y SP4 (d). ..... - 166 -
- Figura IV.24.** (a) Coeficiente de correlación y (b) RMSE obtenido a partir de los modelos KO (izquierda) y CKC (centro) y KDE (derecha) respecto a las estimaciones FT para los cuatro muestreos diseñados y las tres resoluciones espaciales (20 m, 300 m y 1000 m). ..... - 168 -
- Figura V.1.** Productos de BRDF corregida para el 3 de Octubre de 2005 (a) junto con los productos y errores siguientes derivados del algoritmo diseñado en LandSAF: error asociado a la banda del NIR (b), el producto LAI (c), el producto FVC (d), el error del LAI (e) y el error de la FVC (f). ..... - 173 -
- Figura V.2.** Valores medios y desviación estándar de los diferentes productos de LAI, FVC y FAPAR a validar junto con los mapas *in-situ* para cada parámetro y para el área 5×5 km<sup>2</sup>. En el caso del LAI, también se han incluido los mapas derivados con las técnicas geoestadísticas. .... - 176 -
- Figura V.3.** Mapas de LAI para los productos (a) *in-situ*, (b) VGT\_LandSAF\_v1, (c) VGT\_CYC\_v1 y (d) MODIS\_v4. .... - 179 -
- Figura V.4.** Histogramas de los productos de LAI a validar junto con el mapa de LAI *in-situ* para la resolución de 1 km (a) y 3 km (b) sobre el área de 50×50 km<sup>2</sup>. .... - 179 -
- Figura V.5.** Diagramas de dispersión, RMSE y coeficiente de Pearson entre los productos LAI de satélite y el mapa LAI *in-situ*. .... - 180 -
- Figura V.6.** Mapas de FVC para los productos *in-situ* (a), VGT\_LandSAF\_v1 (b) y VGT\_CYC\_v1 (c). .... - 182 -
- Figura V.7.** Histogramas del producto FVC a validar junto con el mapa *in-situ* para la resolución de 1 km (a) y 3 km (b). .... - 183 -
- Figura V.8.** Diagramas de dispersión, RMSE y coeficiente *r* para los productos de FVC VGT\_LandSAF\_v1 (a) y VGT\_CYC\_v1 (b) respecto a los mapas de referencia. .... - 183 -
- Figura V.9.** Mapas de FAPAR para los productos *in-situ* (a), VGT\_MODIS\_v4 (b) y VGT\_CYC\_v1 (c). .... - 184 -
- Figura V.10.** Histogramas del producto FAPAR a validar junto con el mapa *in-situ* para la resolución de 1 km (a) y 3 km (b). .... - 185 -
- Figura V.11.** Diagramas de dispersión, RMSE y coeficiente de Pearson para el producto FAPAR respecto a los mapas de referencia. .... - 185 -
- Figura V.12.** Composición en color RGB (a) de la zona de estudio a partir de las bandas de reflectividad normalizada a la observación nadir 4, 3, y 2 (e.g.

coeficiente  $k_0$  derivado de datos VGT). La imagen (b) corresponde a la clasificación de vegetación utilizada derivada de la Global Land Cover Classification (GLC)..... - 186 -

**Figura V.13.** Productos de LAI a 3 km de resolución correspondientes a VGT\_LandSAF\_v1 (a), VGT\_CYC\_v1 (b), MSG\_LandSAF\_v1 (c) y MODIS\_v4 (d)..... - 187 -

**Figura V.14.** Histogramas de los productos de LAI (a), FVC (b) y FAPAR (c) a la resolución espacial de 3 km. .... - 188 -

**Figura V.15.** Productos de FVC a 3 km correspondientes a VGT\_LandSAF\_v1 (a), VGT\_CYC\_v1 (b) y MSG\_LandSAF\_v1 (c)..... - 189 -

**Figura V.16.** Productos de FAPAR correspondientes a MODIS\_v4 (a) y VGT\_CYC\_v1 (b)..... - 190 -

**Figura V.17.** Error absoluto de los productos (a) VGT\_LandSAF\_v1, (b) MSG\_LandSAF\_v1 y (c) MODIS\_v1 respecto al VGT\_CYC\_v1 para el LAI. .... - 191 -

**Figura V.18.** Error absoluto de los productos (a) VGT\_LandSAF\_v1 y (b) MSG\_LandSAF\_v1 respecto al VGT\_CYC\_v1 para la FVC. .... - 192 -

**Figura V.19.** Error absoluto del producto MODIS\_v4 respecto al VGT\_CYC\_v1 para la FAPAR. .... - 193 -

**Figura V.20.** Histogramas por clases de los diferentes productos LAI (a) y FVC (b). .... - 194 -

**Figura V.20 (continuación).** Histogramas por clases de los productos FAPAR (c). .... - 195 -



---



---

## LISTADO DE TABLAS

---



---

|  |         |
|--|---------|
| <b>Tabla II.1.</b> Matriz de confusión derivada de la clasificación supervisada mediante el método de máxima probabilidad.....   | - 92 -  |
| <b>Tabla II.2.</b> Parámetros estadísticos calculados con los valores de NDVI para los diferentes campos donde se adquirieron medidas <i>in-situ</i> , Alfalfa (A1, A9, A10), Remolacha (B3), Maíz (C1, C2 y C3), Cebolla (ON1), Patata (P1), Ajo (G1) y Hierba (GR).....                            | - 93 -  |
| <b>Tabla II.3.</b> Consideraciones en la estimación del LAI con el LICOR LAI2000....   | - 94 -  |
| <b>Tabla II.4.</b> Recomendaciones de adquisición según las características de la cámara, los factores externos y características de la cubierta.....  | - 96 -  |
| <b>Tabla II.5.</b> Parámetros proporcionados por el LICOR LAI2000 .....  | - 97 -  |
| <b>Tabla III.1.</b> Descripción de las ESUs adquiridas por cada instrumento y de los campos muestreados para cada cultivo. ....  | - 108 - |
| <b>Tabla III.2.</b> LAI corregido del efecto de acoplamiento de los elementos de la cubierta y LAI efectivo para algunas de las ESUs presentes en la zona de estudio.....  | - 113 - |
| <b>Tabla III.3.</b> Valores medios, desviación estándar y coeficiente de variabilidad de los parámetros LAI, FVC y FAPAR. ....   | - 115 - |
| <b>Tabla IV.1.</b> Coeficientes obtenidos en las distintas FTs de los parámetros LAI, FVC y FAPAR.....   | - 136 - |
| <b>Tabla IV.2.</b> Coeficientes y errores RMSE, RW y RC asociados a las funciones de transferencia obtenidas con los conjuntos de datos CH1 y CH2. ....  | - 145 - |
| <b>Tabla IV.3.</b> RMSE y coeficiente de correlación entre las estimaciones de los datos eliminados con las funciones FT1 y FT2 respecto a las estimaciones de la FT original (i.e. CH1_FT y CH2_FT) y respecto a los valores <i>in-situ</i> (i.e. CH1_ <i>in-situ</i> y CH2_ <i>in-situ</i> ). .... | - 145 - |
| <b>Tabla IV.4.</b> Parámetros relacionados con la anisotropía, $r$ y dirección de máximo alcance.....  | - 151 - |
| <b>Tabla IV.5.</b> Parámetros estadísticos de las estimaciones derivadas de la FT, KO, CKC y KDE a partir de los conjuntos de datos LAI <sub>LICOR</sub> y LAI <sub>DHP</sub> . El <i>bias</i> , $r$ y RMSE se ha calculado respecto a la FT.....  | - 156 - |
| <b>Tabla IV.6.</b> Error de estimación proporcionado por los modelos FT, KO, CKC y KDE respecto a los datos <i>in-situ</i> LAI <sub>DHP</sub> .....  | - 157 - |

|   |         |
|---|---------|
| <b>Tabla IV.7.</b> Comparación de las estimaciones proporcionadas por los modelos KO, CKC y KDE con las medidas in-situ del LAI <sub>LICOR</sub> para los cuatro muestreos. ....  | - 167 - |
| <b>Tabla V.1.</b> Características de los datos de reflectividad utilizados para derivar los parámetros biofísicos. ....   | - 175 - |
| <b>Tabla V.2.</b> Coeficiente de correlación y RMSE para los diferentes productos LAI, FVC y FAPAR respecto al mapa de referencia en el área de 5x5 km <sup>2</sup> ...   | - 177 - |
| <b>Tabla V.3.</b> Estadísticos entre el producto LAI derivado con los algoritmos LandSAF_v1, MODIS_v4 y CYCLOPES_v1 y las estimaciones de los modelos KO, CKC y KDE y el muestreo SP4. ....   | - 177 - |
| <b>Tabla V.4.</b> Coeficiente de correlación y RMSE para los diferentes productos LAI, FVC y FAPAR respecto al mapa de referencia en el área de 50x50 km <sup>2</sup> .-  | 181 -   |
| <b>Tabla V.5.</b> Valores medio y desviación estándar ( $\sigma$ ) de los productos de LAI, FVC y FAPAR. ....   | - 188 - |
| <b>Tabla V.6.</b> Valores medios y desviación estándar de los productos a validar distinguiendo las siguientes clases, C1 (Closed Forest), C2 (Mixed Forest & Shrublands), C3 (Cultivated & Managed Areas) y C4 (Sparse Vegetation). .... | - 196 - |
| <b>Tabla V.7.</b> Valores medios y desviación estándar de los productos a validar distinguiendo por clases. ....  | - 197 - |

## INTRODUCCIÓN

---

---

La influencia que la actividad del hombre tiene sobre el medioambiente que lo sustenta se puede dividir en cuatro tipos de procesos agrupados bajo el término de Cambio Global (Loveland et al 2000), (i) la transformación y degradación de la tierra como los procesos de deforestación y desertificación), (ii) la modificación de los ciclos bioquímicos del carbono, nitrógeno o del agua, (iii) la pérdida de biodiversidad, principalmente por la sobreexplotación de recursos naturales, y (iv) el cambio climático, proceso que se deriva en parte de los anteriores. Las respuestas y estrategias que se planteen para mitigar el impacto de estos procesos de degradación del medioambiente tienen que estar basadas en la estimación precisa de variables que nos permitan obtener y desarrollar a diferentes escalas espaciales y temporales los indicadores necesarios.

Uno de estos indicadores es la cubierta vegetal, que interviene en los intercambios de energía y agua del sistema suelo-vegetación-atmósfera, afectando directamente al sistema climático tanto a escala regional como global. En este contexto, la teledetección es una herramienta muy potente en el uso de parámetros que describen el estado de la cubierta vegetal, ya que permite modelar y monitorizar a escala global y regional la superficie terrestre, constituyendo, a su vez, un instrumento indispensable para hacer frente a los desafíos del Cambio Global.

Su alto potencial se debe, en parte, al continuo desarrollo tecnológico de los programas actuales de observación de la Tierra (*Earth Observation*, EO) como el *Earth Science Enterprise* (ESE) de NASA, el *Living Planet* de ESA, o el *Satellite Application Facilities* (SAF) de EUMETSAT, los cuales permiten actualmente una visión mucho más unitaria del planeta, gracias a una constelación de sensores de última generación que observan la superficie simultáneamente (e.g. VEGETATION/SPOT, POLDER/ADEOS-PARASOL, MODIS/EOS, MERIS/ENVISAT, SEVIRI/MSG, AVHRR-3/EPS). Éstos, además de incorporar nuevos canales espectrales de medida, y de una resolución espacial mucho mejor (especialmente MERIS y MODIS), permiten captar imágenes bajo condiciones de iluminación y de observación variables (e.g. SEVIRI, POLDER, VEGETATION, AVHRR-2), en razón a la elevada frecuencia de medidas diarias y a la orientación del sensor. Sin embargo, el desarrollo de aspectos tecnológicos para explotar esta gran cantidad de información supone en la actualidad un reto tecnológico tanto analítico como de manejo de la información.

Las características básicas que presentan estos sensores actualmente en uso (i.e. muestreo angular, sensibilidad espectral, frecuencia de observación, frecuencia temporal), han contribuido a mejorar la estimación de las variables, y por tanto, a una mayor comprensión de los diferentes procesos que ocurren en la biosfera. Mientras que MERIS y MODIS proporcionan la mayor resolución espacial, MERIS presenta la mayor información espectral, POLDER ofrece óptimas capacidades multiangular, y los satélites de los servicios meteorológicos (SEVIRI) garantizan una continuidad temporal necesaria para los estudios a largo plazo.

**Tabla 1.** Características básicas de sensores de última generación.

| Sensor     | Resolución (nadir)   | Frecuencia | Ángulo observación | Ángulo iluminación | Canales espectrales | Periodo operacional |
|------------|----------------------|------------|--------------------|--------------------|---------------------|---------------------|
| POLDER     | 6 km                 | ~1 día     | variable           | ~ cte.             | 5                   | 1997, 2003, 2005-   |
| MERIS      | 300m<br>1 km         | ~2 días    | variable           | ~ cte.             | 15                  | 2002-               |
| MODIS      | 250m<br>500m<br>1 km | ~1 día     | variable           | ~ cte.             | 7                   | 2000-               |
| VEGETATION | 1 km                 | ~1 día     | variable           | ~ cte.             | 4                   | 1998-               |
| SEVIRI     | 3 km                 | 15 min     | cte.               | variable           | 3                   | 2003-2018           |

Por otra parte, este avance tecnológico ha permitido que, actualmente, exista una gran oferta y fácil acceso de productos derivados a partir de metodologías más elaboradas que permite estudiar de forma más cuantitativa a la que se hacía tradicionalmente los fenómenos que ocurren en la superficie terrestre. Hasta hace no mucho, las misiones espaciales se habían centrado generalmente en la obtención de información semi-cuantitativa de la superficie terrestre y utilizaban un solo instrumento (e.g. AVHRR). Sin embargo, actualmente los principales sistemas de observación de la tierra (e.g. MODIS, VEGETATION, MERIS), además de proporcionar los datos en bruto ("level 1"), es decir, radiancia o reflectividad en el techo de la atmósfera, ofrecen una serie de productos elaborados con distinto nivel de tratamiento como corregidos de atmósfera ("level 2") o parámetros biofísicos ("level 3"). Un ejemplo claro de la aplicación de estos avances es la detección casi en tiempo real de desastres naturales, como terremotos, tormentas, huracanes o incendios, permitiendo tener un mayor conocimiento de la magnitud del suceso para extraer la mayor información posible relevante a dicho evento y poder tomar decisiones rápidas para llevar a cabo las medidas de control o recuperación necesarias en cada caso.

En el caso del estudio de la cubierta vegetal, existe una fuerte demanda de parámetros biofísicos que sean directamente aplicables al estudio de fenómenos de la superficie. Los parámetros biofísicos que más destacan en el estudio del estado de la cubierta vegetal son el índice de superficie foliar (LAI), la fracción de cobertura vegetal (FVC), la fracción de la radiación fotosintéticamente activa que es absorbida por cubierta vegetal (FAPAR), la biomasa y la clorofila. Estos parámetros se usan para cuantificar la interacción de la radiación solar con la vegetación y con el suelo, así como la interacción de flujos de energía y materia (e.g. agua, CO<sub>2</sub>) entre superficie y atmósfera. La comunidad científica pretende superar así

conceptos tradicionales tales como los índices de vegetación, que con frecuencia dependen de las características de la escena y del sensor.

Son productos que presentan un elevado interés agronómico y medioambiental en multitud de aplicaciones de la biosfera, tales como los ciclos del carbón y el agua, la variabilidad climática interanual, la gestión forestal, la seguridad alimentaria (predicción de cosechas, prevención de riesgos tales como incendios, sequías) y el manejo sostenible del suelo. Además, los modelos atmosféricos de circulación general (AGCMs) y los modelos de área limitada (LAMs) utilizados por climatólogos y meteorólogos incorporan los procesos físicos en superficie mediante los modelos SVAT (*Soil-Vegetation-Atmosphere Transfer*), los cuales utilizan la FVC y el LAI como *inputs* prioritarios para representar de forma detallada las características de la cubierta vegetal.

### Validación de productos derivados de teledetección

La amplia aplicación de estos productos, ha dado lugar a una fuerte demanda de un producto preciso, consistente y de alta calidad. Ello ha motivado que las principales agencias hagan un esfuerzo en producir dichos parámetros mediante el empleo de metodologías robustas y operacionales, con la precisión exigible por una amplia comunidad de usuarios potenciales.

Sin embargo, el interés por un producto cada vez más preciso implica considerar diferentes aspectos que no se llevaban a cabo tradicionalmente con el suficiente rigor científico, como por ejemplo la validación científica de los algoritmos que los producen y los propios productos (Justice et al 2000). Por una parte, se requiere evaluar el nivel y potencial del prototipo respecto al nivel actual y analizar la idoneidad de cada algoritmo para una aplicación concreta y con un error asumible. Por otra parte, es necesario definir estrategias de validación y de intercomparación del producto para garantizar su consistencia espacial y temporal respecto a valores de referencia y a los productos actuales. Es así que la implementación operacional de los prototipos requiere tanto el desarrollo metodológico como la validación científica de los productos. Hasta tal punto, que las principales agencias han creado programas y actividades a nivel global para la validación de los productos y algoritmos de los nuevos sensores (Hu et al 2003, Morissette et al 2002). La tabla 2 recoge los programas actuales de validación de productos de baja resolución.

**Tabla 2.** Programas internacionales dirigidos a la validación de sensores de baja resolución.

| Validación sensor | Programa      |   |
|-------------------|---------------|---|
| ENVISAT/MERIS     | ESA           | <a href="http://darc.nerc.ac.uk/Envisat/cal_val.htm">http://darc.nerc.ac.uk/Envisat/cal_val.htm</a> |
| MODIS/TERRA       | MODLAND       | <a href="http://modland.nascom.nasa.gov/">http://modland.nascom.nasa.gov/</a>                       |
| SPOT/VEGETATION   | CNES , VALERI | <a href="http://avi1.avignon.inra.fr/valeri/">http://avi1.avignon.inra.fr/valeri/</a>               |
| ADEOS/POLDER      | CNES, VALERI  | <a href="http://avi1.avignon.inra.fr/valeri/">http://avi1.avignon.inra.fr/valeri/</a>               |

El concepto de validación se entiende como el proceso de evaluar mediante técnicas independientes la calidad de los productos derivados a partir de satélite (Justice et al 2000). La validación hace referencia a determinar la incertidumbre de los productos a partir de la comparación directa con datos de referencia, (e.g. estimación *in-situ* del producto derivado). El objetivo final de la validación es, además de asociar una incertidumbre, asignar al producto un alto nivel de consistencia espacial y temporal para que pueda ser utilizado en cualquier contexto, momento y con diferentes productos derivados de otros sensores independientemente de sus características espectrales y espaciales.

La validación se ha entendido desde un principio como la comparación con datos de referencia, normalmente estimaciones *in-situ* del parámetro de interés. Sin embargo para productos de media y baja resolución, este procedimiento es difícil de llevar a cabo debido a que los productos se extienden a escala regional y global. En este caso, el mayor problema en la validación es la falta de información verdad-terreno, lo que ha dado lugar a que el proceso de validación ya no se limite simplemente a la comparación directa del producto con medidas de referencia, adquiriendo más atención el desarrollo de estrategias que resuelvan el problema del escalado de la información *in-situ* hasta la resolución del producto a validar.

El proceso de validación se entiende actualmente como un conjunto de diferentes actividades entre los que destacan:

a. Validación directa.

La validación a partir de medidas *in-situ* consiste en la comparación directa entre los productos derivados mediante teledetección y dichas medidas de referencia. En el caso de productos de media y baja resolución, este procedimiento requiere la adquisición de medidas *in-situ* sobre diferentes áreas de estudio distribuidas globalmente, así como también de estrategias para escalar la información *in-situ* a la resolución del producto a validar, proceso conocido como *up-scaling*.

El proceso de *up-scaling* se aborda actualmente combinando las medidas *in-situ* con datos de satélite a alta resolución para derivar mapas de productos a dicha escala y así disponer de un área suficientemente extensa (e.g. 10×10 km<sup>2</sup>) para degradarla a la resolución del producto a validar (Tian et al 2002a).

b. Intercomparación con otros productos o validación indirecta.

La validación indirecta permite evaluar el producto derivado mediante teledetección a partir de la comparación con otros productos actuales obtenidos a partir de otros sensores y algoritmos. Se complementa con la validación directa en cuanto a que proporciona información de la precisión y consistencia del producto estimado respecto a los actualmente en uso. La validación indirecta permitirá obtener información sobre el rango de variabilidad de cada uno, la precisión de cada producto, posibles problemas o mala caracterización en determinadas cubiertas.

c. Seguimiento temporal del producto.

El seguimiento temporal se lleva a cabo mediante el análisis de la evolución temporal del producto derivado sobre diferentes zonas de estudio. Este procedimiento permite evaluar la consistencia temporal del producto en base a su respuesta con el ciclo fenológico anual de la cubierta y variaciones a lo largo de un determinado periodo.

Por último, se podría incluir la validación realizada por el usuario al que se le distribuye el producto. Se trata de un proceso de evaluación a partir del cual se derivan posibles inconsistencias o fuentes de error en el producto cuando lo utilizan en sus modelos y analizan sus resultados.

## Marco de trabajo

En nuestro caso, el planteamiento del problema de validación de productos biofísicos surge de los proyectos en los que nuestro grupo de investigación, la Unidad de Investigación de Teledetección (UIT) de la Universitat de València (UV), está involucrado. En particular, el proyecto europeo LandSAF<sup>1</sup> (*Land Surface Analysis for Satellite Application Facilities*) financiado por EUMETSAT<sup>2</sup> y dirigido desde Junio de 1999 por el Instituto de Meteorología Portugués, incluye la validación como una de las actividades a realizar para alcanzar sus objetivos. El objetivo principal de este proyecto consiste en desarrollar las técnicas apropiadas para estimar diferentes parámetros relacionados con la superficie terrestre a partir de la información proporcionada por los sensores SEVIRI (*Spinning Enhanced Visible and InfraRed Imagery*) a bordo del satélite geoestacionario MSG (*Meteosat Second Generation*) y AVHRR-3 (*Advanced Very High Resolution Radiometer*) a bordo del satélite polar EPS (*Eumetsat Polar System*). Los parámetros de interés para este proyecto son la temperatura de la superficie (LST), el albedo (AL), la superficie de cobertura nevosa (SC), los flujos de radiación de onda corta (DSSF) y larga (DSLRF) que llegan a la superficie, el LAI, la FVC y la FAPAR.

La tarea encomendada a la UIT en el proyecto LandSAF ha consistido en el desarrollo de los algoritmos apropiados para estimar los parámetros LAI y FVC a partir de la función de distribución de reflectividad bidireccional o BRDF (*Bidirectional Reflectance Distribution Function*) proporcionada por los sensores SEVIRI y AVHRR-3, con el objetivo de aprovechar la mayor información espectral y direccional (García-Haro et al 2005b, Camacho-de Coca et al 2003).

Posterior a la fase de desarrollo, entramos en la fase inicial de dos años (2005-2007) para que los productos sean operacionales (*Initial Operational Phase, IOP*), que incluirá la aplicación de los algoritmos a datos reales y la validación de los productos. Nuestro principal objetivo en esta fase es validar el algoritmo y los

---

<sup>1</sup> <https://landsaf.meteo.pt/>

<sup>2</sup> <http://www.eumetsat.de>

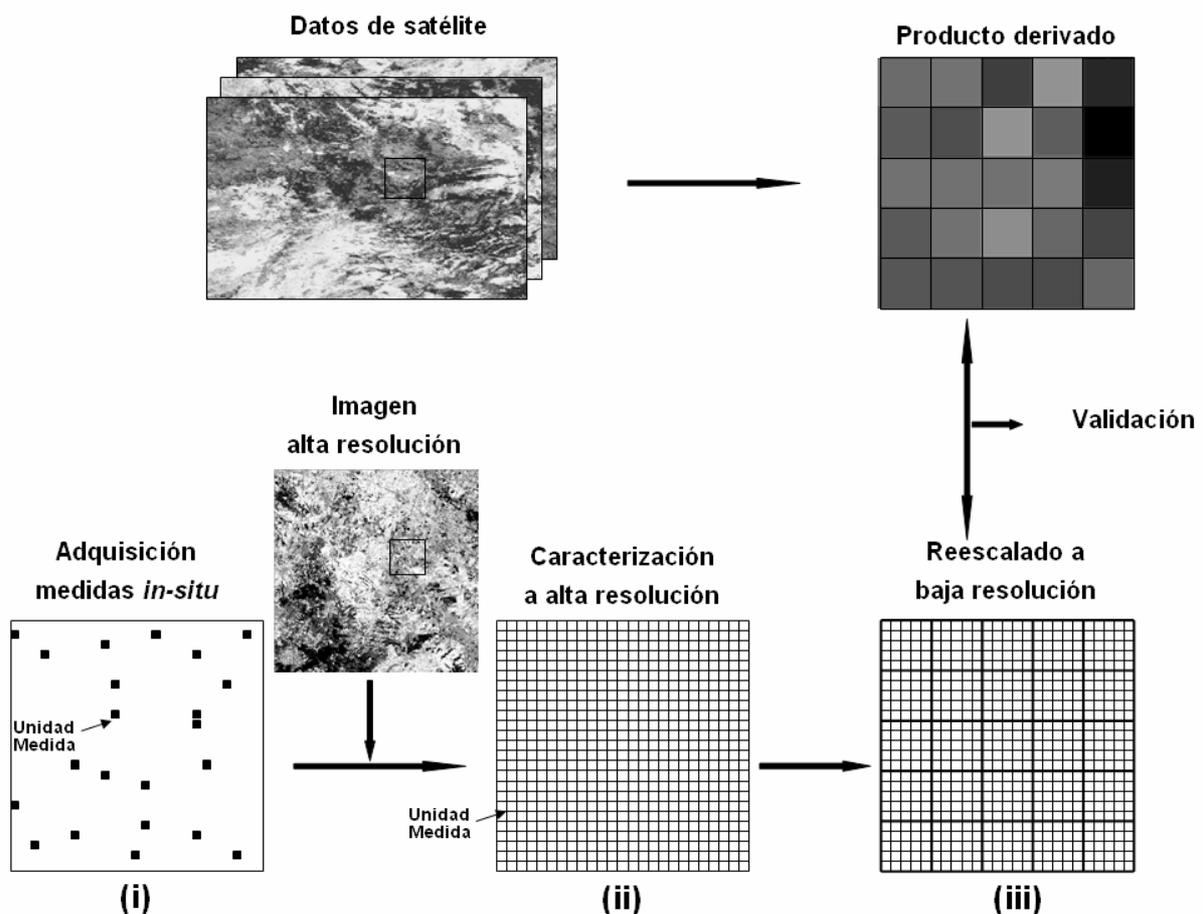
productos derivados, demostrando la credibilidad y competitividad de los mismos. Para ello, se ha creado un comité, METLAND (Meteosat LAND), con el objetivo de coordinar un plan de validación estándar y consistente, que se encuentre al nivel de los diferentes grupos de validación actuales (e.g. MODLAND), y reunir todas las actividades de validación llevadas a cabo en cada producto.

### **El problema asociado a la validación**

Debido al error introducido por la heterogeneidad de la superficie y por la propia estrategia de validación, la metodología propuesta para abordar dicha actividad debe ser fácil de entender, sencilla y trasladable a otras zonas. Se recomienda (Liang 2004) comenzar con actividades que permitan conocer la incertidumbre asociada al producto (e.g. validación directa) sobre un conjunto de zonas de estudio, y avanzar en actividades con mayor dificultad como la intercomparación, dado que precisa recopilar productos de diferentes sensores, conocer el algoritmo que se ha utilizado, georeferenciar todos los productos a un sistema de referencia común, agregarlos a una misma resolución espacial y buscar técnicas de intercomparación adecuadas (e.g. estadísticos descriptivos, estudios de correlación, etc.).

Sin embargo, la validación directa no es una actividad sencilla debido a los diferentes procesos que la constituyen. La figura 1 muestra un esquema de los pasos comunes incluidos en las diferentes metodologías llevadas a cabo por los principales proyectos de validación de productos, como, (i) la elección de un muestreo adecuado e instrumentos de medida, (ii) el escalado de la información *in-situ* a alta resolución mediante el apoyo de datos de satélite, y (iii) el escalado del mapa estimado hasta la resolución del producto a validar.

En primer lugar, la validación requiere un área muestreada mayor que la resolución espacial del producto a validar. Este requerimiento impone diferentes limitaciones a la hora de realizar un muestreo en el campo, sobre todo cuando la zona de estudio presenta una alta heterogeneidad. En este caso, los factores que se presenten en el campo, como el número de instrumentos, el número de personas disponibles para medir, el rango óptimo de medida, la variabilidad temporal de la variable a estimar, etc., son factores determinantes en el número de medidas adquiridas y calidad de las mismas. En segundo lugar, las técnicas utilizadas para escalar la información deben ser adaptadas a las nuevas dimensiones del área de estudio y, particularmente, a la heterogeneidad espacial (Milne & Cohen 1999).



**Figura 1.** Procesos comunes incluidos en las metodologías actuales para la validación directa de productos derivados mediante teledetección a media y baja resolución espacial.

El muestreo espacial de parámetros relacionados con la cubierta vegetal no es un proceso sencillo cuando se realiza en superficies mayores de 10 km<sup>2</sup>. Cuestiones importantes que se plantean normalmente, se hacen más difíciles como, cuándo, qué y dónde medir (Burrows et al 2002). El diseño del muestreo espacial implica una serie de consideraciones como, la distribución espacial, el tamaño y el número de unidades mínima de medidas dentro del área de estudio (Liang 2004). Aunque la elección de un diseño de muestreo u otro resulta crítico para obtener esa mejor representación de la cubierta, existe muy poca literatura que aborde este tema. Los tipos de muestreo que se encuentran en la literatura dependen mayormente del instrumento utilizado, la arquitectura de la cubierta y las características del área de estudio (Liang 2004, Chen 1996).

Por otra parte, el escalado de la información *in-situ* se resuelve desde varias perspectivas. Este proceso es problemático en cuanto que la estructura espacial y propiedades geoestadísticas de la escena cambian con la escala (Openshaw 1984). Los métodos más utilizados en el escalado de los parámetros biofísicos *in-situ* a alta resolución son, (i) los métodos semi-empíricos que relacionan las medidas *in-situ*

con algún parámetro derivado a partir de imágenes de alta resolución (Fernandes 2003, Chen et al 2002, Tian et al 2002a) y (ii) los métodos de interpolación basados en la geoestadística (i.e. cokrigado colocalizado) que estiman superficies continuas de la variable muestreada y posteriormente la comparan con el producto derivado mediante satélite a partir de métodos estadísticos (Berterretche et al 2005, Burrows et al 2002, Gohin & Langlois 1993, Atkinson et al 1992).

De este modo, son notables las diferentes decisiones y consideraciones que se deben realizar antes y durante la validación de los productos, como por ejemplo el diseño óptimo del muestreo espacial de las medidas tanto desde el punto de vista estadístico como logístico, georeferenciar y localizar las medidas *in-situ* junto con los mapas de alta resolución, georeferenciar los diferentes productos, etc. De acuerdo a las consideraciones expuestas en este punto, se han definido los objetivos de esta tesis y la metodología seguida para conseguirlos.

## Objetivos del trabajo

El objetivo principal de este trabajo consiste en desarrollar una metodología que permita la caracterización espacial a alta resolución de los parámetros biofísicos, LAI, FVC y FAPAR a partir de medidas *in-situ*, para su uso como verdad terreno en la validación directa de productos biofísicos. Para ello, se llevarán a cabo las siguientes tareas:

1. Diseño de un muestreo espacial que caracterice la variabilidad de la zona de estudio.
2. Propuesta de varios modelos que permitan extender espacialmente las medidas *in-situ* a alta resolución (i.e. caracterización a alta resolución).
3. Evaluación de los diferentes modelos en la estimación de los mapas a alta resolución.
4. Evaluación de la incertidumbre asociada al modelo y al muestreo espacial.
5. Diseño de una configuración eficiente (i.e. modelo, muestreo y resolución espacial) que minimice el error asociado a las estimaciones.
6. Validación directa de diferentes productos a baja resolución a partir de los mapas de alta resolución estimados.
7. Por último, validación indirecta con diferentes productos sobre la Península Ibérica para obtener información sobre el rango de variabilidad de cada uno, la precisión de cada producto o mala caracterización en determinados tipos de cubiertas.

Para conseguir lo anterior, la metodología que se plantea en este trabajo pretende ser consistente y estándar, en cuanto a las técnicas propuestas y a que pueda ser utilizada en un amplio conjunto de biotipos. Se compone de los siguientes pasos:

1. Elección del área de estudio, instrumentos para estimar *in-situ* los parámetros biofísicos y diseño del muestreo espacial.
2. Aplicación de modelos para extender espacialmente las medidas *in-situ*.
3. Evaluación de los resultados obtenidos.
4. Evaluación de la incertidumbre asociada al muestreo espacial y al modelo seleccionado en 2.
5. Diseño de una configuración (modelo, muestreo y resolución) que minimice el error asociado a los resultados obtenidos en 2.
6. Validación directa: Comparación del producto con la verdad-terreno.
7. Validación indirecta: Escalado de los diferentes productos a una resolución espacial común y sistema de referencia. Comparación entre ellos.

### Estructura de la memoria

En el **Capítulo I** se describen los conceptos teóricos más relevantes para la comprensión del problema físico que se plantea en este trabajo. El capítulo plantea el problema físico en detalle (Sección I.1) y justifica las diferentes actividades que conlleva el proceso de validar, así como la problemática asociada a la validación directa (Sección I.2 y I.3). A continuación se describen los parámetros biofísicos que se van a validar, LAI, FVC y FAPAR, así como el interés que presenta cada uno en diferentes procesos que tienen lugar en la biosfera (Sección I.4). También se introducen las diferentes técnicas que se utilizan para la caracterización *in-situ* de los parámetros, prestando mayor atención a las técnicas basadas en la estimación de la *gap fraction*, como son el LICOR LAI2000 y la cámara hemisférica (Sección I.5). Posteriormente, se discute el problema asociado al diseño del muestreo espacial y se resumen los diferentes muestreos más utilizados en la literatura relacionada con la caracterización de parámetros biofísicos (Sección I.5.2). Por último, se presentan los métodos utilizados para modelar el comportamiento a alta resolución de los parámetros medidos *in-situ*, como son las técnicas de regresión lineal multivariada y las técnicas geoestadísticas (Sección I.6), para terminar con un breve resumen de las diferentes iniciativas que existen actualmente en la validación de dichos parámetros, como programas internacionales, bases de datos, campañas de campo, etcétera (Sección I.7 y I.8).

En el **Capítulo II** se describe la metodología que proponemos para caracterizar a alta resolución los parámetros LAI, FVC y FAPAR a partir de medidas *in-situ* en la zona agrícola de Barrax (Albacete). El capítulo comienza con una descripción detallada del área de estudio, que incluye su localización, proyectos realizados en ella, usos de suelo y topografía (Sección II.1). Además, se incluye un estudio del uso del suelo en el momento de la adquisición de medidas *in-situ* a partir de una clasificación de la zona, y un análisis de la heterogeneidad espacial de la cubierta

vegetal. Posteriormente, se describen los instrumentos utilizados para la caracterización *in-situ* (i.e. LICOR LAI2000 y cámara hemisférica), las condiciones de adquisición y el procedimiento para procesar los datos (Sección II.2 y II.3). Uno de los objetivos que nos planteamos en este capítulo es evaluar las diferencias (i.e. ventajas e inconvenientes) de la cámara hemisférica frente al LICOR LAI2000. El capítulo continúa con la descripción de los pasos a seguir para estimar los mapas a alta resolución a partir de las técnicas propuestas (Sección II.4).

En el **Capítulo III**, se analizan las medidas *in-situ* obtenidas por los instrumentos descritos en la metodología, el LICOR LAI2000 y la cámara hemisférica. Seguidamente, se presenta el procesado llevado a cabo para estimar los parámetros de interés y se incluye una evaluación del programa utilizado para procesar las fotografías hemisféricas fijando especial atención en la influencia del operador sobre el resultado final. Finalmente se detallan las principales conclusiones que se derivan de las estimaciones obtenidas y de la comparación realizada entre ambos instrumentos.

En el **Capítulo IV**, se lleva a cabo el proceso de escalado a alta resolución de las medidas *in-situ* a partir de las técnicas, (i) regresión lineal multivariada y (ii) geoestadísticas. El capítulo incluye la evaluación de ambos métodos en la estimación de mapas a partir de medidas *in-situ* y la comparación entre ellos (Sección IV.1 y IV.2). La técnica de regresión multivariada relaciona las medidas *in-situ* con los valores radiométricos de la imagen a alta resolución seleccionada a partir de relaciones lineales empíricas. Este método permite estimar los parámetros de interés sobre un área extensa (e.g. 10×10 km<sup>2</sup> y 50×50 km<sup>2</sup>) y apropiada para la validación de productos de media y baja resolución. Por otra parte, las técnicas geoestadísticas utilizadas consisten en tres modelos derivados de la técnica por krigado o *Kriging*, el krigado ordinario (KO), el cokrigado colocalizado (CKC) y el krigado con deriva externa (KDE). El krigado presenta la ventaja de considerar la dependencia espacial entre las observaciones de la variable medida y permite introducir información adicional en las estimaciones. Es una técnica que se ha aplicado con éxito en la literatura con parámetros biofísicos a partir de medidas *in-situ*, como LAI, FVC y biomasa ([Martínez et al 2004a](#), [Goovaerts 1999](#), [Atkinson et al 1994](#)). Por otra parte, en este capítulo se presta especial atención a la influencia del muestreo espacial en las estimaciones, a asociar un error a los mapas debido a este proceso y a derivar una imagen de calidad asociada a los mapas que permita evaluar el método de regresión lineal. Por último, se evalúan las dos técnicas propuestas (Sección IV.3) en función del muestreo y de la resolución espacial con el objetivo de encontrar una configuración eficiente (e.g. modelo, muestreo y resolución espacial) para diferentes resoluciones, que permita minimizar los esfuerzos en el campo y caracterizar con el menor error la variabilidad presente en la zona de estudio.

Por último, en el **Capítulo V** se incluye un ejemplo de la validación de productos a baja resolución sobre el área agrícola de Barrax. Con este capítulo se pretende

mostrar la aplicación de los mapas *in-situ* derivados a partir de la metodología propuesta en este trabajo. Los productos escogidos corresponden a los parámetros LAI, FVC y FAPAR derivados a partir de datos VEGETATION/SPOT, MODIS/TERRA y SEVIRI/MSG. En particular, se han utilizado los primeros resultados de FVC y LAI derivados al aplicar el prototipo *Variable Multiple Endmember Spectral Mixture Analysis* (VMESMA) (García-Haro et al 2005b) en fase de desarrollo, dado el interés por evaluar dicho prototipo dentro del proyecto LandSAF antes de su implementación en la cadena de producción. Otros productos que se han incluido corresponden a los parámetros FVC, LAI y FAPAR derivados en el proyecto CYCLOPES con los mismos datos VEGETATION a los que se les ha aplicado el prototipo de LandSAF. Por último, se ha incluido en la discusión los productos LAI y FAPAR derivados a partir de datos MODIS/TERRA. La validación ha consistido en los dos primeros procedimientos descritos en el capítulo I. Por una parte, se ha realizado la validación directa de los productos derivados con datos VEGETATION y MODIS en dos áreas descritas en el capítulo anterior, 5×5 km<sup>2</sup> y 50×50 km<sup>2</sup>. Por último, se ha llevado a cabo la validación indirecta de todos los productos para toda la Península Ibérica. Este estudio permitirá a partir de la intercomparación entre ellos obtener información sobre el rango de variabilidad de cada uno, la precisión de cada producto, posibles problemas o mala caracterización en determinadas cubiertas.

## CAPÍTULO I

---

---

### FUNDAMENTO TEÓRICO

---

---

*En este capítulo, se detallan los aspectos teóricos más relevantes para la comprensión del problema físico que planteamos en este trabajo a partir de una revisión bibliográfica amplia y actual. Dicho problema consiste en la caracterización a alta resolución de parámetros biofísicos a partir de medidas in-situ para utilizarlos posteriormente en la validación directa de productos de vegetación derivados mediante teledetección. El capítulo comienza con la definición de los conceptos de calibración y validación, la justificación de la necesidad de validar, las diferentes actividades que conlleva el proceso de validar, así como la problemática asociada a la validación directa (Sección I.1, I.2 y I.3). A continuación (Sección I.4), se describen los parámetros biofísicos que se van a validar, LAI, FVC y FAPAR, así como el interés que presenta cada uno en los diferentes procesos que tienen lugar en la biosfera. El siguiente apartado (Sección I.5) introduce las diferentes técnicas que se utilizan para la caracterización in-situ de los parámetros, prestando mayor atención a las técnicas basadas en la estimación de la gap fraction, como son el LICOR LAI2000 y la cámara hemisférica. Posteriormente (Sección I.5.2), se discute el problema asociado al diseño del muestreo espacial y se resumen los diferentes muestreos más utilizados para la caracterización de parámetros biofísicos. Por último (Sección I.6), se presentan las técnicas utilizadas para modelar el comportamiento a alta resolución de los parámetros medidos in-situ, como son la técnica de regresión lineal multivariada y las geoestadísticas, para terminar con una breve descripción del problema del cambio de escala (Sección I.7) y de los diferentes métodos e iniciativas que existen actualmente para la validación de dichos parámetros, como programas internacionales, bases de datos, campañas de campo, etc (Sección I.8).*

## I.1 El problema físico: la validación de productos derivados mediante teledetección

El problema físico que abordamos en este trabajo es el de desarrollar una metodología para realizar la validación de productos derivados mediante teledetección, en nuestro caso los parámetros biofísicos de la cubierta vegetal LAI, FVC y FAPAR (ver sección I.4). Actualmente, el interés por un producto cada vez más preciso, junto con la amplia oferta de productos derivados de técnicas y sensores diferentes, implica realizar una calibración del algoritmo utilizado y una validación del producto, de modo que éste sea operativo y pueda ser distribuido a la comunidad de usuarios. Por una parte, se requiere evaluar el nivel y potencial del algoritmo respecto al nivel actual y analizar la idoneidad de cada algoritmo para una aplicación concreta y con un error asumible. Por otra parte, la implementación operacional de dichos prototipos requiere tanto el desarrollo metodológico como la validación científica de los productos. Es así que, resulta imprescindible definir estrategias de validación y de intercomparación entre la multiplicidad de productos existentes para evaluar la exactitud del producto y garantizar su consistencia espacial y temporal con los demás productos actuales ([Morissette et al 2005](#)).

La amplia oferta de productos biofísicos a diferentes escalas ha dado lugar a un cambio en el concepto de validación, de modo que ya no se entiende simplemente como la comparación directa del producto con medidas de referencia, sino que engloba varias actividades como la intercomparación entre productos, el estudio de su consistencia temporal y espacial o incluso el problema del escalado de la información *in-situ* hasta la resolución del producto a validar. El objetivo final de la validación consiste en conocer el grado de incertidumbre asociado al producto y evaluar la consistencia espacial y temporal del producto para que pueda ser utilizado en cualquier contexto, momento y con diferentes productos, independientemente del sensor y algoritmo que se haya utilizado para derivarlo. De hecho, sin una adecuada validación, el producto presenta limitaciones en su aplicación.

La estimación de parámetros biofísicos mediante teledetección en el intervalo espectral solar ( $\approx 300-3000$  nm) requiere comprender la interacción de la radiación electromagnética con la cubierta vegetal, es decir el modo en que se transmite, absorbe y refleja por su interior. Este problema requiere utilizar un algoritmo o función de transferencia (FT) que conecte las observaciones desde satélite con las variables biofísicas de la superficie. En general, cada algoritmo se basa en una función de transferencia radiativa que describe la interacción de los fotones con la materia en el sistema atmósfera-vegetación-suelo ([Myneni et al 1995](#)), un método para invertir el modelo (e.g. optimización, redes neuronales o tablas de

interpolación) e información *a priori* que incluya las condiciones de contorno del sistema.

Se trata de una tarea muy compleja, en parte debido a la variabilidad en las propiedades ópticas y estructurales que presentan las superficies naturales. La solución del problema implica realizar una serie de hipótesis y decisiones acerca del modo en que interacciona la radiación con la cubierta vegetal y que condicionará la forma de resolver el problema y el resultado final. Una de las decisiones con mayor peso concierne a la elección de la función de transferencia radiativa y a los parámetros que intervienen en ella. En este sentido, los algoritmos utilizados para derivar parámetros biofísicos precisos han experimentado una importante evolución gracias al desarrollo tecnológico de las misiones actuales de observación de la Tierra, permitiendo incluir en la formulación variables que describen el comportamiento de la radiación en el interior de la cubierta vegetal. Sin embargo, esta evolución lleva implícito un aumento en el número de variables e hipótesis que intervienen en el proceso (e.g. propiedades ópticas y estructurales de los componentes de la cubierta vegetal) y que dan lugar a que sean difíciles de controlar en el proceso de calibración del algoritmo.

El conjunto de suposiciones, variables que intervienen, etc., hace necesario una evaluación del algoritmo que permita seleccionar las variables más discriminativas y calibrar el sistema para unas condiciones estándares conocidas. Esta evaluación justificará el uso correcto del algoritmo y su aplicación en diferentes campos o disciplinas. El último paso, consistirá en validar los productos para que sea posible integrarlos en diferentes aplicaciones y homogeneizar datos derivados a partir de algoritmos y sensores diferentes.

El proceso de evaluación implica analizar diferentes aspectos como su exactitud, precisión, y consistencia con otros productos. Estos términos aparecen frecuentemente en el contexto de la estimación de parámetros biofísicos cuando se dirigen a la comunidad de usuarios. Un producto exacto se entiende como aquel que minimiza la distancia ( $\delta = X_{\text{sat}} - X_{\text{ref}}$ ) entre el valor estimado ( $X_{\text{sat}}$ ) y el real o de referencia ( $X_{\text{ref}}$ ). De modo que, cuánto menor sea  $\delta$ , más exacta será la medida. Por otra parte, el término precisión se refiere al grado de concordancia entre las estimaciones de la misma magnitud. Por tanto, es posible que el producto no presente un alto grado de exactitud, dada la dificultad que implica su estimación, pero muestre una precisión similar a los productos actualmente en uso. Por último, un término muy utilizado en este contexto es la consistencia del producto. Se entiende como un producto consistente aquel que presenta un alto grado de estabilidad y fiabilidad, tanto espacial como temporal.

La evaluación de la exactitud, precisión y consistencia constituye principalmente la validación del producto. El nivel de exactitud exigido varía ampliamente dependiendo de la aplicación, dado que los productos con alto grado de exactitud requieren un mayor esfuerzo computacional y mejor conocimiento de las variables que intervienen en el sistema. Hay que llegar a un compromiso entre exactitud,

coste computacional e incertidumbre asociada al producto. Por otra parte, el error incluye tanto la imprecisión de los datos como su falta de exactitud y por tanto es la magnitud que se espera obtener cuando se distribuye el producto. De este modo, para determinar de forma correcta la incertidumbre asociada a dicho producto se debería, además de comparar las estimaciones con valores de referencia, realizar una intercomparación con los productos actualmente en uso. Esto es lo que se lleva a cabo en la validación directa e indirecta (Justice et al 2000).

### **I.1.1 Concepto de calibración y validación**

Por calibración se entiende, según el grupo de trabajo y calibración WGCV<sup>3</sup> (*Working Group on Calibration and Validation*), el proceso a partir del cual se cuantifica la correlación entre los valores estimados por la función de transferencia y los valores reales o de referencia que deberían de obtenerse bajo las mismas condiciones (Belward 1999). De este modo, la calibración puede implicar, determinar simplemente la desviación de las estimaciones respecto al valor de referencia o bien, minimizar los errores.

La validación se define, de acuerdo con el WGCV, como el proceso de evaluar mediante técnicas independientes la calidad de los productos derivados a partir de satélite (Justice et al 2000). El objetivo final de la validación consiste en asociar una incertidumbre al producto que informe al usuario final sobre la precisión y exactitud del mismo. También la de asignar al producto un alto nivel de consistencia espacial y temporal para que pueda ser utilizado en cualquier contexto, momento y con diferentes productos derivados de otros sensores independientemente de sus características espectrales y espaciales. Se trata de un proceso de evaluación que además permite mejorar los algoritmos desarrollados para derivar los productos.

Tanto el proceso de validación como el de calibración requieren de valores de referencia (e.g. medidas *in-situ*) para contrastar las estimaciones efectuadas. Sin embargo, a medida que la resolución espacial de los productos aumenta este procedimiento es difícil de llevar a cabo debido a la extensión espacial de los productos (i.e. escala regional y global).

En este contexto y dada la necesidad de una validación robusta y estándar, se han creado desde las principales agencias espaciales (e.g. NASA, CNES, EUMETSAT) diferentes grupos de trabajo con el objetivo común de desarrollar un protocolo de validación. Tal es el caso del grupo MODLAND<sup>4</sup> (*MODIS Land Discipline Team*) encargado de la validación de productos de Tierra MODIS/TERRA, la validación de MERIS/ENVISAT confiada a ESA<sup>5</sup> o la validación de VEGETATION/SPOT

---

<sup>3</sup> <http://wgcv.ceos.org/>

<sup>4</sup> <http://modland.nascom.nasa.gov/>

<sup>5</sup> [http://darc.nerc.ac.uk/Envisat/cal\\_val.htm](http://darc.nerc.ac.uk/Envisat/cal_val.htm)

encomendada al proyecto VALERI<sup>6</sup> (*VALidation of Land European Remote sensing Instruments*).

La constitución de un protocolo permite reunir esfuerzos comunes, como la adquisición de medidas *in-situ* a partir de diferentes campañas de campo organizadas a nivel global y redes internacionales. Dichos esfuerzos facilitarán la adquisición de datos, así como la posibilidad de una mayor participación de los diferentes grupos interesados en validar sus productos. El resultado es un conjunto de datos de alta calidad con una incertidumbre conocida que permitirá la sinergia entre sensores e intercomparación de productos.

El protocolo recoge las consideraciones realizadas por el comité LPV (*Land Product Validation*), uno de los seis grupos creados dentro del WGCV, con el objetivo de desarrollar una serie de normas básicas que faciliten y orienten sobre las diferentes actividades que requiere la validación, tales como la adquisición de medidas *in-situ*, el muestreo espacial o el procedimiento del escalado (Privette et al 2000, Justice et al 2000, Cohen & Justice 1999).

## I.2 Estrategia de validación

Entre las actividades que incluye el proceso de validación destacan las siguientes:

### a. Validación a partir de medidas *in-situ* o validación directa

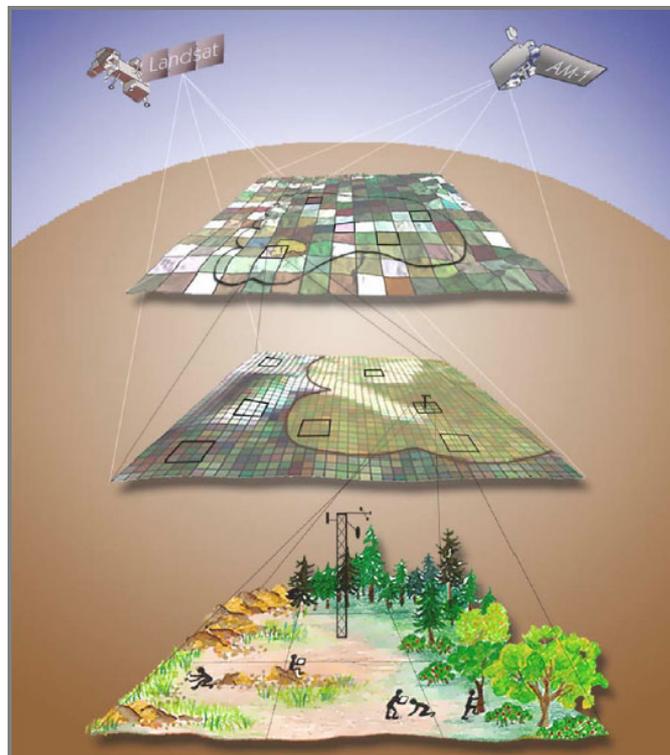
La validación a partir de medidas *in-situ* consiste en evaluar la exactitud del producto a partir de la comparación directa entre las estimaciones derivadas mediante satélite ( $X_{sat}$ ) y valores de referencia ( $X_{ref}$ ) del mismo atributo. Se trata de un proceso complicado, principalmente debido a la heterogeneidad mostrada por la variable de interés en el área de estudio.

La validación directa se basa principalmente en, (i) la caracterización de la zona de estudio a partir de medidas *in-situ*, (ii) el escalado de la información *in-situ* a la resolución espacial del producto a validar y (iii) la comparación del producto derivado mediante teledetección con el producto estimado a partir de las medidas de referencia, donde cada uno de ellos introduce un error en el resultado final. La figura I.1 muestra la metodología seguida por el proyecto MODLAND basada en los tres puntos anteriores. La metodología llevada a cabo consiste en concentrar las medidas *in-situ* en un área de 25 km<sup>2</sup> donde se sitúa una estación meteorológica que mide vapor de agua e intercambios de CO<sub>2</sub>, entre otros (Running et al 1999). Posteriormente utilizan una imagen de alta resolución (e.g. Landsat ETM+) para escalar las medidas *in-situ*. Dicha imagen cubre un área mayor que la zona donde se han realizado las medidas *in-situ* para disponer de un número significativo de píxeles a la resolución del producto a validar (Cohen et al 2003a). El muestreo espacial realizado se diseña para facilitar el uso de técnicas estadísticas (Burrows et

---

<sup>6</sup> <http://avi1.avignon.inra.fr/valeri/>

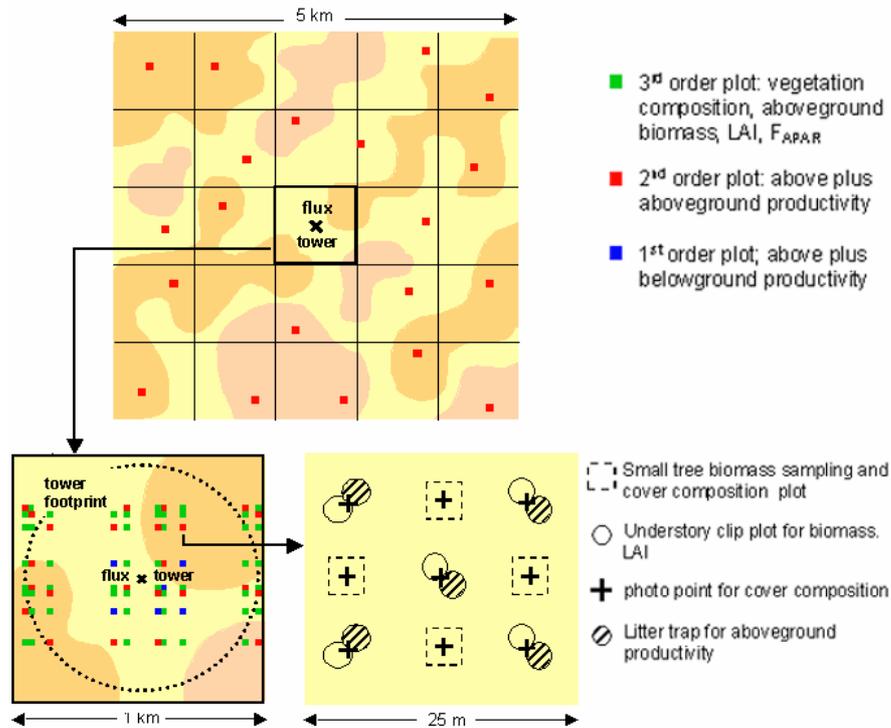
al 2002). Los datos *in-situ* se utilizan para desarrollar algoritmos específicos de la zona y modelar los parámetros de interés (e.g. LAI y FAPAR), así como, caracterizar el error de dichas estimaciones (Cohen & Justice 1999, Morisette et al 2002, 2003).



**Figura I.1.** Metodología seguida para validar sensores de media y baja resolución a partir de medidas *in-situ*. Imagen obtenida del proyecto de validación MODLAND.

El principal problema que presenta la validación directa se refiere a la caracterización de la zona de estudio a partir de un número limitado de medidas *in-situ* que sea representativo de la variabilidad presente en el área de estudio (Levy & Lemeshow 1999). Este proceso requiere considerar un conjunto de decisiones que dependen principalmente de la variable a conocer, como por ejemplo los instrumentos de medida y el muestreo realizado. La variabilidad mostrada por la magnitud a medir condicionará, además de la distribución de las medidas, aspectos importantes como los instrumentos y personas necesarios para caracterizar la zona o la duración de las medidas, etc. El diseño del muestreo espacial implica una serie de consideraciones sobre el área de estudio, áreas de muestreo y unidades elementales de medida (*Elementary Sampling Unit*, ESU). Dichas consideraciones hacen referencia, entre otras, a la distribución espacial y al número de áreas de muestreo requeridas dentro del área de estudio, al tamaño de estas regiones y al número y tamaño de las unidades mínimas de medida (Liang 2004). La figura I.2 presenta un ejemplo del muestreo realizado en el proyecto

*BigFoot*<sup>7</sup> (Cohen et al 2003a). El área de estudio (i.e. 5×5 km<sup>2</sup>) se divide en regiones de 1 km<sup>2</sup> donde se distribuyen diferentes ESUs de 25×25 m<sup>2</sup>. Se distinguen diferentes ESUs (verdes, rojas y azules) según los parámetros medidos y se realiza un muestreo sistemático en cada una de ellas compuesto de un mínimo de cuatro (e.g. biomasa) y nueve medidas (e.g. FVC) según el parámetro de interés.



**Figura I.2.** Ejemplo del muestreo realizado en el contexto del proyecto *BigFoot*. El área de 5×5 km<sup>2</sup> se divide en áreas de muestreo con dimensiones de 1 km<sup>2</sup>. En cada área de muestreo se distribuyen una serie de unidades elementales de medida (ESU) con dimensiones de 25×25 m<sup>2</sup>.

Posteriormente a la caracterización a partir de medidas *in-situ*, el siguiente paso consiste en extender espacialmente la información para poder realizar la comparación con los productos derivados mediante teledetección. Éste es un problema complicado debido a la heterogeneidad del área de estudio y que se resuelve desde varias perspectivas (Liang 2004, Raffy 1994, Townshend & Justice 1988, Woodcock & Strahler 1987). El proceso consiste en extender espacialmente las medidas *in-situ* (i.e. escala fina) a una resolución menor con el propósito de disponer de un mapa a alta resolución de los parámetros medidos *in-situ*. Posteriormente, se reescalan los mapas a la resolución espacial de los productos derivados mediante satélite a partir de técnicas de agregación (e.g. media aritmética, transformada de fourier). Este proceso requiere de la elección de técnicas adecuadas que conserven la variabilidad mostrada por la variable de interés.

<sup>7</sup> [www.fsl.orst.edu/larse/bigfoot/](http://www.fsl.orst.edu/larse/bigfoot/)

El escalado es problemático en cuanto que la estructura espacial y propiedades geoestadísticas de la escena cambian con la escala (Openshaw 1984). Los modelos desarrollados para una escala en particular no implican que sean extrapolables a otras escalas, los cuales pueden complicarse si existen varias variables de interés (Pierce & Running 1995).

En el caso de productos a escala global, este procedimiento requiere la adquisición de medidas *in-situ* sobre diferentes áreas de estudio distribuidas globalmente, siendo de gran utilidad las redes internacionales de adquisición de datos. Una de las estrategias que actualmente se utilizan para la validación de sensores de media y baja resolución (e.g. MODIS, MISR, VEGETATION, MERIS) a partir de medidas *in-situ*, es el uso de imágenes de alta resolución (e.g. Landsat/TM, SPOT) para derivar una relación empírica (e.g. función de transferencia) que relacione los parámetros biofísicos medidos *in-situ* con los valores radiométricos y obtener mapas de alta resolución de los productos a validar (Baret et al 2005a, Fernandes 2003, Tian et al 2002a).

#### **b. Intercomparación con otros productos o validación indirecta**

La validación indirecta permite evaluar el producto estimado a partir de la comparación con productos actuales. No es dependiente de las medidas de referencia y por tanto es posible realizarlo sobre un muestreo amplio de cubiertas vegetales y ecosistemas, condiciones climáticas (e.g. diferentes latitudes), tanto para una fecha en particular o un periodo de tiempo.

La intercomparación se puede llevar a partir de varios procedimientos, bien aplicando algoritmos diferentes a datos del mismo sensor, bien aplicando el mismo algoritmo a sensores diferentes, o también a partir de productos derivados con sensores y algoritmos diferentes. Esta actividad se puede realizar mediante el análisis de tendencias y parámetros estadísticos (e.g. RMSE, *bias*, desviación estándar, etc.), donde la disponibilidad de información auxiliar será de gran utilidad, como por ejemplo usos del suelo, tipo de cubierta, medidas *in-situ* disponibles, etc.

#### **c. Seguimiento temporal del producto**

El seguimiento temporal se lleva a cabo mediante el análisis de la evolución temporal del parámetro de estudio sobre diferentes zonas de estudio. Este procedimiento permite evaluar la consistencia temporal del producto en base a su respuesta con el ciclo fenológico anual de la cubierta y variaciones a lo largo de un determinado periodo.

### **I.3 Problemática de la validación directa**

Como se ha mencionado anteriormente, la metodología de validación debe ser fácil de entender, sencilla y trasladable a otras zonas. La validación directa no es una actividad sencilla debido a los diferentes procesos que la constituyen, como la

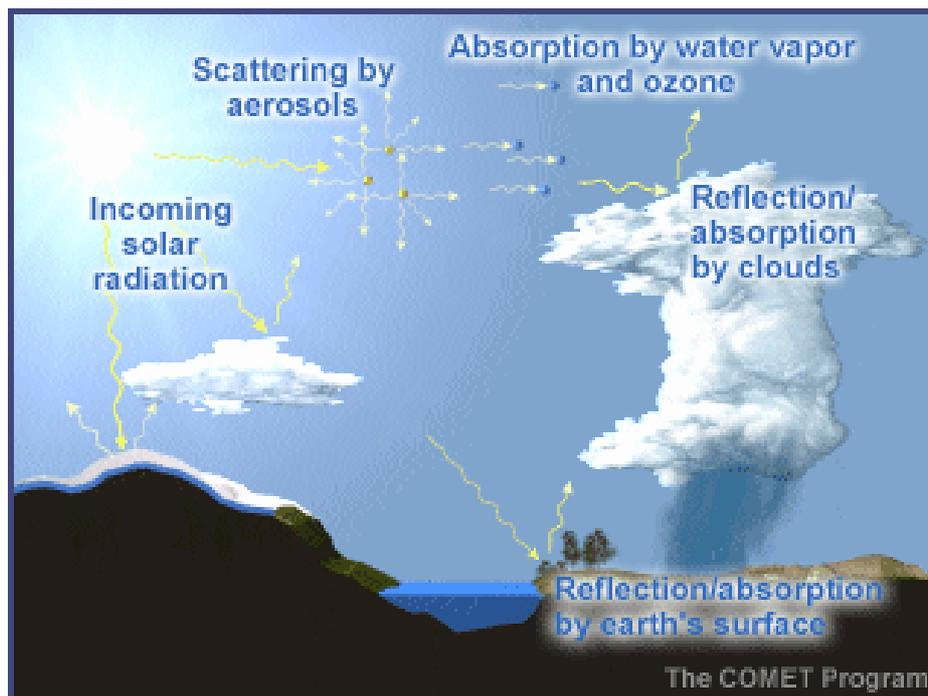
estimación del producto mediante teledetección, la caracterización *in-situ* de la variable, la elección de instrumentos de medida, el muestreo de campo y el escalado de la información *in-situ* hasta la resolución del producto.

Un aspecto importante, y que puede introducir errores en la validación directa, es en qué medida la variable *in-situ* y la variable derivada mediante teledetección son comparables. En la validación de parámetros biofísicos (e.g. LAI y FVC), las medidas realizadas *in-situ* llevan asociado un error debido al instrumento de medida, al operador, factores externos, etc. En el caso del LAI y FVC se tratan de magnitudes que se definieron para estimarlas *in-situ* y que, posteriormente, se han adaptando a la estimación mediante técnicas de teledetección, comenzado con instrumentos ópticos para medirla *in-situ* (e.g. LICOR LAI2000, TRAC, etc.) y trasladando dichos conocimientos a un sistema de teledetección. Este análisis permitirá tener en cuenta las limitaciones y posibles incertidumbres inherentes a la estimación de dicha magnitud mediante teledetección.

### **I.3.1 Errores asociados a la estimación del producto**

La estimación de cualquier producto implica previamente realizar un pre-procesado de la imagen en bruto, que lleva asociado una serie de errores a evaluar, para después aplicar un algoritmo que relacione la radiancia que recibe del sensor con la variable física de interés.

Este proceso incluye tratamientos básicos de la información recogida por el sensor, como la corrección atmosférica de los productos, la cual se refiere al proceso que convierte la radiación en el techo de la atmósfera a reflectividad en superficie (Kaufman 1989). Para ello, es necesario conocer el proceso de transferencia radiativa que ocurre en la atmósfera y su composición. Entender lo que ocurre en la atmósfera implica conocer los diferentes procesos de absorción, transmisión y dispersión que se producen, (ver figura I.3), como por ejemplo la composición de la atmósfera, el contenido en gases (e.g. vapor de agua, ozono), el contenido en aerosoles (e.g. nitratos, sales de los océanos, contaminación atmosférica, biomasa quemada), la presencia de nubes, etc. El paso más crítico de la corrección atmosférica se debe a la estimación del contenido en aerosoles y vapor de agua. Este problema se resolvería correctamente estimando la concentración de ambos componentes en el momento de adquisición de la imagen (e.g. mediante radiosondeos, Lidar, radiómetros espectrales como el Cimel 318, etc.) y aplicando, posteriormente, un código de transferencia radiativa, como el MODTRAN o 6S. Una amplia y detallada revisión de este problema y de las diferentes soluciones que se han propuesto se puede encontrar en Liang (2004).

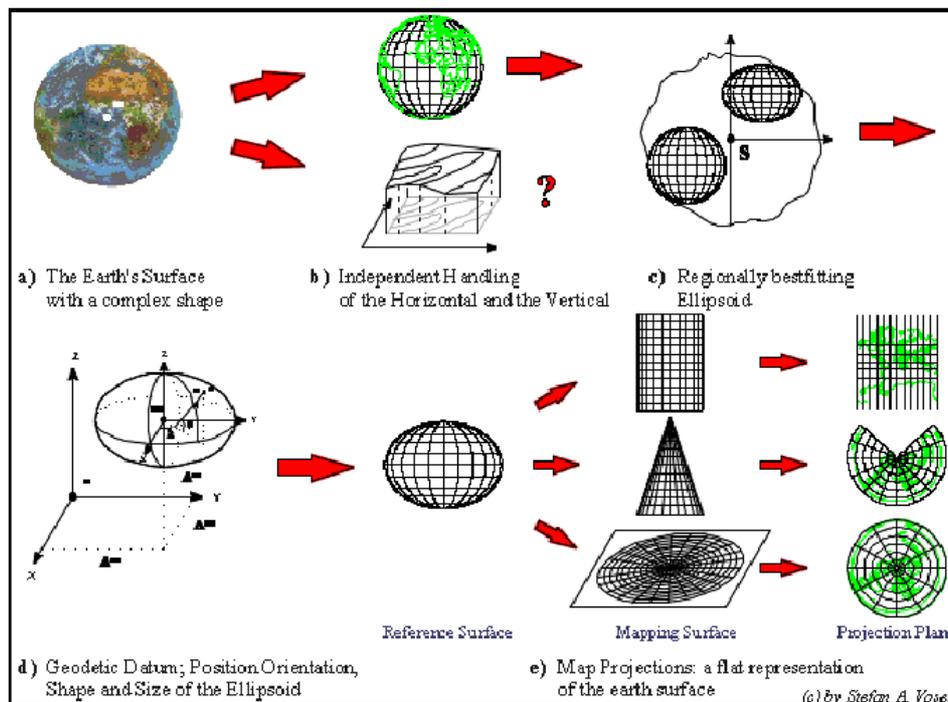


**Figura I.3.** Comportamiento de la radiación al paso por la atmósfera. Esta figura describe los diferentes procesos que afectan a la radiación incidente a su paso por la atmósfera.

Por otra parte, el producto debe ser corregido topográficamente dado que las sombras afectan en diferente proporción al dominio espectral, siendo una fuente de error más que se debe corregir (Holben & Justice 1980, Sandmeier & Itten 1997). Otra corrección que se debe llevar a cabo es la geométrica debido a las distorsiones que pueda presentar la imagen al ser adquirida por satélites o aviones. La corrección geométrica implica el proceso de rectificar y georeferenciar la imagen. La rectificación es el proceso de asignar a la imagen un sistema de proyección diseñado para representar la superficie de una esfera o esferoide (e.g. La Tierra) en un plano, ver figura I.4. Para ello se debe seleccionar, en primer lugar, un elipsoide que represente lo mejor posible la forma de la Tierra o la curvatura de la zona de estudio (figura I.4 a-d). A continuación se elige un sistema de proyección y se proyecta la imagen en un plano (figura I.4 e). Dado que la proyección implica una distorsión de la superficie, los diferentes sistemas comprometen la exactitud entre ciertas propiedades, tales como la conservación de la distancia, el ángulo o el área. Este proceso implica, normalmente, una transformación del tamaño de la imagen y del píxel, lo que da lugar a un cambio en el valor de los píxeles originales. Por otra parte, la georeferenciación se refiere al proceso de asignar coordenadas cartográficas a una imagen. La imagen puede ya estar proyectada en un plano, pero no estar georeferenciados en el sistema de coordenadas adecuado.

Por último, cabe destacar los errores cometidos al aplicar el algoritmo de estimación debido a la función de transferencia que se utiliza para describir el comportamiento de la variable con la radiación incidente en la cubierta vegetal, a

las variables que se consideran para describir el sistema y a las diferentes hipótesis realizadas.



**Figura I.4.** Diferentes pasos de los que se compone el proceso de registrar y georeferenciar una imagen.

### I.3.2 Errores asociados a la caracterización *in-situ*

La caracterización *in-situ* de parámetros relacionados con la cubierta vegetal no es un proceso sencillo cuando se realiza en superficies mayores de 10 km<sup>2</sup>. Cuestiones importantes que se plantean normalmente, se hacen más difíciles como, cuándo, qué y dónde medir (Burrows et al 2002).

Resolver estas preguntas implica tomar decisiones sobre el instrumento escogido para estimar dichos parámetros, el procedimiento de medida y el muestreo llevado a cabo. Los errores debido a la instrumentación están asociados principalmente a las características del detector (i.e. ruido debido a variaciones aleatorias en el detector, limitaciones por la resolución espacial y espectral, etc.). Por otra parte, los errores derivados del procedimiento de medida se deben principalmente a, (i) la influencia del operador (i.e. posición del detector, elección de repeticiones, etc.), (ii) factores externos a la medida (i.e., condiciones de iluminación, vegetación senescente, etc.) y (iii) variabilidad espacial presentada por la cubierta.

Por último, los errores que se derivan del muestreo elegido se relacionan con, (i) las dimensiones de la unidad elemental de medida en superficie, (ii) el número de repeticiones en dicha unidad elemental y (iii) la distribución espacial de las ESUs. El muestreo espacial es un aspecto tan importante como complicado, ya que se

pretende que el conjunto de medidas *in-situ* caracterice lo mejor posible la variabilidad mostrada por el parámetro de estudio dentro del área elegida (Tian et al 2002b). Sin embargo, la propia heterogeneidad de la superficie terrestre es una fuente de error importante sobre todo cuando se trabaja con imágenes de baja resolución, lo que hace extremadamente difícil caracterizar la zona a partir de medidas *in-situ*.

### I.3.3 Errores asociados al proceso de escalado

Existen dos procesos de escalado, (i) *up-scaling*, la conversión de resolución fina a baja y (ii) *down-scaling*, la conversión de baja resolución espacial a fina. Comúnmente se refiere a estos dos términos como agregación y desagregación. El proceso de *up-scaling* es más importante en la validación de productos que el proceso de *down-scaling*. Para validar productos de baja resolución, la situación ideal se cumpliría cuando los elementos a analizar correspondieran a superficies homogéneas (Woodcock & Harward 1992) y fuera posible encontrar una zona extensa de cómo mínimo 2-3 píxeles. Sin embargo, frecuentemente aparecen los píxeles mezcla que disminuyen la efectividad del análisis (Woodcock & Strahler 1987).

Esta limitación se resuelve, como se ha comentado anteriormente, utilizando imágenes de alta resolución para derivar mapas de la variable estimada. Sin embargo, una cuestión que se plantea respecto al escalado de la información es si se debería derivar las variables biofísicas a partir de la imagen de alta resolución y luego agregarla o primero agregarla a la resolución del producto a validar y posteriormente derivar las variables.

### I.4 Parámetros biofísicos de la cubierta vegetal

Por parámetros biofísicos de la cubierta vegetal entendemos aquellos parámetros con una especial incidencia en los ciclos biogeoquímicos de la Tierra (carbón, nitrógeno, azufre), ciclo del agua, y en el intercambio de energía con la atmósfera. En la región espectral solar estos son, principalmente, la fracción de cobertura vegetal (FVC), el índice foliar (LAI) y la fracción de radiación absorbida fotosintéticamente activa (FAPAR).

En el contexto de la teledetección, estos parámetros presentan un gran interés en aplicaciones relacionadas con la climatología, hidrología, agricultura de precisión, cambio global (Sellers et al 1997a), por estar directamente relacionados con el intercambio de flujos de masa y energía entre el sistema atmósfera-biosfera, así como también en la productividad neta de la cubierta (NPP) (Andrieu & Baret 1993, Prince 1991, Noilhan & Planton 1989).

### I.4.1 El índice de superficie foliar (LAI)

Desde el punto de vista de la teledetección, se trata de un parámetro fundamental por cuanto tiene una influencia directa en la cantidad de evapotranspiración, en la fotosíntesis de la cubierta y en la producción de biomasa (Nemani et al 1993). Es un parámetro incluido en los modelos que describen el intercambio de flujos de energía, masa y momento entre la biosfera y la atmósfera. Su estimación es necesaria para climatología, predicción numérica, estudios de la biosfera tales como la desertificación o deforestación, o para modelar el funcionamiento de la cubierta vegetal. En áreas agrícolas en particular, el LAI es un parámetro de gran importancia en la producción de la biomasa debido a su relación con diferentes aspectos como, la radiación interceptada, el crecimiento del cultivo, uso del agua y erosión del suelo, entre otros (Pearce et al 1965).

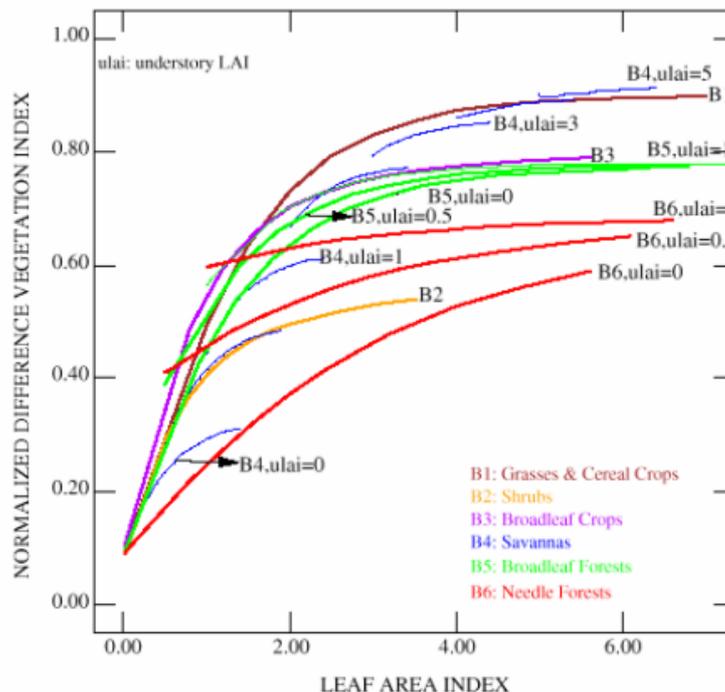
El concepto de LAI lo introdujo por primera vez Watson (1947) definiéndolo como el área total de las hojas fotosintéticamente activas (contabilizadas por sólo una cara) por unidad de suelo. A parte de esta definición, existen en la literatura al menos cuatro definiciones de LAI que se diferencian, principalmente, por los procesos o variables que se quieran estimar a partir de él (i.e. crecimiento de la vegetación, atenuación de la radiación en la cubierta, etc.) y por la técnica utilizada para estimarlo. Las cuatro definiciones más comunes son:

1. LAI total, se define como el área exterior total de las hojas por unidad de área horizontal que se encuentre debajo de la cubierta. Esta definición considera la forma de las hojas.
2. La mitad del LAI total.
3. El LAI horizontalmente proyectado, se define como la suma del área sombreada de cada hoja si fuera iluminada por una fuente de luz situada a una distancia infinita y perpendicular a ella.
4. El LAI proyectado inclinado, se define como el área total proyectada por cada hoja por unidad de suelo considerando la inclinación de la hoja.

Aunque actualmente continúan apareciendo otras interpretaciones, las definiciones 2 y 3 son las más utilizadas (Stenberg et al 1994, Fassnacht et al 1994, Chen & Black 1992, 1991), apreciándose un aumento considerable de la última definición en la literatura reciente (Barclay 1998).

En la extensa literatura dirigida a este parámetro, se encuentra una estrecha relación con diferentes parámetros relacionados con la cubierta vegetal, como los índices de vegetación (e.g. NDVI), la FVC o la FAPAR. En ocasiones, el LAI presenta una relación lineal con el NDVI (Wardley & Curran 1984, Tucker 1980, Wiegand 1979) o asintótica en el caso de valores mayores que 2 (Carlson & Ripley 1998), ver figura I.5. Este comportamiento muestra ser dependiente de la geometría de la cubierta, las propiedades ópticas del suelo y de las hojas, así como también de

las condiciones de observación y de iluminación (Baret et al 1991, Clevers 1989). El LAI se comporta, respectivamente, con la FAPAR y la FVC según la ley de Poisson (Turner et al 2002, Daughtry et al 1992). El rango de variación encontrado en la literatura alcanza valores máximos entre 6 y 8 para la clase de bosques caducifolios, y valores entre 2 y 4 para la clase de cultivos (Beadle 1993).



**Figura I.5.** Comportamiento del LAI con el NDVI para diferentes cubiertas vegetales. Tal como se expone en la literatura, se observa un comportamiento lineal con el NDVI hasta valores de LAI igual a 2 y asintótico a partir de 3 y 4.

#### I.4.2 La fracción de cobertura vegetal (FVC)

Este parámetro es de suma importancia, para desacoplar la contribución de la fracción de suelo y vegetación en los procesos de balance de energía que tienen lugar en la interfase biosfera-atmósfera, con especial atención en la determinación de la evapotranspiración que proviene del suelo y de la vegetación (Weiss & Baret 1999, Sellers et al 1996). Su variación espacial en un ecosistema proporciona una medida cuantitativa de la heterogeneidad del paisaje lo cual es de gran interés en estudios ecológicos. Al igual que el LAI tiene un amplio rango de aplicaciones, de interés tanto para la comunidad científica, como para usuarios del ámbito público y privado.

La fracción de cobertura vegetal se define como la proporción de vegetación, observada desde el nadir, que se distribuye horizontalmente sobre la superficie (Deardorff 1978). El valor de la FVC se restringe al rango entre 0 y 1. Presenta una relación lineal con el NDVI (Gutman & Ignatov 1998) y con la FAPAR (Myneni & Williams 1994).

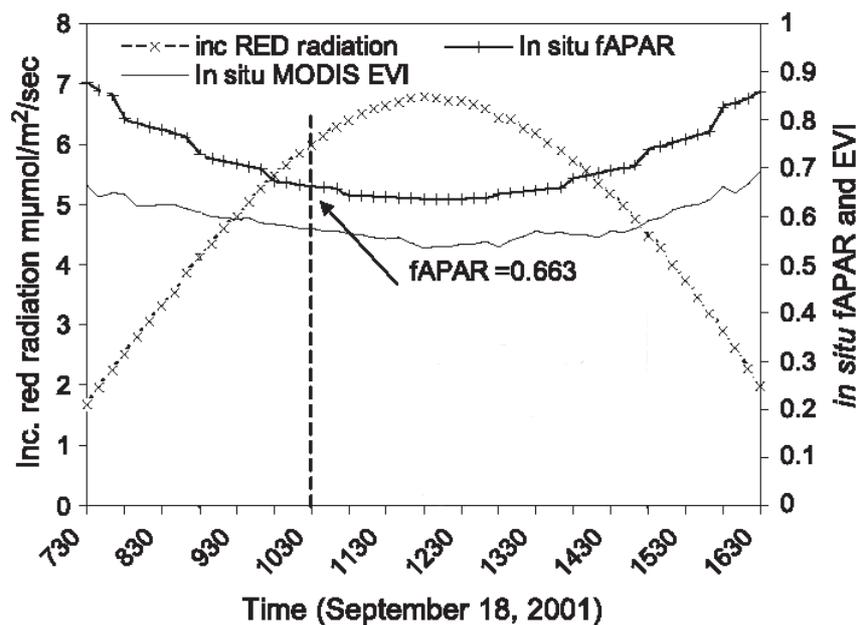
### I.4.3 Fracción de radiación fotosintéticamente activa absorbida (FAPAR)

Se define como la fracción de la radiación fotosintéticamente activa en el rango espectral de 0.4 a 0.7  $\mu\text{m}$  absorbida por la cubierta para transformarla en energía química durante la fotosíntesis y, por tanto, expresa la capacidad de la cubierta para absorber energía (Fensholt et al 2004). La FAPAR es una variable necesaria en los modelos de productividad de los ecosistemas, en modelos de clima, hidrología y ecología (Sellers et al 1997b).

La FAPAR se calcula como el cociente entre la radiación fotosintéticamente activa absorbida por la cubierta (APAR), en  $\text{MJ}/\text{m}^2$ , y la radiación incidente fotosintéticamente activa (PAR) (Begué 1991). La PAR absorbida por la vegetación verde es la cantidad ideal para estimar la fijación del carbono en la cubierta (Gallo et al 1993), pero, por otra parte, la FAPAR está más relacionada con los índices de vegetación (Hall et al 1990).

En la literatura es posible encontrar como la FAPAR se relaciona de forma lineal con el NDVI o EVI (Fensholt et al 2004, Huete et al 2002, Ehiphania & Huete 1994, Begué et al 1991) resolviendo el problema de saturación que se presentan cuando se estima la FAPAR a partir del LAI. La FAPAR muestra un rango de variación diario con valores máximos al amanecer y al atardecer (i.e. ángulo cenital solar elevado), y valores mínimos alrededor del mediodía cuando el Sol se sitúa en el nadir (Fensholt et al 2004).

La figura I.6 muestra un ejemplo de dicha variación diaria a partir de la FAPAR medida *in-situ* cada 10 minutos, junto con la radiación incidente en el rojo y el índice EVI derivado de MODIS. El área caracterizada corresponde a una zona semiárida de Senegal con un alta presencia de Sabana (Fensholt et al 2004). Se observa como el máximo y mínimo de la FAPAR corresponden al mínimo y máximo de radiación incidente, y como la FAPAR y el EVI presentan un comportamiento muy similar.



**Figura I.6.** Rango de variación diaria de FAPAR medido *in-situ* cada 10 minutos donde se observan valores máximos al amanecer y atardecer. Estos resultados se adquirieron en un área semiárida de Senegal con un alta presencia de Sabana (Fensholt et al 2004).

## I.5 Caracterización *in-situ* de LAI, FVC y FAPAR

Entre los métodos existentes para caracterizar *in-situ* el LAI, FVC y FAPAR destacan los métodos ópticos, los cuales se basan en la estimación de los parámetros a partir de la medida indirecta de la transmisión de la radiación en el interior de la cubierta vegetal. Dichos métodos presentan algunas ventajas como, menor tiempo en la estimación, fácil manejo y menor impacto en la cubierta vegetal (Jonckheere et al 2004, Gower et al 1999). Además de estas técnicas, los métodos indirectos incluyen técnicas que estiman a partir del contacto con las hojas (e.g. método del punto inclinado, Wilson 1963, 1960) o técnicas alométricas (Gower & Norman 1991, Smith et al 1991).

Los métodos indirectos ópticos son los más extendidos y se basan en la medida de la frecuencia de contacto (Wilson 1960) o la *gap fraction* (Ross 1981). La frecuencia de contacto se define como la probabilidad de que un rayo de luz penetre dentro de la cubierta e interactúe con algún elemento de la vegetación. La *gap fraction*,  $P_0(\theta)$ , o fracción de huecos en la cubierta hace referencia al valor integrado acimutalmente de la frecuencia de huecos sobre dicha cubierta (Weiss et al 2004a, Nilson 1971), y por tanto es una cantidad que se puede medir. Este parámetro depende de la radiación incidente, la estructura de la cubierta (e.g. LAI) y las propiedades ópticas de los elementos que la componen.

Otro aspecto a considerar en el uso de la *gap fraction* para estimar dichos parámetros es que no distingue entre elementos fotosintéticamente activos y no activos de la cubierta como por ejemplo el tronco, ramas o flores, los cuales son una fuente importante de error (Chen et al 1997, Whitford et al 1995). De forma alternativa, se han propuesto otro tipo de índices y parámetros que permiten corregir este efecto, como el índice de superficie de vegetación (VAI) (Fassnacht et al 1994), el índice de superficie de la planta (PAI) (Neumann et al 1989), el parámetro  $\alpha$  definido por Chen (1996) o, incluso, instrumentos como la cámara hemisférica que permite distinguir los elementos fotosintéticamente no activos (Hill 1924). A continuación se presentan los diferentes procedimientos que se utilizan para estimar los parámetros LAI, FVC y FAPAR a partir de la *gap fraction*.

## LAI

Aunque por definición la estimación del LAI resulta directa (Evans 1972) a partir de sumar el área total de las hojas, éste se basa en un método destructivo y poco realista cuando se pretende muestrear un área extensa. Se han desarrollado numerosas técnicas para estimar el LAI que se pueden englobar en dos grupos, los métodos directos y los indirectos (Jonckheere et al 2004, Kussner & Mosandl 2000, Gower et al 1999). El primero de los métodos consiste en medir la superficie foliar de forma directa, sin embargo, presenta la desventaja de que consume mucho tiempo y, por tanto, no resulta compatible con el seguimiento a largo plazo del desarrollo de la superficie foliar tanto espacial como temporal (Chason et al 1991). Por este motivo, se han desarrollado otro tipo de métodos que resuelven estas limitaciones, como son los métodos indirectos los cuales estiman el LAI a partir de la estimación de otras variables más sencillas de medir (Gower et al 1999, Fassnacht et al 1994).

Los procedimientos actualmente utilizados se basan en la medida de la *gap fraction* y posterior inversión de la ecuación I.1. Cuando las hojas se consideran infinitamente pequeñas y distribuidas espacialmente de forma aleatoria, la *gap fraction* se relaciona con el LAI a partir del modelo de Poisson (Welles 1990):

$$P_0(\theta_v, \varphi_v) = e^{-N(\theta_v, \varphi_v)} = e^{-\frac{G(\theta_v, \varphi_v) \text{LAI}}{\cos \theta_v}} \quad \text{[I.1]}$$

donde  $G(\theta_v, \varphi_v)$  es la función de proyección, es decir la proyección media de la normal a la superficie foliar en la dirección  $(\theta_v, \varphi_v)$ . La función  $G(\theta_v, \varphi_v)$  toma unos valores dependiendo del tipo de función de distribución foliar (e.g. LIDF) que presente la cubierta (i.e. orientación planófila, erectófila o esférica), el cual se suele considerar acimutalmente simétrico. Una descripción más detallada de este comportamiento se puede encontrar en Ross, (1981) y en el anexo A.

Sin embargo, en el caso de que la cubierta no presente una distribución aleatoria de hojas, y muestre cierto nivel de agrupamiento, se debe introducir un término que

tenga en cuenta este factor, también denominado grado de agrupamiento ( $\Omega$ ) o *clumping* de la cubierta (Nilson 1971). El efecto *clumping* da lugar a un aumento de la fracción de radiación no interceptada por la cubierta vegetal, desviándose así del modelo de Poisson, por lo que se define un LAI efectivo (LAI<sub>e</sub>) como:

$$\text{LAI}_e = \text{LAI} \cdot \Omega \quad [\text{I.2}]$$

donde  $\Omega$  presenta valores mayores que la unidad para distribuciones regulares, igual a la unidad para aleatorias e inferior a la unidad para estructuras que presentan agrupamiento. Campbell & Norman (1998) analiza el efecto del agrupamiento para el caso particular de cultivos. Se observa una reducción de hasta un 30% en la radiación interceptada por la cubierta, resultando en una subestimación del LAI.

Existen diferentes variantes de la ecuación I.1 para estimar el LAI que consisten en simplificar las direcciones consideradas. Uno de los métodos más simples considera sólo la dirección cenital de 57.5°, dado que se ha demostrado que para este ángulo la función de proyección  $G(\theta_v, \varphi_v)$  es independiente del ángulo medio de inclinación foliar (ALA) (Bonhomme et al 1972a, Wilson 1963), mostrando un error del 7% en el LAI cuando se considera esta aproximación. Posteriormente, Miller (1967) propuso una simplificación de la ecuación A.3, la cual estimaba el LAI suponiendo que éste sólo dependía del ángulo cenital de observación.

Por otra parte, se utilizan las técnicas de inversión a partir de métodos iterativos (Perry et al 1988) o tablas de interpolación como las Look-Up-Tables (LUT) (Weiss et al 2000, Knyazikhin et al 1998). Estas técnicas permiten estimar de forma más exacta el LAI y el ALA utilizando múltiples direcciones sin necesidad de realizar aproximaciones como en los casos anteriores. Se puede encontrar una revisión e intercomparación de estos métodos en Kimes et al (2000) y Combal et al (2002).

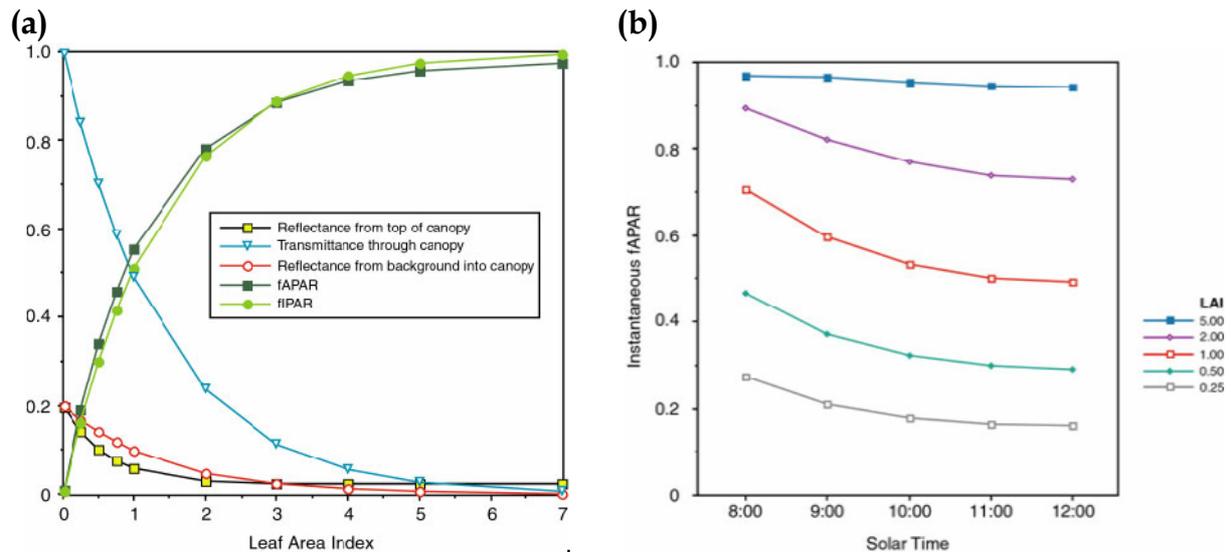
## FVC

Dado que corresponde a la fracción de suelo cubierta por vegetación, su estimación se realiza directamente si se conoce la fracción de huecos visible en el nadir,  $P_0(0)$ . La fracción de cobertura se obtiene a partir de la expresión,  $\text{FVC} = 1 - P_0(0)$ . La estimación de la  $P(0)$  se realiza comúnmente a partir de la clasificación de fotografías realizadas desde la normal a la superficie (Calera et al 2001).

## FAPAR

La FAPAR varía diariamente en función de las propiedades de la cubierta (figura I.7b), sin embargo se puede estimar la FAPAR instantánea a partir de la *gap fraction* medida en la dirección del Sol en el momento de adquisición,  $P_0(\theta_s)$ . En estudios relacionados con la interacción de la radiación en la cubierta se aproxima la FAPAR instantánea a la fracción de radiación incidente (FIPAR) en la cubierta vegetal (Gower et al 1999, Weiss & Baret 1999, Gallo et al 1993, 1986), es decir se

supone que se comporta como un cuerpo negro (transmisividad y reflectividad nula). De este modo, el cálculo de la FAPAR a partir de la *gap fraction* se simplifica según la expresión  $FAPAR=1-P_0(\theta_s)$  (Weiss & Baret 1999). Aunque la diferencia entre la FIPAR y la FAPAR depende de la fracción, composición y reflectividad de la cubierta, existe una buena aproximación entre ambas en función del LAI (ver figura I.7). Respecto a la fracción de cobertura, la diferencia entre la FAPAR y FIPAR es mayor para cubiertas dispersas.



**Figura I.7.** Representación gráfica de la influencia de la arquitectura de la cubierta en la FAPAR y FIPAR (a) y la variación de la FAPAR diaria (b).

### I.5.1 Instrumentos de medida basados en la *gap fraction*

Los diferentes instrumentos basados en la medida de la *gap fraction* se engloban en dos categorías, (i) los que suponen una distribución espacial aleatoria de las hojas y, (ii) los que consideran un cierto agrupamiento en la cubierta a través de la distribución de los huecos (*gap size distribution*). En la primera categoría destacamos el DEMON<sup>8</sup> (Lang et al 1985), el AccuPAR<sup>9</sup> (Decagon 2001), el LICOR LAI2000<sup>10</sup> (Li-Cor 1992), mientras que en la segunda categoría destaca el TRAC<sup>11</sup> (Chen et al 1997). La cámara hemisférica pertenece a ambas categorías, dado que permite estimar tanto la *gap fraction* como la *gap size distribution* (Jonckheere et al 2004, Hill 1924). En los últimos años el uso de las fotografías hemisféricas (*Digital hemispherical Photographs, DHP*) ha aumentado de forma considerable en diversas aplicaciones relacionadas con la cubierta vegetal (Jonckheere et al 2004). Diferentes autores concluyen que la cámara hemisférica presenta un alto potencial en la estimación de parámetros estructurales frente a otros instrumentos como el LICOR

<sup>8</sup> <http://www.cbr.clw.csiro.au/pyelab/tour/demon.htm>

<sup>9</sup> <http://www.decagon.com/>

<sup>10</sup> <http://www.licor.com/>

<sup>11</sup> 3<sup>rd</sup> Wave Engineering, Ontario, Canada

LAI2000 o el TRAC (Jonckheere et al 2004, Leblanc et al 2002, White et al 2000), debido principalmente a que permite discriminar espacialmente los diferentes elementos de la cubierta.

A continuación describimos en detalle los dos instrumentos ópticos utilizados en este trabajo para la estimación de los parámetros LAI, FVC y FAPAR. Las estimaciones se han llevado a cabo a partir del LICOR LAI2000 y la cámara hemisférica. El LICOR LAI2000 se presenta como un instrumento ampliamente aceptado en la estimación del LAI debido principalmente a su fácil manejo y rápida adquisición de las medidas (Deblonde et al 1994, Gower & Norman 1991). Por otra parte, la cámara hemisférica presenta dos ventajas importantes. En primer lugar, la DHP proporciona la *gap fraction* en todas las direcciones cenitales, lo que permite estimar diferentes parámetros estructurales de la cubierta, como son el LAI, FVC, el *clumping* y ALA, y también parámetros relacionados con el régimen de radiación solar como la FAPAR (White et al 2000, Rich et al 1993, Rich 1990, Bonhomme et al 1972b). En segundo lugar, presenta un mayor intervalo óptimo de aplicación que el LICOR LAI2000, dado que permite estimar la *gap fraction* bajo un amplio rango de condiciones de iluminación, extendiendo las horas útiles de medidas.

### LICOR LAI2000 Plant Canopy Analyzer

Es un instrumento similar a la cámara hemisférica en cuanto que el sensor del instrumento se sitúa bajo una lente angular u ojo de pez, que proyecta la radiación difusa incidente sobre cinco fotodiodos concéntricos situados a diferentes posiciones cenitales que abarcan el rango angular desde 0 a 75° (7°, 23°, 38°, 53° y 68°). Además, incluye un filtro óptico que enmascara la radiación incidente cuya longitud de onda sea superior a 490 nm. De este modo, se pretende minimizar la radiación dispersada por la cubierta y conseguir un mayor contraste entre las hojas, las cuales se comportan ópticamente como un cuerpo negro, y el cielo, como un objeto brillante. El cociente entre las medidas simultáneas arriba y debajo de la cubierta proporciona la estimación del *gap fraction*. Posteriormente, el LAI se determina a partir de la inversión del modelo de Poisson, descrito en la ecuación [I.1] (Welles & Norman 1991).

El LICOR LAI2000 proporciona una solución numérica a la ecuación [I.1] para la transmisividad que registran los cinco detectores angulares (Welles & Norman 1991), que se expresa de la siguiente forma:

$$LAI = 2 \cdot \sum_{i=1}^5 \frac{\ln P_0(\theta_i)}{\cos \theta_i} \cdot W_i \quad [I.3]$$

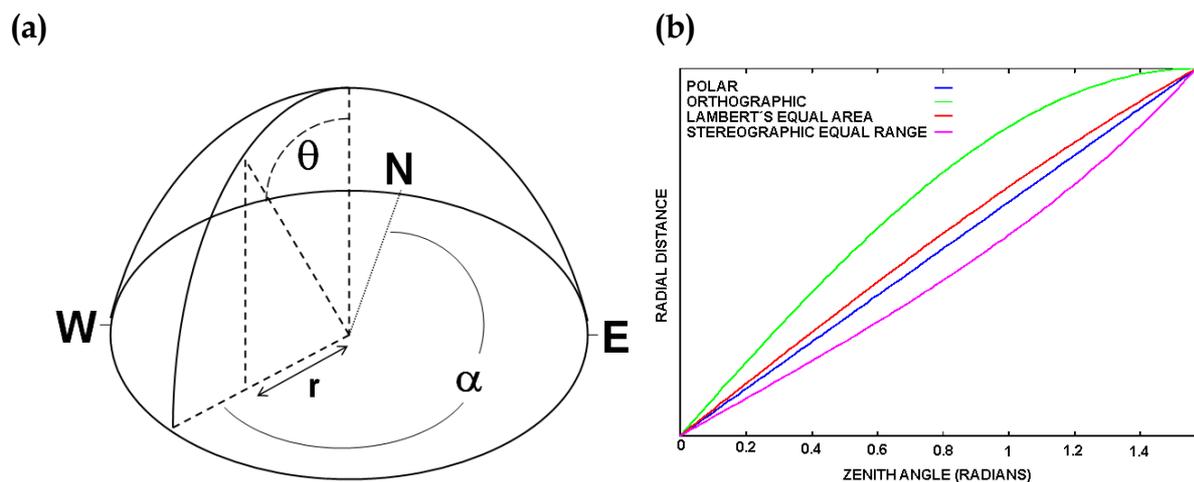
donde  $i$  corresponde al número de detectores y  $W_i$  a los pesos asociados a cada uno de ellos, 0.034, 0.104, 0.160, 0.218 y 0.484, respectivamente. Dado que estos valores son constantes, la ecuación [I.3] no requiere mucho tiempo de cálculo, permitiendo que el LICOR LAI2000 proporcione una estimación del LAI a medida

que se van guardando las medidas. Es importante remarcar que el valor estimado por el LICOR LAI2000 corresponde a un LAI efectivo (Ec. [I.2]). Debido a que dicho instrumento se basa en la medida de la transmisividad, incluye en sus cálculos todos aquellos elementos que se comportan ópticamente como cuerpos negros para longitudes de onda menores a 490 nm y además no distingue entre elementos fotosintéticamente activos y no activos como son el tronco, las flores y frutas (Chen & Black 1992).

### Cámara hemisférica

La cámara hemisférica fue originalmente diseñada por Hill (1924) para proporcionar una visión completa del cielo para estudios relacionados con la formación de las nubes. Este instrumento consta de una cámara digital equipada con un ojo de pez que consiste esencialmente en la proyección de las coordenadas angulares de un objeto de tres dimensiones en un plano (Rich 1990), ver figura I.8a. La imagen desde abajo proporciona una visión de todo el cielo, con el cenit en el centro de la imagen y el horizonte en los extremos de la imagen.

Cada lente angular se caracteriza por su función de proyección, la cual relaciona el ángulo entre el rayo incidente y el eje óptico de la cámara con la distancia radial  $r$  entre dicho punto y el centro de la imagen. Las proyecciones más utilizadas son, por ejemplo, la estereográfica, ortográfica, o simplemente polar (el radio de un punto de la imagen es directamente proporcional al ángulo que forma dicho objeto con el eje de la lente) (Rich 1990), ver figura I.8b. Aunque cada método de proyección proyecta en la imagen un mismo punto con una posición radial diferente en la imagen, las diferencias son muy pequeñas (Herbert 1986).

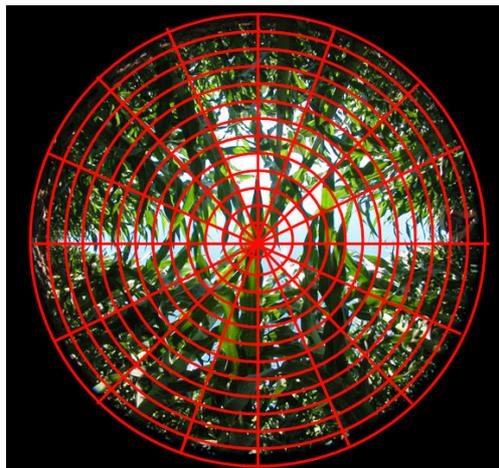


**Figura I.8.** Ejemplo de la configuración angular que corresponde a una imagen hemisférica (a), donde  $\theta$  y  $\alpha$  corresponden al ángulo cenital y acimutal, respectivamente. La figura (b) muestra las funciones de proyección más utilizadas.

El procesamiento de las imágenes hemisféricas consiste en transformar la posición de los píxeles en coordenadas angulares y clasificar los píxeles en suelo/cielo y vegetación verde para calcular la *gap fraction* y la distribución del brillo. A partir de

estas variables es posible obtener los parámetros anteriormente descritos. Existen diferentes programas desarrollados para procesar este tipo de imágenes, aunque la mayoría están diseñados para procesar fotografías desde abajo, como por ejemplo Hemiview (Rich 1990), SCANOPY (Rich et al 1993), GLA (Frazer 2000) y CANEYE ([www.avignon.inra.fr/can\\_eye](http://www.avignon.inra.fr/can_eye)). Estos programas permiten importar imágenes hemisféricas, mostrarlas y analizarlas a partir de técnicas de clasificación de la imagen.

Todos los programas se basan principalmente en el modelo de Poisson para derivar el LAI y otros parámetros estructurales de la cubierta (e.g. el ángulo de inclinación de las hojas, ALA). El proceso que siguen todos ellos consiste principalmente en la clasificación de la imagen para estimar la *gap fraction* y a partir de ella la estimación de parámetros estructurales, como LAI, ALA y *clumping*, mediante la inversión de la *gap fraction* en función del ángulo cenital de observación, ver figura I.9. Por otra parte, los parámetros relacionados con el régimen de radiación solar (e.g. radiación directa, difusa o FAPAR) se derivan al superponer la *gap fraction* en función del ángulo cenital y acimutal estimada de la fotografía (i.e. *gap fraction* bidireccional) con la posición del Sol en función del ángulo cenital y acimutal a lo largo del día (Rich 1990).



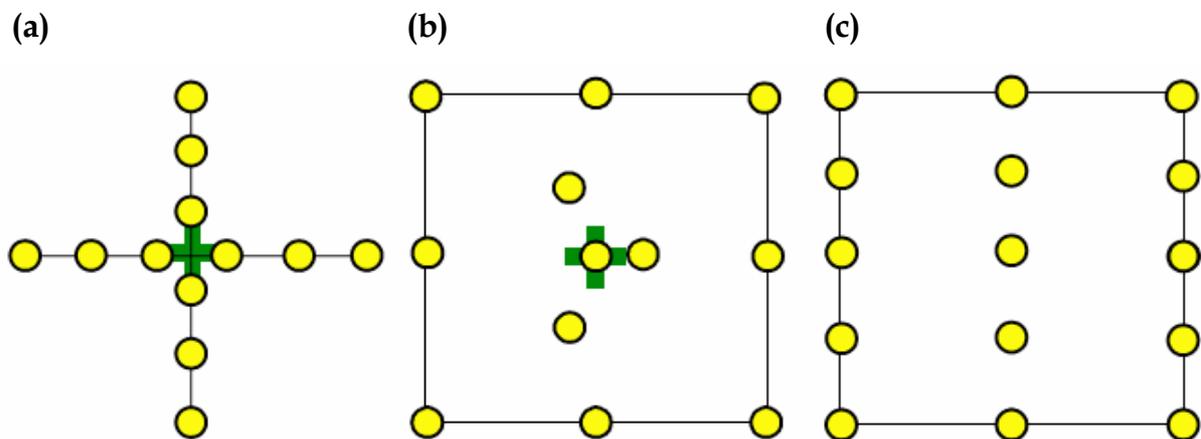
**Figura I.9.** Imagen obtenida desde abajo con la cámara hemisférica en una cubierta de maíz. La figura muestra un ejemplo del procedimiento para calcular la *gap fraction* a partir de la división en secciones.

Las principales diferencias que existen entre los programas consisten en las funciones que ofrecen (e.g. número máximo de imágenes que procesa, tiempo computacional, posibilidad de procesar fotos adquiridas desde arriba (*downward looking*) o debajo de la cubierta (*upward looking*), en los algoritmos utilizados para clasificar (e.g. uso de valores de corte en la intensidad, *convex hull*, etc.) y en las técnicas utilizadas para invertir el modelo de Poisson (e.g. LUT, redes neuronales, etc.).

### I.5.2 Técnicas de muestreo

La elección de dónde medir es una de las consideraciones más importantes en la caracterización *in-situ*, dado que el conjunto de datos adquirido será considerado como representativo de toda la población presente en el área de estudio. Este procedimiento requiere elegir, (i) las dimensiones de la ESU, (ii) el número de medidas que la compongan y (iii) el número, tamaño y posición de las regiones de entrenamiento dentro del área de estudio.

Como se ha comentado anteriormente, por ESU nos referimos al área muestreada que corresponderá a un único valor en el conjunto de datos. El valor asignado a esta área suele ser el valor medio de un conjunto de medidas distribuidas aleatoriamente o de forma bien definida, ver figura I.10. En el contexto de diferentes proyectos de validación como VALERI o MODLAND, las dimensiones de la ESU suelen corresponder al tamaño del píxel de la imagen de alta resolución que se utiliza simultánea a la adquisición de medidas (Baret et al 2005a, Chen & Black 2002, Tian et al 2002a). Por ejemplo, Chen et al (1997) proponen un muestreo en forma de cruz con la cámara hemisférica cada 10 metros a lo largo de dos transectos de 40 metros (Whitford et al 1995, Rich et al 1993, Wang & Miller 1987), Neumann et al (1989) distribuyen aleatoriamente nueve medidas dentro de un área de 15×15 m<sup>2</sup>, mientras que Baret et al (2003) proponen caracterizar un área de aproximadamente 20×20 m<sup>2</sup> mediante la adquisición de 12 medidas distribuidas en forma de cruz o dentro del cuadrado delimitado por el área (figura I.10 a-c).



**Figura I.10.** Diferentes diseños de distribución de medidas dentro de una ESU propuestos en VALERI (Baret et al 2003).

Por otra parte, las zonas de muestreo, así como el número necesario y su distribución, deben de elegirse dependiendo de la variabilidad mostrada por la zona de estudio y los tipos de cubierta que presenta. La elección de diferentes zonas de muestreo es necesaria cuando el área a validar presenta grandes dimensiones (e.g. 50×50 km<sup>2</sup>) con diferentes tipos de cubierta y, por tanto, no es realista muestrear toda la zona (Chen et al 2002).

Posteriormente, dentro de cada zona de muestreo se distribuyen las ESUs. Aunque la elección de un diseño de muestreo u otro resulta crítico para obtener esa mejor representación de la cubierta, existe muy poca literatura que aborde este tema. Los tipos de muestreo que se encuentran en la literatura dependen mayormente del instrumento utilizado, la arquitectura de la cubierta y las características del área de estudio (Chen 1996). Los muestreos que más se han utilizado se detallan a continuación:

1. *Muestreo aleatorio*. Se trata del más simple de implementar aunque es el que presenta la mayor variancia respecto a otros métodos (Müller & Zimmerman 1999, Bogaert & Russo 1999).
2. *Muestreo estratificado*. Este muestreo consiste en redefinir el área a partir de estratos, los cuales pueden ser zonas que presentan la misma población, o el mismo tipo de suelo o cubierta vegetal (Fassnacht et al 1997). La ventaja de estratificar se traduce en una mayor eficiencia, dado que es posible obtener la misma variancia que, por ejemplo, el muestreo aleatorio pero con menor número de medidas. Sin embargo, una estratificación inadecuada puede dar lugar a una ineficiencia del muestreo.
3. *Muestreo sistemático*. Todos los patrones sistemáticos producen una malla regular de muestras aunque la estructura de la malla puede variar (Law et al 2001, Nackaerts et al 2000). La ventaja de este patrón es la dispersión uniforme de las muestras sobre toda la población. Sin embargo, la principal desventaja es que no se considera la población de cada una de las clases, de modo que algunas de ellas puede no estar representada correctamente por el conjunto de muestras elegidas.
4. *Muestreo por transectos*. Este diseño implica realizar recorridos en una dirección (Iachan 1982). Se pueden encontrar trabajos donde se han llevado a cabo transectos a partir de 50 metros hasta algunos cientos de metros con el TRAC, el LICOR LAI2000 y la cámara hemisférica (Leblanc et al 2002, Chen 1996, Lang et al 1991, Welles 1990). Parece ser un muestreo adecuado cuando se trata de caracterizar vegetación natural (Tian et al 2002a), a diferencia de los cultivos.

Sin embargo, estos diseños no consideran la correlación espacial que presentan la mayoría de los ecosistemas (Aubry & Debouzie 2000, Legendre 1993, Dutilleul 1993), siendo en ocasiones ineficientes. Un muestreo alternativo consiste en utilizar las técnicas anteriores junto con técnicas geoestadísticas (e.g. variogramas o correlogramas) para incluir la dependencia espacial. Este estudio se realiza en ocasiones a partir del parámetro NDVI (Burrows et al 2002).

## I.6 Caracterización de parámetros biofísicos a alta resolución

En este apartado se plantea el problema de extender espacialmente las medidas *in-situ* para derivar un mapa a alta resolución, simultáneo a los productos derivados mediante teledetección, para utilizarlo como verdad-terreno en la validación de dichos productos. El principal problema de la caracterización de parámetros biofísicos viene dado por, (i) la heterogeneidad espacial de la variable de interés en el área de estudio y (ii) la no linealidad de los algoritmos utilizados para escalar la información (Chen 1999, Friedl 1997).

Un fenómeno se dice que es heterogéneo cuando una o más variables que la representan varían en el espacio (Dutilleul 1993, Kolasa & Rollo 1991). La heterogeneidad ha sido objeto de estudio en diferentes disciplinas como la ecología (e.g. distribución espacial de una población animal), ciencias medioambientales (e.g. distribución de diferentes suelos), geografía (e.g. distribución de la población), etc.

En el contexto de la teledetección, este comportamiento de la variable de interés depende del instrumento de observación que se utilice para estudiarla (Garrigues 2004). Existen varias técnicas para describir este fenómeno (e.g. textura, entropía, variograma, etc), siendo la varianza una de las más sencillas, la cual disminuye a medida que la resolución espacial también lo hace (Woodcock & Strahler 1987). Los programas internacionales en validación directa (e.g. LPV) plantean una metodología estándar basada en la caracterización de la variabilidad espacial del parámetro de estudio a alta resolución (e.g. 20-30 m) aunque los productos a validar tengan una resolución espacial de 1 km (e.g. MODIS, VEGETATION).

### I.6.1 Revisión de modelos para la estimación de variables biofísicas

El problema de la caracterización espacial se resuelve aplicando un modelo adecuado que sea capaz de representar la variabilidad del parámetro medido en el área de estudio. Para ello distinguimos dos grupos según se disponga de información *in-situ* de la variable de interés o sólo derivada mediante teledetección.

En el caso de disponer de medidas *in-situ*, existe un uso extendido de los métodos estadísticos, los cuales consisten principalmente en relaciones semi-empíricas entre los parámetros biofísicos y las bandas espectrales o índices de vegetación (IV), siendo la regresión simple la técnica más utilizada (Baret et al 2005a, Wang et al 2004, Colombo et al 2003, Cohen et al 2003b, Chen et al 2002). Sin embargo, esta técnica se considera como no espacial, en tanto que no tiene en cuenta la dependencia espacial entre los datos y no incluye información de las observaciones próximas en la posición a estimar (Hudak et al 2002).

De forma alternativa a esta técnica, destacan las técnicas geoestadísticas, las cuales consideran la dependencia espacial de las observaciones en sus estimaciones y, por

tanto, la heterogeneidad de la variable de interés. Estas técnicas, por definición, no se incluyen dentro de la categoría de modelos derivados en teledetección ya que no necesitan de un soporte obtenido mediante teledetección para ser aplicado. Sin embargo, dentro de la geoestadística se han ido desarrollando modelos que incluyen la información derivada mediante satélite para mejorar las estimaciones (e.g. cokrigado colocalizado o *collocated cokriging*). Actualmente, existe un amplio uso de la geoestadística junto con la teledetección como es el caso de la hidrológica (Goovaerts 2000, Kitanidis 1997), estimación de campos de precipitación (Kyriakidis 2004, Prudhomme 1999, Cassiraga & Gómez-Hernández 1997) o de parámetros biofísicos (Berterretche et al 2005, Atkinson et al 1996, Burrows et al 2002, Wylie et al 2002). Ambas técnicas, se combinan normalmente con información derivada mediante teledetección para realizar las estimaciones.

En el caso de disponer sólo de imágenes de satélite se utilizan la inversión de modelos físicos de la cubierta vegetal, como los modelos de transferencia radiativa (e.g. modelos turbios) o los modelos lineales (e.g. análisis de mezclas espectrales, modelos óptico-geométricos), (Gobron et al 2000a, Li & Strahler 1995). Un aspecto esencial de la estimación de parámetros es la elección de una técnica de inversión adecuada, ya que puede afectar seriamente la eficiencia computacional y los resultados del cálculo. Aunque tradicionalmente se han empleado técnicas de optimización, cada vez más se prefiere el uso de redes neuronales y tablas de interpolación (e.g. LUT), ya que ofrecen una mayor robustez y eficiencia computacional. La incorporación de información *a priori* en el proceso de inversión es un aspecto innovador a la vez que necesario, como así demuestran varios estudios (e.g. Combal et al 2002). De lo contrario, la precisión con que se estiman los parámetros puede quedar comprometida cuando el muestreo de observaciones es escaso, los datos presentan errores apreciables o el parámetro a estimar (e.g. LAI) es poco sensible a variaciones de la reflectividad (García-Haro et al 2003).

Cada aproximación comentada tiene sus ventajas e inconvenientes. Los métodos semiempíricos resultan en diferentes expresiones matemáticas con coeficientes empíricos que dependen, principalmente, del tipo de cubierta (Zhang et al 2000) y geometría de adquisición (Turner et al 1999, Chen et al 1997), de modo que son difícilmente extrapolables a otras situaciones. Sin embargo, se presentan como un método robusto y operativo, actualmente en uso, en cuanto a que permiten realizar un seguimiento del estado de la cubierta vegetal, y por tanto analizar los cambios o tendencias que en ésta se puedan producir. Algunos autores encuentran geometrías óptimas para estimar parámetros minimizando los posibles factores externos (Roujean & Bréon 1995). Por ejemplo, en Roujean & Lacaze (2002) se estiman mapas globales de LAI y FVC a partir del índice DVI para la geometría óptima de observación en el nadir e iluminación en el cenit. Otros autores utilizan modelos de BRDF para la optimización de los índices de vegetación (i.e. minimizar la diferencia entre el valor del índice y la variable de interés) (Gobron et al 2000b, Goovaerts et al 1999, Verstrate & Pinty 1996).

Por su parte, la geoestadística incluye diferentes técnicas con gran aplicación en la interpolación o extensión espacial de medidas *in-situ*. Una de las técnicas de interpolación más utilizadas en geoestadística son los métodos basados en la técnica del krigeado o *kriging* (i.e. krigeado simple, krigeado con derivada externa, cokrigeado colocalizado, etc.). Las técnicas basadas en el krigeado proporcionan el mejor estimador lineal insesgado, en el sentido que el sistema de ecuaciones que tiene que ser resuelto para determinar los coeficientes se obtiene imponiendo la condición de que el promedio de los datos estimados sea igual al promedio de los datos muestreados, y que el promedio del cuadrado de la diferencia de las estimaciones y los valores reales sea mínima (Carroll & Cressie 1996, Matheron 1971). Sin embargo, aunque se han desarrollado modelos que incluyen información derivada mediante teledetección como apoyo en las estimaciones, la geoestadística es una técnica que necesita de información *in-situ* para aplicarla, lo cual no es siempre posible. Este requisito limita su aplicación a escala local y regional, como es el caso de estimación de parámetros biofísicos en un área de 3×3 km<sup>2</sup> (Baret et al 2003) o estimación de campos de precipitación a escala regional dado el fácil acceso de la información obtenido de las estaciones meteorológicas distribuidas por el área de interés (Goovaerts 2000).

En cuanto a la inversión de modelos físicos de la cubierta vegetal, los modelos lineales, aunque muy generales y eficientes, ignoran parámetros de la cubierta, como el LAI. Además, se muestran insensibles a las inhomogeneidades de la superficie, por lo que están limitados por la presencia de píxeles mezcla, que son habituales en datos de baja resolución. Por otra parte, los modelos 3-D son potencialmente muy precisos pero su complejidad inherente los hace en ocasiones intratables sobre zonas extensas. Estos métodos incorporan un gran número de parámetros de la superficie, lo que limita su aplicabilidad sobre zonas extensas.

En este trabajo se han elegido las técnicas estadísticas frente a los modelos de inversión por su fácil aplicación y su uso extendido en diferentes aplicaciones. Dentro del grupo de las estadísticas, tres son los métodos de interpolación a partir de medidas *in-situ* que más se utilizan (Chen et al 2002, Atkinson et al 1996), (i) estimación por krigeado, (ii) estimación por cokrigeado utilizando información adicional derivada de teledetección, y (iii) estimación por regresión de mínimos cuadrados (*Ordinary Least Square*, OLS) junto con imágenes de alta resolución. En este estudio se ha ensayado la caracterización a alta resolución a partir de medidas *in-situ* con la técnica OLS multivariada y tres modelos geostatísticos derivados del krigeado. El método geostatístico presenta las siguientes ventajas respecto a los estimadores lineales no espaciales:

1. Los métodos OLS no consideran la dependencia espacial de la variable a estimar, ignorando la información que se localiza cerca de la posición a estimar.
2. La estimación se acompaña de una cuantificación de la incertidumbre asociada al método, es decir la varianza del krigeado.

3. Es posible utilizar el modelo para determinar el muestreo espacial óptimo para caracterizar lo mejor posible la variabilidad mostrada por la variable medida.
4. Es posible utilizar información auxiliar, como imágenes de alta resolución, para estimar la variable de interés (e.g. krigado con deriva externa).

## I.6.2 Técnica de regresión multivariada

El método OLS multivariado responde a la siguiente expresión:

$$Y = \beta_0 + \sum_{i=1}^n \beta_i(X_i) + \varepsilon \quad \text{[I.4]}$$

donde  $Y$  es la variable observada (i.e. variable dependiente);  $X_i$  las variables independientes consideradas;  $\beta_0$  representa el valor medio de  $Y$  cuando  $X$  es igual a cero, también conocida como ordenada en el origen;  $\beta_i$  corresponde a la pendiente asociada a cada variable independiente considerada e indica el cambio que experimenta la variable  $Y$  respecto a la variable  $X_i$ ;  $\varepsilon$  corresponde al error aleatorio asociado a cada observación del conjunto  $Y$ . El vector  $\varepsilon$  mide la diferencia entre el valor observado de  $Y$  y el predicho por la regresión, de modo que cumpla la condición de distribución normal (i.e. valor esperado igual a cero y varianza igual a la del vector  $X$ ). Este término de error es una variable de diagnóstico para comprobar si el modelo utilizado es válido (Quinn & Keough 2002). En Kleinbaum et al (1998) se puede encontrar una discusión más detallada sobre los métodos OLS. Los coeficientes del modelo se determinan de modo que la regresión obtenida minimice la suma de los errores cuadráticos (Curran & Hay 1986), es decir disminuye la varianza de las estimaciones (Hudak et al 2002, Cohen et al 2001).

Un parámetro importante para la evaluación del método es el error cuadrático medio (RMSE) y el error de validación cruzada (RC). El RMSE proporciona una herramienta para analizar la dispersión de los valores estimados respecto a los observados (i.e. medidos *in-situ*), es decir el error medio que se comete en la estimación. Sin embargo, este error sólo evalúa la función con los datos *in-situ*, de modo que para valorar la función en otras localizaciones donde no se ha medido se deben utilizar otras herramientas. En algunos casos, se utiliza una fracción de los puntos para obtener el modelo de regresión y otra fracción para validar el modelo. Sin embargo, en la mayoría de ocasiones el conjunto de datos no presenta un número de observaciones suficientes como para prescindir de una parte de ellos. En este caso, una alternativa consiste en la validación cruzada o cálculo del RC a partir del método *leaving-one-out* (Cohen et al 2003b, Efron & Gong 1983). Este método obtiene tantos modelos de regresión como observaciones presenta el conjunto de datos, pero en cada caso elimina un dato del conjunto de  $n$  valores y predice su valor a partir del modelo ajustado a las  $n-1$  observaciones restantes. El RC se obtiene como la media de las diferencias al cuadrado entre el valor

observado y el predicho, de modo que cuanto más se aproxime el valor estimado al observado menor será el RC y por tanto, mejor será el modelo considerado.

### I.6.3 Técnicas geoestadísticas

La geoestadística nació en la década de los 50 como una rama de la estadística aplicada a la minería, con el fin de evaluar las reservas útiles de minerales (Krige 1951, Sichel 1949, 1947). El término fue introducido por G. Matheron (Matheron 1962, 1963a, 1963b) quien la definió como la aplicación del formalismo de las funciones aleatorias para el reconocimiento y estimación de fenómenos naturales. Se trata de una ciencia aplicada que se basa en describir cuantitativamente variables naturales distribuidas en el espacio, partiendo de una muestra representativa del fenómeno a estudiar. La geoestadística exige, como primera etapa fundamental, el conocimiento del comportamiento estructural de la información o, lo que es lo mismo, el modelado del patrón espacial en base a las medidas.

En geoestadística se usa el modelo de función aleatoria (FA) para describir los fenómenos naturales (Goovaerts 1997, Matheron 1962). El modelo de FA es una herramienta apropiada para modelar la variabilidad espacial del fenómeno bajo estudio, donde la FA especifica cuál es el rango de valores que la variable puede tomar en cualquier punto y el grado de correlación que este valor tiene con los datos cercanos. La variable bajo estudio se considera regionalizada la cual es sólo una realización en el espacio o en el tiempo de un conjunto infinito de posibles realizaciones de la FA (Woodcock & Strahler 1988a, 1988b).

Sea  $Z(\mathbf{u})$  la función aleatoria que representa el parámetro bajo estudio, donde  $\mathbf{u}$  es el vector de coordenadas espaciales. El problema consiste en representar la variabilidad de la función  $Z(\mathbf{u})$  en el espacio. Esta representación será utilizada para resolver problemas como la estimación del valor  $z(\mathbf{u}_0)$  en el punto  $\mathbf{u}_0$  donde no disponemos de información, o la estimación de la proporción de valores de  $Z(\mathbf{u})$  que se encuentran por encima o por debajo de un umbral dado  $z_k$ .

Los pasos para desarrollar un estudio geostadístico genérico son:

1. Descripción de la información.
2. Análisis de la continuidad espacial.
3. Predicción.
4. Evaluación de la incertidumbre.

### I.6.3.1 Análisis de la continuidad espacial

El objetivo del análisis de la continuidad espacial consiste en describir y cuantificar la relación entre observaciones de la misma o diferentes variables en diferentes posiciones. La descripción espacial se realiza a través de expresiones que cuantifican la relación entre una o diferentes variables en función de la distancia de separación entre ellas, como son el variograma, la función de covarianza y el correlograma. Sea  $Z_i(\mathbf{u}_\alpha)$ ,  $\alpha=1,\dots,n$  un conjunto de  $n$  observaciones de una determinada variable, la tabla I.1 muestra las funciones más utilizadas para cuantificar la continuidad espacial de un conjunto de datos.

**Tabla I.1.** Diferentes herramientas utilizadas para caracterizar la dependencia espacial de los datos.

| Función               | Expresión matemática  |       |
|-----------------------|---|-------|
| Variograma            | $\gamma(\mathbf{h}) = \frac{1}{2N(\mathbf{h})} \sum_{\alpha=1}^{N(\mathbf{h})} [z_i(\mathbf{u}_\alpha) - z_i(\mathbf{u}_\alpha + \mathbf{h})]^2$  | [I.5] |
| Función de Covarianza | $C(\mathbf{h}) = \frac{1}{N(\mathbf{h})} \sum_{\alpha=1}^{N(\mathbf{h})} z_i(\mathbf{u}_\alpha) \cdot z_i(\mathbf{u}_\alpha + \mathbf{h}) - m_{-\mathbf{h}} m_{+\mathbf{h}}$<br>$m_{-\mathbf{h}} = \frac{1}{N(\mathbf{h})} \sum_{\alpha=1}^{N(\mathbf{h})} z_i(\mathbf{u}_\alpha); m_{+\mathbf{h}} = \frac{1}{N(\mathbf{h})} \sum_{\alpha=1}^{N(\mathbf{h})} z_i(\mathbf{u}_\alpha + \mathbf{h})$ | [I.6] |
| Correlograma          | $\rho(\mathbf{h}) = \frac{C(\mathbf{h})}{\sigma_{-\mathbf{h}} \sigma_{+\mathbf{h}}}; \sigma_{-\mathbf{h}}^2 = \frac{1}{N(\mathbf{h})} \sum_{\alpha=1}^{N(\mathbf{h})} z_i(\mathbf{u}_\alpha)^2 - m_{-\mathbf{h}}^2$<br>$\sigma_{+\mathbf{h}}^2 = \frac{1}{N(\mathbf{h})} \sum_{\alpha=1}^{N(\mathbf{h})} z_i(\mathbf{u}_\alpha + \mathbf{h})^2 - m_{+\mathbf{h}}^2$                               | [I.7] |

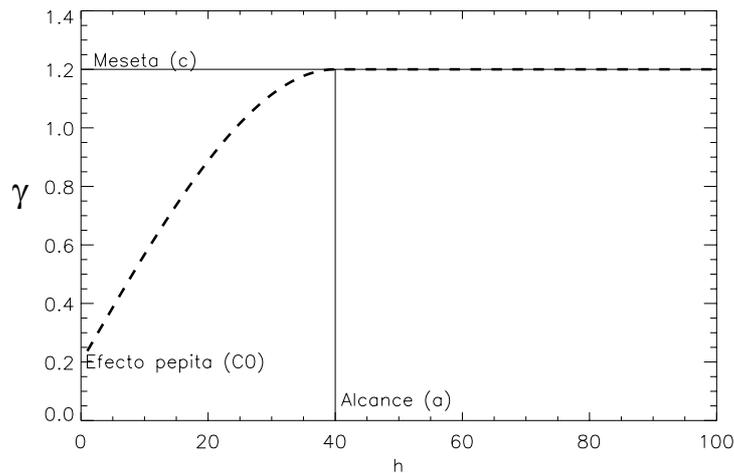
Entre las funciones descritas en la tabla anterior, el variograma y la covarianza son las más utilizadas. En general, el variograma es una función monótona no decreciente en función de la distancia de separación  $\mathbf{h}$ . El variograma presenta valores bajos a distancias pequeñas, aumentando su valor a medida que la separación entre los datos se hace mayor y se caracteriza por mostrar valor nulo en el origen por definición y valores positivos para  $\mathbf{h}>0$  (Wackernagel 1995). Por otra parte, la covarianza puede tomar valores negativos y se relaciona con el variograma mediante la expresión,

$$\gamma(\mathbf{h}) = C(0) - C(\mathbf{h}) \quad \text{[I.8]}$$

donde  $C(0)$  corresponde a la varianza ( $\sigma^2$ ) del conjunto de datos cuando el modelo de FA es estacionario de segundo orden (Goovaerts 1997).

El variograma viene descrito por tres parámetros, el alcance ( $a$ ), la meseta ( $c$ ) y el efecto pepita ( $c_0$ ), ver figura I.11. El alcance corresponde a la distancia de

separación que coincide con la varianza de la variable de estudio o meseta y marca la zona de influencia en torno a un punto, a partir del cual no existe correlación entre los datos en esa dirección (Woodcock & Strahler 1988a, 1988b). Por último, aunque el variograma presenta valor nulo para la distancia de separación cero, con frecuencia el variograma es discontinuo en el origen, con un salto finito que se conoce como efecto pepita. Este efecto puede explicar errores debidos al proceso de medida de la variable y también variaciones sobre distancias mucho más pequeñas que los intervalos de muestreo utilizados (Burgess & Webster 1980).



**Figura I.11.** Ejemplo de la forma típica que presenta el variograma junto con sus parámetros característicos, el alcance (a), la meseta (c) y el efecto pepita ( $c_0$ )

Además de la utilidad de los variogramas en las variantes del krigeadado (Gohin & Langlois 1993, Atkinson et al 1992, Bhatti et al 1991, Dancy et al 1986) y, más recientemente, técnicas de simulación (Dungan et al 1994, Atkinson 1993a), los variogramas se presentan como una herramienta muy útil en la teledetección. Muestra de ello, son los diferentes trabajos encontrados en la literatura dirigidos a diseñar el muestreo espacial más apropiado de diferentes propiedades relacionadas con el suelo o vegetación (Atkinson 1991, Webster & Oliver 1989), la combinación de medidas *in-situ* con datos procedentes de imágenes de satélite a partir del cokrigeadado (Atkinson et al 1992) o incluso la evaluación del efecto de la resolución espacial (Atkinson & Curran 1995, Atkinson 1993b, Jupp et al 1988, 1989).

### Cálculo del variograma experimental

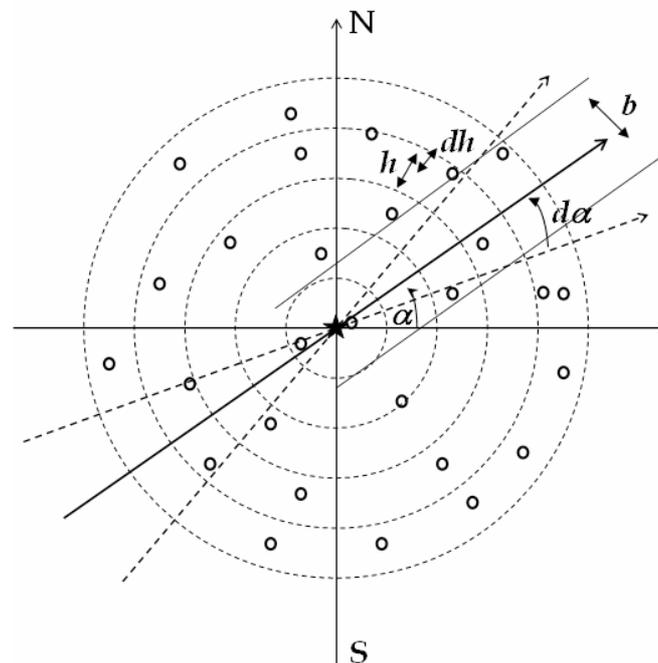
Los pasos a seguir para la modelización del patrón de continuidad espacial son los siguientes:

1. *Cálculo del variograma experimental omnidireccional.* El variograma omnidireccional no se centra en una dirección particular sino que incluye todas las combinaciones de direcciones posibles. Es una herramienta que

permite tener una idea inicial acerca de los parámetros alcance, meseta y efecto pepita.

2. *Cálculo de los variogramas experimentales direccionales.* Una vez calculado el variograma omnidireccional, conviene explorar los variogramas direccionales para analizar la existencia de anisotropía si la hubiera. El análisis debe proporcionar las direcciones de continuidad máxima y mínima.
3. *Ajuste de un modelo al variograma experimental.* El siguiente paso al estudio de anisotropía consiste en obtener un modelo teórico que combine las estructuras presentadas por los variogramas con alcance mínimo y máximo. Esta función permite predecir el valor del variograma para cualquier distancia de separación y dirección (Isaacs & Srivastava 1986).

El cálculo del variograma experimental viene determinado por la elección de los siguientes parámetros (figura I.12), (i) distancia de separación mínima a partir de la cual comenzar el cálculo ( $h$ ), (ii) tolerancia asociada a dicha distancia ( $dh$ ), (iii) dirección fija ( $\alpha$ ) (en el caso de calcular variogramas direccionales), (iv) tolerancia asignada a dicha dirección ( $d\alpha$ ) y (v) ancho de banda ( $b$ ).



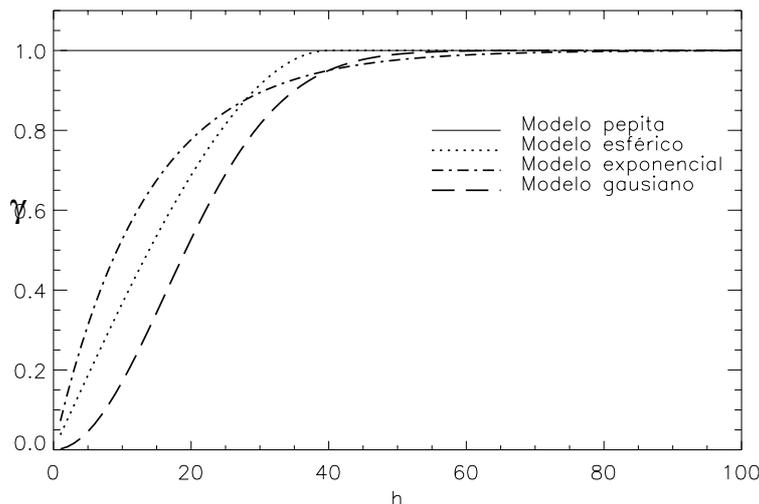
**Figura I.12.** Descripción gráfica de los parámetros necesarios para calcular el variograma a partir de un conjunto de datos distribuidos irregularmente.

En el caso de que se disponga de un conjunto de datos distribuido irregularmente en el espacio, la distancia  $h$  se selecciona como la distancia media entre datos y se calcula el variograma, por ejemplo, para distancias que vayan desde cero hasta la

mitad de la distancia máxima de separación entre las parejas de puntos. La tolerancia asociada a  $h$  se elige normalmente como la mitad del incremento de separación, de modo que cuanto mayor sea la tolerancia, mayor será el número de parejas de observaciones que se incluyan en el cálculo, proporcionando, de esta manera, un aspecto más suavizado al variograma experimental. Una vez definida la distancia de separación, se toman todas las parejas de observaciones que están separadas esta distancia y se calcula el variograma a partir de la expresión I.5 para la distancia  $h$ . A continuación, se repite el mismo cálculo para distancias de separación mayores.

El paso siguiente al cálculo del variograma experimental consiste en ajustar un modelo a los datos. Dicho modelo corresponde a una función matemática expresada en función de la distancia de separación, la meseta, el alcance y el efecto pepita, la cual debe cumplir ciertas condiciones que garanticen la existencia de una solución única y estable de los sistemas de ecuaciones lineales generados a la hora de aplicar alguna técnica de interpolación o simulación geoestadística. La figura I.13 muestra los modelos básicos que se utilizan para modelar el comportamiento del variograma.

El paso siguiente a la obtención del modelo espacial de la variable de interés, puede consistir en estimar dicha variable en localizaciones donde no se ha medido. A continuación se describe la base teórica de las técnicas geoestadísticas más utilizadas y en concreto las variantes del kriging propuestas en esta memoria, el kriging ordinario (KO), el kriging con derivada externa (KDE) y el cokriging colocalizado (CKC).



**Figura I.13.** Descripción gráfica del comportamiento de los modelos más utilizados, modelo pepita, esférico, exponencial y gaussiano.

### I.6.2.2 Estimación por krigado

Krigado (Goovaerts 1997, Isaacs & Srivastava 1989, Journel & Huijbregts 1978), es un nombre genérico que, en honor a Danie Krige, fue dado a un conjunto de técnicas de interpolación pertenecientes al grupo de algoritmos de regresión por mínimos cuadrados generalizados. La idea básica del krigado es estimar el valor desconocido de un atributo  $z$  en el punto de coordenadas  $\mathbf{u}_0$  como una combinación lineal de  $n$  valores conocidos de  $z$ , cuyas coordenadas son  $\mathbf{u}_\alpha$ , con  $\alpha=1, \dots, n$ . Para representar el parámetro de interés  $z(\mathbf{u})$  adoptamos un modelo estocástico. Este modelo estocástico consiste en admitir que los valores que puede tomar  $z$  dentro del área de estudio vienen dado por una FA.

La forma general del estimador por krigado viene expresada a través de la fórmula siguiente:

$$z^*(\mathbf{u}) - m(\mathbf{u}_0) = \sum_{\alpha=1}^n \lambda_\alpha [z(\mathbf{u}_\alpha) - m(\mathbf{u}_\alpha)] \quad \text{[I.9]}$$

donde el símbolo \* denota que se trata de un valor estimador;  $m(\mathbf{u}_0)$  y  $m(\mathbf{u}_\alpha)$  son los valores esperados de las variables aleatorias  $Z(\mathbf{u}_0)$  y  $Z(\mathbf{u}_\alpha)$  respectivamente, y  $\lambda_\alpha$ ,  $\alpha=1, \dots, n$  son los coeficientes de ponderación asignados a los datos de la variable que intervienen en la estimación.

La representación estocástica del atributo  $z(\mathbf{u})$ , permite definir el error en la estimación realizada como:

$$R(\mathbf{u}_0) = Z^*(\mathbf{u}_0) - Z(\mathbf{u}_0) \quad \text{[I.10]}$$

donde  $R(\mathbf{u}_0)$  es el error cometido en la estimación del atributo  $z$  en la localización  $\mathbf{u}_0$ ; y  $Z^*(\mathbf{u}_0)$  y  $Z(\mathbf{u}_0)$  son el valor estimado y el valor verdadero respectivamente. El valor estimado por krigado es por construcción aquel que minimiza la varianza del error de la estimación y es, además, un estimador insesgado (ver anexo B). Es decir, para el punto de coordenadas  $\mathbf{u}_0$  el objetivo del krigado es:

$$\min \sigma_R^2(\mathbf{u}_0) = \text{Var}\{Z^*(\mathbf{u}_0) - Z(\mathbf{u}_0)\} \quad \text{[I.11]}$$

bajo la restricción

$$E\{Z^*(\mathbf{u}_0) - Z(\mathbf{u}_0)\} = 0 \quad \text{[I.12]}$$

Todos los estimadores por krigado son una variante de la expresión general [I.9], en la cual los coeficientes de ponderación  $\lambda_\alpha$  se obtienen resolviendo el sistema de ecuaciones lineales que surgen de las condiciones [I.11] y [I.12]. El resto de estimadores pertenecientes a la familia del krigado dependen del modelo considerado para la función aleatoria  $Z(\mathbf{u}_\alpha)$ . La FA se descompone normalmente en términos de una función que define la tendencia de la variable,  $m(\mathbf{u}_\alpha)$  y el residuo asociado,  $R(\mathbf{u}_\alpha)$ :

$$Z_i(\mathbf{u}) = R_i(\mathbf{u}) + m_i(\mathbf{u}) \quad i = 1, \dots, N_v \quad \text{[I.13]}$$

El término residual se modela como una función aleatoria cuyo valor esperado es igual a cero, mientras que el valor esperado de la función aleatoria  $Z(\mathbf{u})$  se considera como la componente que hace referencia a la tendencia en función de la posición,  $E\{Z(\mathbf{u})\}=m(\mathbf{u})$ . A continuación describiremos brevemente las principales variantes del krigado.

### Krigado simple (KS)

El estimador por krigado simple (KS) tiene la expresión siguiente:

$$z_{\text{KS}}^*(\mathbf{u}_0) - m = \sum_{\alpha=1}^n \lambda_{\alpha} [Z(\mathbf{u}_{\alpha}) - m] \quad \text{[I.14]}$$

donde  $m$ , que es igual al valor esperado de la variable aleatoria  $Z$ , se considera conocida y constante en todo el dominio de la estimación, y en la práctica se identifica con el valor medio de los datos. Como hemos dicho, los coeficientes de ponderación  $\lambda_{\alpha}$  vienen determinados al exigir que el estimador sea insesgado y que la varianza de los errores sea mínima, lo cual conduce al siguiente sistema lineal de ecuaciones, llamado sistema de krigado simple:

$$\sum_{\beta=1}^n \lambda_{\beta} C(\mathbf{u}_{\alpha} - \mathbf{u}_{\beta}) = C(\mathbf{u}_{\alpha} - \mathbf{u}_0), \alpha = 1, \dots, n \quad \text{[I.15]}$$

donde  $C(\mathbf{h})$  es la covarianza para el vector de separación  $\mathbf{h}$ . En este sistema, a la izquierda de la igualdad están las covarianzas entre los datos y a la derecha entre los datos y el punto a estimar. La varianza de los errores por krigado simple resulta:

$$\sigma_{\text{KS}}^2(\mathbf{u}_0) = \sigma^2 - \sum_{\alpha=1}^n \lambda_{\alpha} C(\mathbf{u}_{\alpha} - \mathbf{u}_0) \quad \text{[I.16]}$$

donde  $\sigma^2$  es la varianza correspondiente a los datos, es decir  $C(0)$ . El mapa de los valores  $\sigma_{\text{KS}}^2$  permite cuantificar la incertidumbre en el campo estimado.

### Krigado ordinario (KO)

En el krigado ordinario (KO) la media es desconocida y se reestima localmente a partir de los datos que intervienen en cada estimación. El estimador por krigado ordinario viene dado por la siguiente expresión:

$$z_{\text{KO}}^*(\mathbf{u}_0) = \sum_{\alpha=1}^n \lambda_{\alpha} z(\mathbf{u}_{\alpha}) \quad \text{[I.17]}$$

El sumatorio de los pesos debe ser igual a la unidad para que el estimador obtenido sea insesgado, que junto con la condición de error mínimo resulta en el sistema de krigado ordinario:

$$\begin{cases} \sum_{\beta=1}^n \lambda_{\beta} C(\mathbf{u}_{\alpha} - \mathbf{u}_{\beta}) + \mu = C(\mathbf{u}_{\alpha} - \mathbf{u}_0), & \alpha = 1, \dots, n \\ \sum_{\beta=1}^n \lambda_{\beta} = 1 \end{cases} \quad [\text{I.18}]$$

donde  $\mu$  es el parámetro de Lagrange introducido en la minimización del error sujeto a la condición de que los pesos sumen uno. La expresión para la varianza de los errores por krigado ordinario es la siguiente:

$$\sigma_{\text{KO}}^2(\mathbf{u}_0) = \sigma^2 - \sum_{\alpha=1}^n \lambda_{\alpha} C(\mathbf{u}_{\alpha} - \mathbf{u}_0) - \mu \quad [\text{I.19}]$$

### Krigado universal (KU)

El krigado universal (KU), o mejor dicho el krigado con un modelo de tendencia, considera que la variación espacial de la media local tiene una forma dada por un polinomio de orden bajo en función de las coordenadas, pero de parámetros desconocidos. En general esta tendencia tiene la forma siguiente:

$$m(\mathbf{u}) = \sum_{l=0}^L a_l f_l(\mathbf{u}) \quad [\text{I.20}]$$

donde  $m(\mathbf{u})$  es la media en el punto de coordenadas  $\mathbf{u}$ ;  $a_l$ , con  $l=0, \dots, L$  son coeficientes desconocidos, y  $f_l(\mathbf{u})$  son monomios de orden bajo en función de las coordenadas.

El estimador por krigado universal tiene la forma siguiente:

$$z_{\text{KU}}^*(\mathbf{u}_0) = \sum_{\alpha=1}^n \lambda_{\alpha} z(\mathbf{u}_{\alpha}) \quad [\text{I.21}]$$

La condición de no sesgo resulta en  $L$  restricciones que deben satisfacer los pesos  $\lambda_{\alpha}$  que unidas a la minimización del error resulta en el sistema de krigado universal, cuyas expresiones son las siguientes:

$$\begin{cases} \sum_{\beta=1}^n \lambda_{\beta} C(\mathbf{u}_{\alpha} - \mathbf{u}_{\beta}) + \sum_{l=0}^L \mu_l f_l(\mathbf{u}_{\alpha}) = C(\mathbf{u}_{\alpha} - \mathbf{u}_0) & \alpha = 1, \dots, n \\ \sum_{\beta=1}^n \lambda_{\beta} f_l(\mathbf{u}_{\beta}) = f_l(\mathbf{u}_0), & l = 1, \dots, L \end{cases} \quad [\text{I.22}]$$

La varianza de los errores por krigado universal viene dada por la siguiente expresión:

$$\sigma_{\text{KU}}^2(\mathbf{u}_0) = \sigma^2 - \sum_{\alpha=1}^n \lambda_{\alpha} C(\mathbf{u}_{\alpha} - \mathbf{u}_0) - \sum_{l=0}^L \mu_l f_l(\mathbf{u}_{\alpha}), \quad \alpha = 1, \dots, n \quad [\text{I.23}]$$

### Krigado con deriva externa (KDE)

El krigado con una deriva externa (KDE) es una extensión del krigado universal. Consiste en considerar una función de tendencia  $f_1(\mathbf{u})$ , definida en cada localización a partir de una variable secundaria  $z_2(\mathbf{u})$ . Al igual que el KU, el estimador KDE permite determinar la tendencia de variación debida a cualquier componente estructural. A diferencia del modelo KU, en este caso es necesario disponer de un valor de la variable secundaria en cada punto a estimar. En general, se considera a la variable secundaria  $z_2(\mathbf{u})$  relacionada de forma lineal con la media de la variable primaria  $m_1(\mathbf{u})$ , tal que:

$$m_1(\mathbf{u}) = a_0 + a_1 z_2(\mathbf{u}) \quad [\text{I.24}]$$

Este modelo presenta la ventaja respecto al estimador KU en que los coeficientes de del modelo de tendencia se recalculan en cada estimación de la variable primaria  $z_1(\mathbf{u})$ , proporcionando un mayor detalle de dicha variable a escala local. El estimador por krigado con deriva externa tiene la siguiente expresión:

$$z_{\text{KDE}}^*(\mathbf{u}_0) = \sum_{\alpha=1}^n \lambda_{\alpha} z_1(\mathbf{u}_{\alpha}) \quad [\text{I.25}]$$

donde  $n_1$ , es el número de datos correspondientes a la variable primaria  $z_1(\mathbf{u})$  que intervienen en cada estimación. Los coeficientes en este estimador surgen de resolver el sistema siguiente:

$$\begin{cases} \sum_{\beta=1}^{n_1} \lambda_{\beta} C_1(\mathbf{u}_{\alpha} - \mathbf{u}_{\beta}) + \mu_0 + \mu_1 z_2(\mathbf{u}_{\alpha}) = C_1(\mathbf{u}_{\alpha} - \mathbf{u}_0), & \alpha = 1, \dots, n \\ \sum_{\beta=1}^{n_1} \lambda_{\beta} = 1 \\ \sum_{\beta=1}^{n_1} \lambda_{\beta} z_2(\mathbf{u}_{\beta}) = z_2(\mathbf{u}_0) \end{cases} \quad [\text{I.26}]$$

Las dos últimas ecuaciones resultan de imponer la condición de no sesgo. La expresión para la estimación de la varianza de los errores por krigado con una deriva externa es la siguiente:

$$\sigma_{\text{KDE}}^2(\mathbf{u}_0) = \sigma^2 - \sum_{\alpha=1}^{n_1} \lambda_{\alpha} C_1(\mathbf{u}_{\alpha} - \mathbf{u}_0) - \mu_0 - \mu_1 z_2(\mathbf{u}_{\alpha}), \quad \alpha = 1, \dots, n \quad [\text{I.27}]$$

Las estimaciones de  $z_1$  son por construcción semejante al campo de la variable secundaria  $z_2$ . Sin embargo, este modelo no considera la correlación cruzada entre variables. La variable secundaria sólo informa acerca de la tendencia de la variable primaria.

### I.6.2.3 Estimación por cokrigado

El cokrigado (Goovaerts 1997, Isaacs & Srivastava, Myers 1982, 1991), no se diferencia del krigado desde un punto de vista algorítmico. Su novedad es que permite que los datos secundarios participen directamente en la estimación de la variable principal. Es decir que la información secundaria se trate como información covariada. Desde el punto de vista de la incorporación de atributos externos, el cokrigado hace mejor uso de la información en el sentido de que, tanto la magnitud de la variable secundaria, como sus patrones de variación espacial, son considerados en la estimación de la variable principal. La cantidad de codependencia lineal es capturada por las covarianzas cruzadas y, a diferencia del krigado con una deriva, la variable externa no necesita estar disponible en todos los puntos en los que se desea estimar la variable primaria. La forma general que toma el estimador por cokrigado para una variable  $z_1$  en una localización ( $\mathbf{u}_0$ ) es la siguiente:

$$z_1^*(\mathbf{u}_0) - m_1(\mathbf{u}_0) = \sum_{\alpha_1=1}^{n_1} \lambda_{\alpha_1} [z_1(\mathbf{u}_{\alpha_1}) - m_1(\mathbf{u}_{\alpha_1})] + \sum_{i=2}^{N_v} \sum_{\alpha_i=1}^{n_i} \lambda_{\alpha_i} [z_i(\mathbf{u}_{\alpha_i}) - m_i(\mathbf{u}_{\alpha_i})] \quad \text{[I.28]}$$

donde  $z_1(\mathbf{u}_{\alpha_1})$ ,  $\alpha_1=1, \dots, n_1$ , son los  $n_1$  datos principales;  $z_i(\mathbf{u}_{\alpha_i})$ ,  $\alpha_i=1, \dots, n_i$ ,  $i=2, \dots, N_v$ , son los datos secundarios correspondientes a  $(N_v-1)$  variables secundarias;  $m_1$  es la media de la variable principal;  $m_i$  son las medias de las variables secundarias y  $\lambda_{\alpha}$  los coeficientes de ponderación de los datos que intervienen en cada estimación. La localización y el número de los datos secundarios pueden ser diferentes de una a otra variable y con respecto a los datos principales. Por simplicidad en adelante consideramos sólo una variable secundaria a menos que se indique lo contrario. Al igual que para krigado, los coeficientes de ponderación en la ecuación [I.28], se obtienen resolviendo el sistema de ecuaciones lineales que surge de minimizar la varianza del error [I.11] en cada estimación sujeta a la restricción de estimador insesgado [I.12]. Al igual que para el krigado, existen diferentes variantes del cokrigado según el modelo considerado para la función aleatoria  $Z(\mathbf{u}_a)$ . En el anexo C se describen brevemente algunas de ellas.

La resolución de un sistema de cokrigado completo, requiere el conocimiento de las funciones de covarianza de las variables principal y secundaria y la de covarianza cruzada entre ellas si una sola variable es incorporada. Esto significa más esfuerzo en términos de modelización y tiempo computacional respecto a las técnicas de krigado, las cuales sólo requerirían la función de covarianza de la

variable principal. Muchas veces, este mayor esfuerzo de cálculo, constituye la principal razón por la cual el cokrigado no es utilizado.

Por otro lado, cuando la información secundaria está exhaustivamente muestreada, como es el caso de los datos sísmicos, existe una dificultad adicional a la hora de la implementación de un cokrigado completo, que se manifiesta a través de la inestabilidad de las matrices del sistema. Esto está causado por la extrema proximidad y fuerte autocorrelación que existe entre los datos más cercanos a la posición de estimación, y las grandes distancias y pobre correlación entre los más alejados.

Estas razones, más el hecho de que si hay un dato secundario colocalizado en la posición a ser estimada, éste tiende a atenuar la influencia de los datos vecinos (i.e. efecto pantalla), nos conduce a presentar la alternativa del cokrigado colocalizado.

#### I.6.2.4 Cokrigado colocalizado

El estimador general por cokrigado colocalizado (Almeida & Journel 1994, Deutsch & Journel 1998, Xu et al 1992) se trata de un modelo que retiene en cada posición  $\mathbf{u}_0$  donde se va a estimar la variable primaria, sólo el dato secundario localizado en este punto (i.e. dato colocalizado). El estimador por cokrigado colocalizado simple (CKCS) para la variable principal es idéntico al del cokrigado simple completo donde el número de datos secundarios  $n_2$  es igual a 1 (ver anexo C). A continuación exponemos las ecuaciones del cokrigado colocalizado ordinario (CKCO), el cual considera la media desconocida y la reestima localmente a partir de los datos que intervienen en cada estimación. El estimador por cokrigado ordinario considerando sólo una variable secundaria es:

$$z_{\text{CKCO}}^*(\mathbf{u}) = \sum_{\alpha=1}^{n_1} \lambda_{\alpha_1} z_1(\mathbf{u}_{\alpha_1}) + \lambda_2 [z_2(\mathbf{u}) - m_2 + m_1] \quad \text{[I.29]}$$

En esta variante, las condiciones impuestas a los coeficientes de ponderación en la expresión C.5 no se pueden aplicar porque darían lugar a que el peso colocalizado de la variable secundaria fuera cero. En este caso, estas condiciones se cambian por la condición:

$$\sum_{\alpha_1=1}^{n_1} \lambda_{\alpha_1} + \lambda_{\alpha_2} = 1 \quad \text{[I.30]}$$

El sistema de  $n_1(\mathbf{u})+2$  ecuaciones para el cokrigado colocalizado cuya solución nos da los coeficientes de ponderación es:

$$\begin{cases} \sum_{\beta_1=1}^{n_1} \lambda_{\beta_1} C_1(\mathbf{u}_{\alpha_1} - \mathbf{u}_{\beta_1}) + \lambda_2(\mathbf{u}) C_{12}(\mathbf{u}_{\alpha_1} - \mathbf{u}_0) + \mu = C_1(\mathbf{u}_{\alpha_1} - \mathbf{u}_0), & \alpha_1 = 1, \dots, n_1 \\ \sum_{\beta_1=1}^{n_1} \lambda_{\beta_1} C_{21}(\mathbf{u}_0 - \mathbf{u}_{\beta_1}) + \lambda_2(\mathbf{u}) C_{22}(0) + \mu = C_{21}(0) \\ \sum_{\beta_1=1}^{n_1} \lambda_{\beta_1} + \lambda_2 = 1 \end{cases} \quad [\text{I.32}]$$

Aunque el número de datos secundarios  $n_2$  se reduce a 1, este algoritmo requiere el cálculo de las covarianzas cruzadas  $C_{12}(\mathbf{h})$  entre variables, con  $\mathbf{h}$  igual a la separación entre los puntos considerados. El uso de un modelo markoviano alivia esta tarea.

### Cokrigado colocalizado bajo un modelo Markov

Este algoritmo recurre a un modelo markoviano que expresa que la dependencia de la variable secundaria  $z_2$  sobre la primaria  $z_1$  está limitada al dato colocalizado  $z_2(\mathbf{u})$ , es decir que:

$$E\{Z_2(\mathbf{u})|Z_1(\mathbf{u}) = z, Z_1(\mathbf{u} + \mathbf{h}) = z'\} = E\{Z_2(\mathbf{u})|Z_1(\mathbf{u}) = z\}, \quad \forall \mathbf{h}, z \quad [\text{I.33}]$$

A partir de esta asunción, se puede demostrar que las covarianzas cruzadas  $C_{12}(\mathbf{h})=C_{21}(\mathbf{h})$  del sistema de cokrigado pueden escribirse en función de las covarianzas como:

$$C_{12}(\mathbf{h}) = \frac{C_{12}(0)}{C_1(0)} C_1(\mathbf{h}), \quad \forall \mathbf{h} \quad [\text{I.34}]$$

Es decir, bajo un modelo de Markov, la covarianza cruzada  $C_{12}(\mathbf{h})$  se calcula reescalando la covarianza de la variable principal. El factor de escala es el coeficiente de correlación lineal entre  $C_{12}(0)$  y  $C_1(0)$ .

El algoritmo de cokrigado colocalizado requiere el mismo esfuerzo de implementación que el de krigado con una deriva externa, y tiene la importante ventaja de permitir que el dato secundario participe directamente en la estimación de la variable principal. Además, y a diferencia del krigado con una deriva externa, el modelo de cokrigado colocalizado se construye en base a un parámetro de calibración como es el coeficiente de correlación. Sin embargo, el cokrigado colocalizado sólo considera la no estacionariedad de la variable primaria a partir de la reestimación local de la media con datos vecinos (e.g. cokrigado colocalizado ordinario), mientras que el KDE resuelve este problema recalculando el modelo de tendencia en cada posición a estimar la variable primaria.

## I.7 Cambio de resolución espacial

La escala y cambios de escala es un tema importante en teledetección (Tian et al 2002a, Curran & Atkinson 2002, Townshend & Justice 1988, Woodcock & Strahler 1987), sobre todo en el caso de la validación directa, donde se dispone de un conjunto de datos con diferentes resoluciones espaciales tal como se observa en diferentes experimentos de campo, SAFARI 2000 (Tian et al 2002b), BIGFOOT (Cohen & Justice 1999), BOREAS (Sellers et al 1997b), VALERI (Baret et al 2005a), etc.

El problema de comparar los diferentes conjuntos de datos en la validación directa se resuelve mediante la agregación o *up-scaling*. Debido a la escala de variación de la variable y a la heterogeneidad mostrada en la zona de estudio, el principal problema del *up-scaling* se refiere a que el modelo o proceso de estudio a una determinada resolución (e.g. alta) no tiene por qué ser igual a otra escala (Raffy 1994). En este contexto, se plantean dos cuestiones de forma frecuente y que se deberán considerar en la última fase de la validación, (i) si el parámetro biofísico estimado a baja resolución es equivalente al medido *in-situ* y (ii) si se debería estimar el mapa de alta resolución y luego agregar a baja resolución o agregar las bandas de reflectividad y, posteriormente aplicar la función de transferencia estimada *in-situ* (Liang 2002, Chen 1999).

Matemáticamente, la forma correcta de estimar un parámetro biofísico ( $X$ ) a baja resolución espacial (e.g. VEGETATION 1 km) a partir de  $n$  píxeles de alta resolución (e.g. SPOT 20 m), consiste en calcular dicho parámetro a partir de la media aritmética de los  $n$  valores correspondientes a los píxeles de alta resolución,  $X_i$  (Woodcock & Strahler 1987). De modo que:

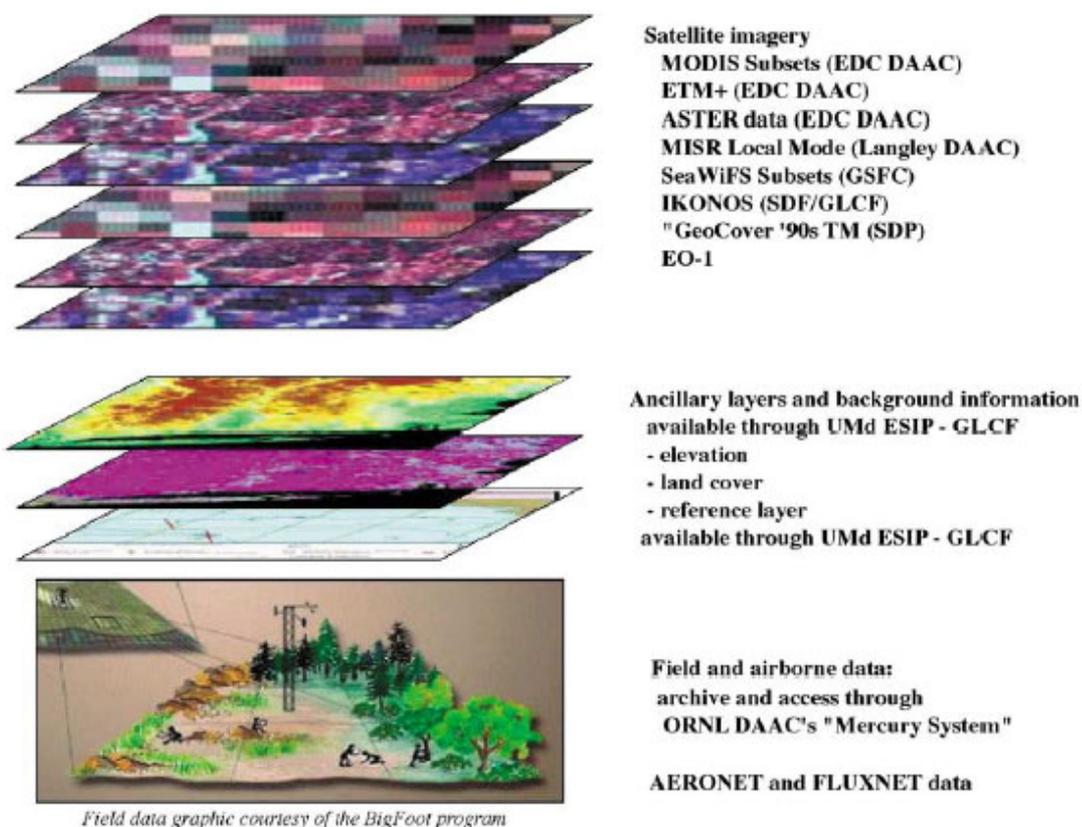
$$X = \frac{1}{n} \sum_{i=1}^n X_i \text{ donde } X_i = f(IV_i; R_i) \quad [I.35]$$

En Chen (1999) se puede encontrar una descripción más detallada de la influencia de la no linealidad de la función  $f$  en el escalado. En nuestro caso, los dos métodos escogidos se basan en estimaciones lineales a partir de las medidas *in-situ*.

Por último, un aspecto importante del escalado ha sido el intentar mantener las características más importantes de la imagen, lo que ha llevado a desarrollar diferentes técnicas, como la transformada de fourier (Justice et al 1989) y las *wavelets* (Jansen 1998, Zhou 1998). Son métodos que trabajan en el dominio de las frecuencias y que permiten eliminar la variabilidad mostrada por la resolución fina manteniendo las características estructurales más destacables. Sin embargo, presentan la limitación de un mayor requerimiento computacional.

## I.8 Programas Internacionales de Validación

La necesidad por un protocolo de validación estándar y robusto, ha dado lugar al desarrollo de un conjunto de programas de validación (e.g. CEOS/LPV, BIGFOOT, VALERI), experimentos de campo (e.g. SAFARI 2000, BOREAS) y bases de datos orientadas a la recopilación y adquisición de información apropiada y de utilidad para validar los diferentes productos (e.g. CEOS-BELMANIP). Según las recomendaciones del WGCV, los programas internacionales de validación de productos a baja resolución espacial coinciden en realizar un esfuerzo común por recopilar la mayor variedad de información de la zona de estudio, y así caracterizarla lo mejor posible, como diferentes medidas *in-situ* (e.g. parámetros estructurales de la cubierta), información del uso del suelo y topografía de la zona (e.g. catastros, clasificación de la cubierta, modelo digital del terreno) e imágenes de sensores con resoluciones espaciales distintas (ver figura I.14). A continuación se destacan los programas, experimentos y redes de datos más relevantes para nuestro estudio.



**Figura I.14.** Ejemplo de la metodología propuesta por CEOS/WGCV. Estos datos están disponibles para todos los *test sites* propuestos por CEOS a través de la Universidad de Maryland<sup>12</sup>.

<sup>12</sup> <http://esip.umiacs.umd.edu/>

### I.8.1 Principales programas de validación

Los programas de validación actuales se han desarrollado para la validación de los productos y algoritmos específicos de un determinado sensor, los cuales proponen un total de aproximadamente 100 zonas de estudio distribuidas por todo el globo con dimensiones desde 1×1 km<sup>2</sup> hasta 10×10 km<sup>2</sup> (Baret et al 2005b).

#### CEOS/LPV

Consiste en 24 zonas de estudio elegidas debido al amplio número de medidas de campo y observación desde satélite llevadas a cabo, de modo que se presentan como zonas adecuadas para llevar a cabo un seguimiento de la cubierta vegetal (ver figura I.15). En la mayoría de los casos, la zona incluye una torre de medida equipada con instrumentos tanto arriba como abajo para la caracterización continua de respuesta radiométrica de la superficie, flujos de dióxido de carbono, variables meteorológicas y contenido de aerosoles y vapor de agua en la atmósfera. Estas medidas se complementarán con campañas de campo intensivas a lo largo del año.

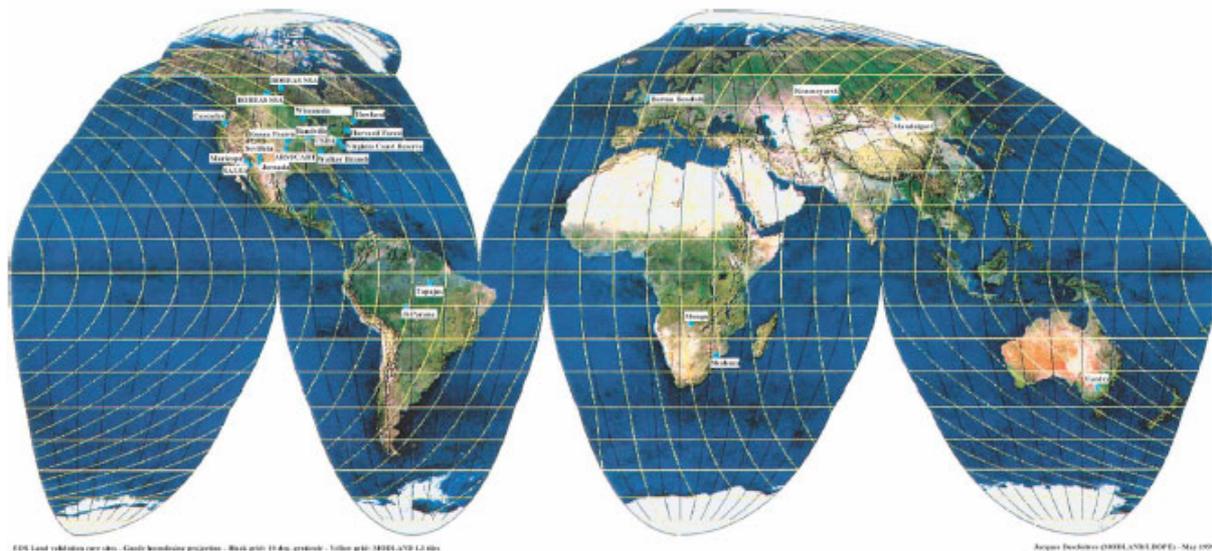


Figura I.15 Zonas de validación seleccionadas por CEOS/LPV.

#### BIGFOOT

Fue desarrollado por la NASA con el objetivo de diseñar un protocolo consistente para validar, en un principio, los productos de Tierra del sensor MODIS (LAI, FAPAR y NPP). Es uno de los principales programas que se han creado para este propósito y que han ofrecido sus datos para otras actividades de validación de EOS. El programa *Bigfoot* se ha consolidando como uno de los proyectos en los que apoyarse para llevar a cabo las diferentes actividades de validación, debido a que plantea una metodología que incluye adquisición de medidas *in-situ*, evalúa diferentes muestreos y aborda el problema del escalado de las medidas *in-situ* hasta las resoluciones espaciales de los productos a validar (Cohen & Justice 1999,

Reich et al 1999). Las zonas de estudio elegidas (e.g. Barrow-USA, Thompson-Canada) se caracterizan por unas dimensiones mínimas de 5×5 km<sup>2</sup> e incluyen una torre meteorológica que proporciona medidas de flujo de energía, agua y carbono. Por otra parte, también se realizan medidas de los parámetros LAI, FAPAR y NPP alrededor de la torre.

La adquisición de los datos se realiza de forma que exista una coincidencia con el paso de diferentes satélites. Por otra parte, el centro de soporte ORNL DAAC<sup>13</sup> (*Oak Ridge National Laboratory Distributed Active Archive Center for Biogeochemical Dynamics*) asociado a la NASA se encarga de la coordinación y distribución de datos. Este organismo da soporte a los programas de validación mediante el archivo y distribución de los datos asociados a la validación, tanto de campo como adquiridos por teledetección. Este tipo de soporte permite que la información sea más accesible y transparente, facilitando el intercambio de información y la posibilidad de llevar a cabo estudios globales en zonas que no serían accesibles o de muy alto coste económico en la mayoría de los casos.

### VALERI

Este proyecto se ha dirigido a la validación de productos derivados a partir de sensores de resolución media principalmente europeos (e.g. VEGETATION/SPOT). Uno de los objetivos consiste en construir una base de datos que incluya medidas *in-situ* de los parámetros FVC y LAI en diferentes tipos de cubiertas distribuidas globalmente. Las adquisiciones se han ido realizando desde el 2001 principalmente en zonas agrícolas (e.g. Barrax (España), Funduela (Rumania)), bosques naturales (e.g. Järvselja (Estonia)) y vegetación natural (e.g. Mongu (Zambia), Skukuza (Sudáfrica)). Para la validación de los productos a resolución media se utilizan mapas de alta resolución de dichos parámetros, los cuales se han obtenido a partir de la relación que existe entre las estimaciones *in-situ* en un área de 3×3 km<sup>2</sup> y la información radiométrica proporcionada por una imagen de alta resolución (SPOT o Landsat).

### METLAND

METLAND da nombre al conjunto de actividades de validación diseñadas para evaluar la información derivada mediante teledetección y los algoritmos diseñados dentro del proyecto LSA SAF. Los principales objetivos de esta actividad se enfocan a los siguientes productos: (i) variables relacionadas con el régimen de radiación (e.g. BDRF, temperatura de la superficie, máscara de nieve, radiación incidente, emisividad, humedad del suelo y evapotranspiración) y (ii) parámetros biofísicos (e.g. LAI, FVC, FAPAR y usos del suelo).

---

<sup>13</sup> <http://www.eosdis.orn.gov>

## I.8.2 Red de zonas de estudio

### FLUXNET<sup>14</sup>

Representa una red global de torres micrometeorológicas para medir el intercambio de dióxido de carbono, vapor de agua y energía entre el sistema tierra-atmósfera. Proporciona alrededor de 266 zonas de estudio de gran interés para la validación de productos de vegetación. Aporta información adicional alrededor de la torre de medida, como por ejemplo el tipo de cubierta y su estado fenológico presente en la zona, de gran interés para los modelos de predicción.

### AERONET<sup>15</sup>

Esta red se ha dirigido a la caracterización de aerosoles en la atmósfera. Se considera una base de datos de gran importancia en los programas de validación dada la necesidad de corregir atmosféricamente antes de derivar los productos. Las zonas de estudio incluidas en esta red utilizan un fotómetro solar CIMEL para realizar la caracterización en un número variable de localizaciones, algunas de ellas permanentes (alrededor de 88). Los datos adquiridos se transmiten en tiempo casi real a la red de satélites geoestacionarios (GEOS, METEOSAT) de donde son recogidos por los diferentes centros de procesado y almacenado como la NASA/GSFC (*Goddard Space Flight Center*).

### CEOS-BELMANIP

Corresponde a una agrupación de las zonas de estudio de los diferentes programas de validación presentados en la sección I.8.1 y las que aparecen en las redes FLUXNET y AERONET. Esta iniciativa se ha desarrollado con el objetivo de unificar las bases de datos existentes y ofrecer una base de datos fiable para la validación e intercomparación de productos biofísicos, LAI, FVC y FAPAR. Esta unificación consiste en analizar la distribución de las zonas de estudio por latitudes y tipos de cubierta. Posteriormente, se eliminan aquellas zonas que se repiten en varias bases de datos y se incorporan nuevas áreas en aquellas latitudes o tipos de vegetación que no estén bien caracterizadas por el conjunto de datos existente. El resultado de esta unificación consiste en 432 zonas de estudio con dimensiones de 8×8 km<sup>2</sup>, lo que se sitúa entre las dimensiones mínimas y máximas de las zonas de estudio elegidas en la sección I.8.1 ([Baret et al 2005b](#)).

## I.8.3 Campañas de campo

### SAVE (Southern Africa Validation of EOS)<sup>16</sup>

---

<sup>14</sup><http://www.fluxnet.zut>

<sup>15</sup> <http://aeronet.gsfc.nasa.gov>

<sup>16</sup> <http://modarch.gsfc.nasa.gov/MODIS/LAND/VAL/terra/privette/summary.html>.

Se creó con el objetivo de validar productos de tierra y atmósfera derivados del sensor MODIS/Terra a partir de la adquisición de medidas *in-situ* en diferentes zonas de estudio en esta área. El conjunto de datos es de gran utilidad para el estudio de cambios en la cubierta a nivel regional en el Sur de África y constituye un soporte de adquisición de medidas *in-situ* a nivel regional durante un largo periodo.

## **PROVE**

Se diseñó como un conjunto de actividades dentro del programa de validación de EOS (Privette et al 2000). Los objetivos principales fueron, (i) obtener experiencia en la adquisición de datos *in-situ*, (ii) desarrollar protocolos para la coordinación, medida y archivo de los datos, y (iii) adquirir un conjunto de datos de parámetros de Tierra y atmósfera para evaluar diferentes algoritmos. Los datos derivados de estos experimentos se distribuyen libremente a partir del laboratorio ORNL DAAC. Los diferentes experimentos que han tenido lugar dentro de este contexto han sido:

### *SAFARI2000 (Southern Africa Regional Initiative 2000)*

Tuvo lugar durante el periodo comprendido entre 1999 y 2001 en el Sur de África como un experimento asociado a la validación de productos MODIS/Terra y ETM/Landsat7 (Swap & Annegarn 1999). El proyecto se orientó al diseño de una serie temporal de campañas de campo en diferentes zonas piloto, donde se coordinaron medidas simultáneas *in-situ* con el paso de sensores aerotransportados y a bordo de satélite. La información recogida en las diferentes campañas está organizada en tres CD-ROM de libre distribución, los cuales incluyen información histórica de la zona para el periodo temporal 1973-1995 y parámetros como el contenido en aerosoles, meteorológicos, de la cubierta vegetal, relacionados con los incendios, composición atmosférica e imágenes MODIS.

### *Transecto Kalahari IGBP (Privette et al 2000)*

El transecto de Kalahari se extiende a lo largo de un gradiente de precipitación desde 200 hasta 1000 mm/año en un área donde el tipo de suelo corresponde a *Kalahari sands*. Corresponde a uno de los transectos terrestres del programa IGBP (*International Geosphere Biosphere Programme*) (Caylor et al 2003). Este gradiente de precipitación resulta en cambios drásticos de la vegetación a lo largo del transecto, de modo que el tipo de vegetación abarca desde zonas de bosque denso en el norte a matorrales dispersos en el Sur.

Para finalizar, destacar las diferentes clasificaciones globales existentes, que aunque no corresponden a bases de datos, son de gran utilidad para las actividades de validación. Entre las existentes destacamos, la IGBP (Loveland et al

2000), Corine Land Cover 2000<sup>17</sup>, GLC2000<sup>18</sup> y ECOCLIMAP la cual proporciona información sobre los parámetros, LAI, FVC, albedo y emisividad para su utilización en modelos climáticos (Masson et al 2004).

---

<sup>17</sup> <http://dataservice.eea.eu.int/dataservice/>

<sup>18</sup> <http://www.gvm.jrc.it/glc2000>



## CAPÍTULO II

---

---

### EXPERIMENTO Y MÉTODOS

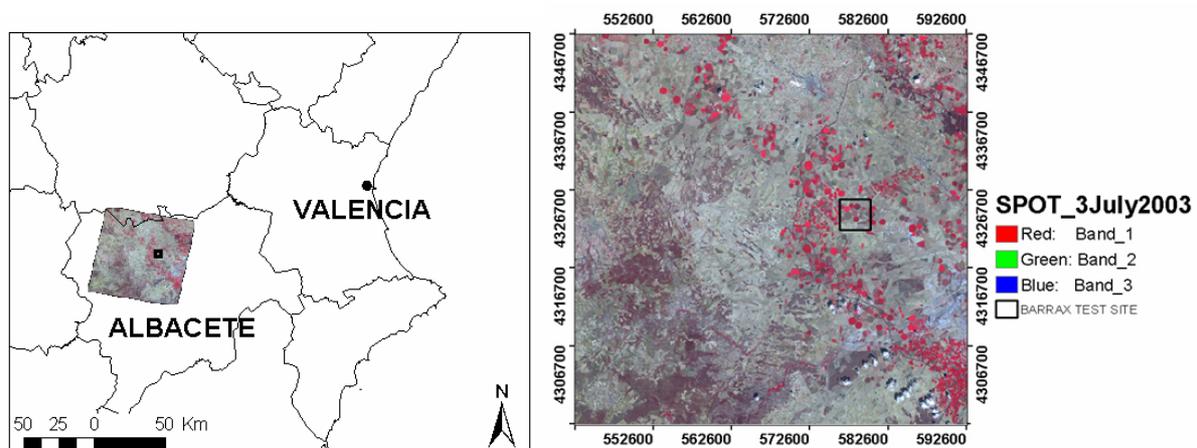
---

---

*En este capítulo se detalla la metodología que proponemos para caracterizar a alta resolución los parámetros LAI, FVC y FAPAR a partir de medidas in-situ en una zona agrícola situada en Barrax (Albacete). Este capítulo comienza con una descripción detallada del área de estudio y las diferentes actividades que tuvieron lugar en dicha área durante Julio de 2003 dirigidas a la validación de algoritmos y productos derivados mediante teledetección. Además, se incluye un estudio del uso del suelo en el momento de la adquisición de medidas in-situ a partir de una clasificación de la zona, y un análisis de la heterogeneidad espacial de la cubierta vegetal a partir de una combinación de herramientas de teledetección y estadística disponibles (Sección II.1). Posteriormente, se describen los instrumentos utilizados para la caracterización in-situ de los parámetros LAI, FVC y FAPAR (i.e. LICOR LAI2000 y cámara hemisférica), las condiciones de adquisición y el procedimiento para procesar los datos (Sección II.2 y II.3). Uno de los objetivos que nos planteamos en este capítulo es evaluar las diferencias (i.e. ventajas e inconvenientes) de la cámara hemisférica frente al LICOR LAI2000. El capítulo continúa con la descripción de los pasos a seguir para derivar los mapas a alta resolución a partir de las técnicas de regresión multivariada y geoestadísticas (Sección II.4). Por último, se aplica la metodología directamente a un caso real, el cual consistirá en la validación directa de los productos de baja resolución MODIS/Terra, VEGETATION/SPOT derivados con diferentes algoritmos (Sección II.5).*

## II.1 Área de Estudio

El área seleccionada para nuestro estudio está situada en la provincia de Albacete (Castilla-La Mancha) y abarca una extensión de 50×50 km<sup>2</sup>. Dentro de este área se incluye la zona piloto de Barrax de aproximadamente 5×5 km<sup>2</sup> (figura II.1) donde se llevaron a cabo las medidas *in-situ*. La zona de Barrax es un área agrícola con predominio de cultivos de secano (Cebada) y alrededor del 40% cultivos de regadío (Maíz, Alfalfa, Trigo, Remolacha y Cebolla).



**Figura II.1.** Localización del área de estudio sobre una imagen SPOT. El área de estudio (50×50 km<sup>2</sup>) abarca parte de la provincia de Albacete e incluye la zona piloto de Barrax (5×5 km<sup>2</sup>) donde se llevó a cabo la campaña de campo SPARC en Julio del 2003.

Este área de estudio se ha escogido debido a diferentes características que la hacen adecuada como zona de validación para sensores, productos y algoritmos. El área presenta una alta variabilidad de los parámetros de interés en una extensión reducida. Por otra parte la gran extensión de los cultivos de regadío, de hasta 1 km de diámetro (ver figura II.2), la hacen idónea para la validación de productos de sensores de media y baja resolución, mientras que la infraestructura de la zona (ITAP<sup>19</sup> y zona de aplicaciones del IDR<sup>20</sup>) le confiere unas características idóneas para seleccionarla como zona de validación. De hecho, esta zona ha sido seleccionada como área piloto en diferentes proyectos de la Unión Europea como EFEDA, RESMEDES, DAIXES y, en la actualidad, DEMETER<sup>21</sup> (Calera et al 2003, Moreno et al 2001, Bolle et al 1993). En los últimos años, ha sido seleccionada por diferentes proyectos y actividades de validación de sensores (e.g. CHRIS/PROBA), algoritmos y productos derivados de satélite (e.g. MERIS/ENVISAT,

<sup>19</sup> Instituto Técnico Agronómico Provincial, [www.itap.es](http://www.itap.es).

<sup>20</sup> Instituto de Desarrollo Regional, [www.idr-ab.uclm.es/idr/idr.asp](http://www.idr-ab.uclm.es/idr/idr.asp).

<sup>21</sup> Demonstration of Earth Observation technologies in routine irrigation advisory services, [www.demeter-ec.net](http://www.demeter-ec.net)

SEVIRI/MSG), como LSA SAF, VALERI y SPECTRA (Baret et al 2005a, Martínez et al 2005b, Camacho-de Coca et al 2003).



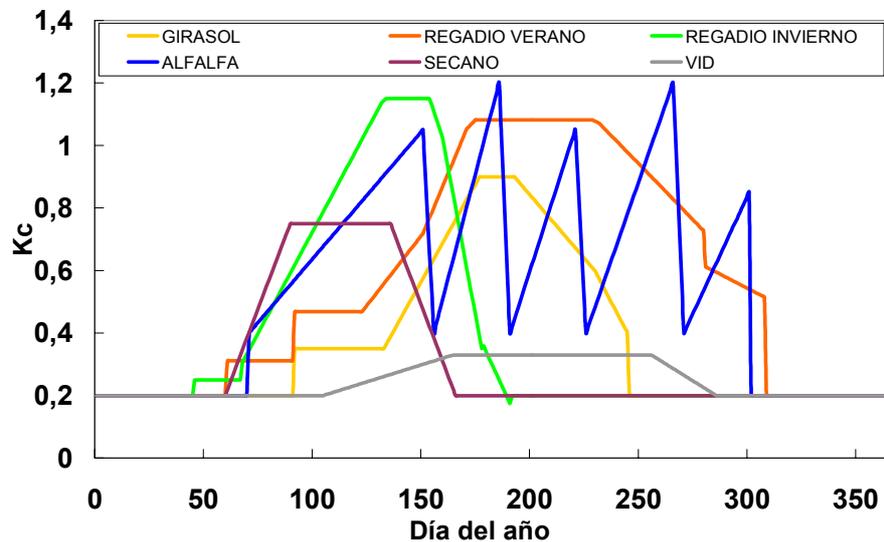
**Figura II.2.** Aspecto de algunos cultivos (e.g. Patata y Alfalfa) muestreados en la zona de estudio de Barrax durante la campaña de SPARC donde se pone de manifiesto su gran extensión (aprox. 800 m de diámetro).

La zona dispone de tres estaciones agro-meteorológicas de la Universidad de Castilla la Mancha, (i) Las Tiesas ( $39^{\circ} 02' 31''$  N;  $2^{\circ} 04' 55''$  O), (ii) Las Tiesas-Lisímetro ( $39^{\circ} 03' 30''$  N;  $2^{\circ} 05' 24''$  O) y (iii) Blancares ( $39^{\circ} 06' 45''$  N;  $2^{\circ} 06' 40''$  O). Estas estaciones se dedican a la adquisición de parámetros con interés para la agro-meteorología (e.g. precipitación, evapotranspiración, velocidad y dirección del viento, temperatura del aire y del suelo, humedad relativa, presión y radiación).

El clima de la zona es de tipo mediterráneo, con precipitaciones en primavera y en otoño, y una estación muy seca en verano. Presenta, además, características propias del clima continental como son unas oscilaciones térmicas diarias altas para todas las estaciones. El régimen medio de precipitaciones anual es inferior a 400 mm, lo que muestra esta zona de La Mancha como una de las más secas de Europa, siendo relativamente alta la variabilidad de un año a otro. Los suelos son de fina textura y presentan un cierto grado de compactación en condiciones secas. Todos los suelos muestran una capa cálcica a aproximadamente 40 cm bajo la superficie. Por debajo de esta capa, aparece otra con grandes cantidades de piedra caliza, lo que constituye la principal limitación productiva del suelo en Barrax (Moreno et al 2001).

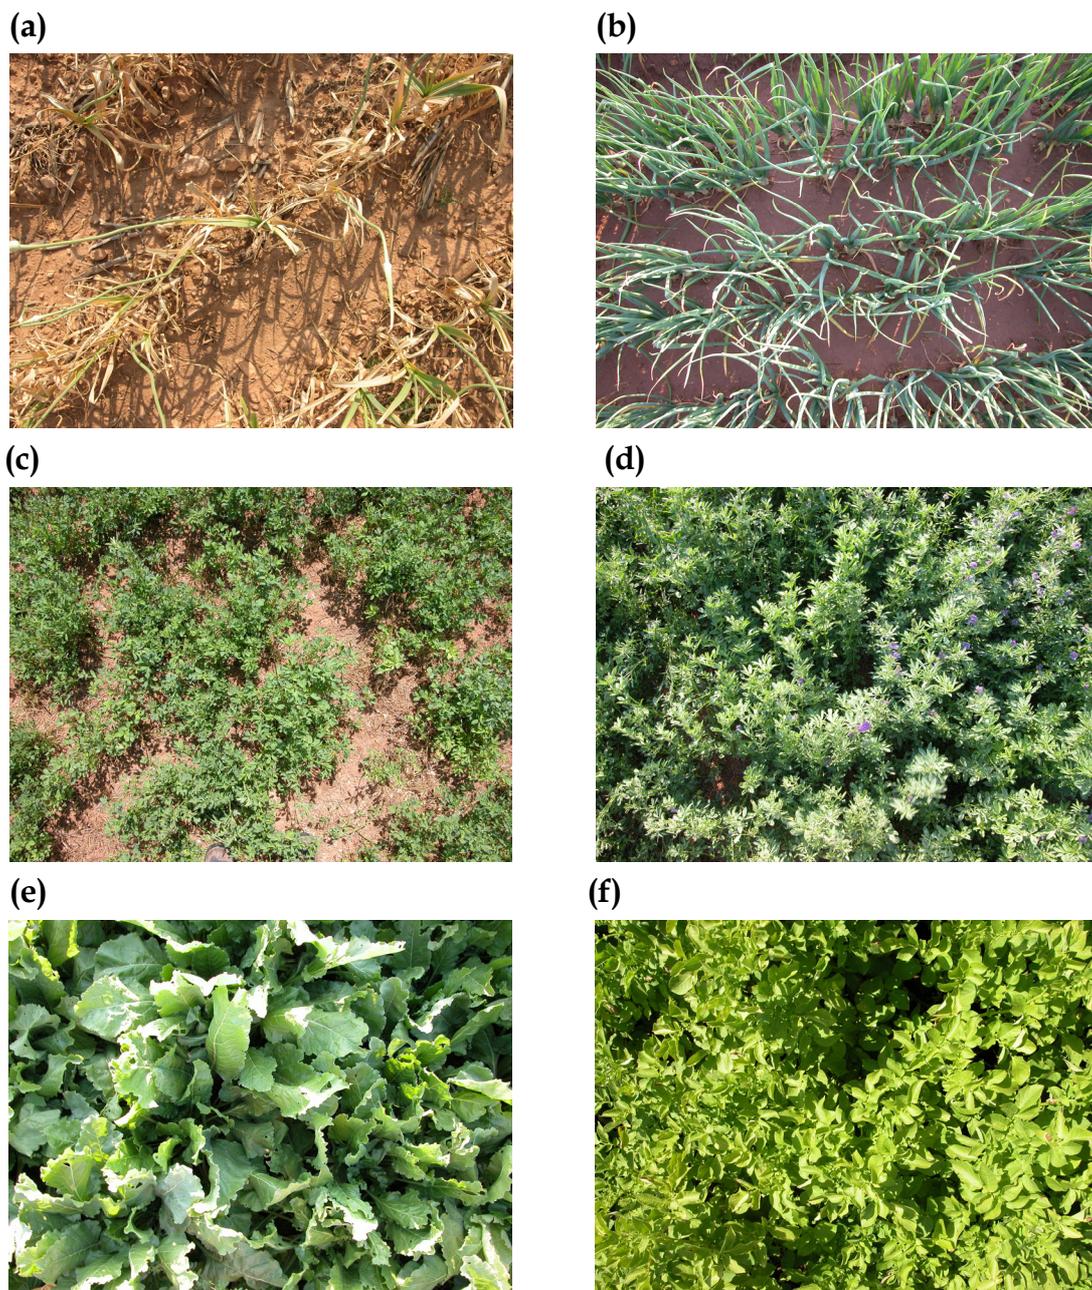
La cubierta vegetal de la zona de estudio presenta un ciclo anual diferente dependiendo del cultivo. Los cultivos de regadío pertenecientes a verano (e.g. Alfalfa, Maíz), la Viña y el Girasol, muestran un máximo común en el coeficiente de cultivo, Kc, entre Junio y Julio (ver figura II.3). El coeficiente de cultivo varía con el propio cultivo y describe las variaciones en la cantidad de agua que las plantas extraen del suelo a medida que se van desarrollando, siendo un buen indicador del desarrollo de la cubierta vegetal (Allen et al 1998). Este comportamiento proporciona las condiciones idóneas para disponer de un amplio rango de

variabilidad en la cubierta vegetal (i.e. fracción de cobertura entre 0-100% y LAI entre 0-6), adecuado para llevar a cabo experimentos como el que se detalla en este capítulo.



**Figura II.3.** Variación anual del coeficiente de cultivo,  $K_c$ , para los cultivos dominantes en la zona de Barrax (e.g. regadío de verano, invierno, secano, Alfalfa, Viña y Girasol).

En la figura II.4 se puede observar el rango de variabilidad encontrado en la zona a partir de diferentes cubiertas de la zona de estudio. Los cultivos de Ajo (figura II.4a) y Cebollas (figura II.4b) son los que presentaban una vegetación más dispersa, con valores de biomasa igual a  $130 \pm 30 \text{ g m}^{-2}$  y  $83 \pm 7 \text{ g m}^{-2}$  y clorofila igual a  $15 \pm 2 \mu\text{g cm}^{-2}$  y  $20 \pm 2 \mu\text{g cm}^{-2}$ , respectivamente. Por otra parte, el cultivo de Alfalfa mostraba una mayor variabilidad espacial entre campos, con un rango de FVC entre 40% y 90% (figura II.4c y II.4d), biomasa igual a  $89 \pm 23 \mu\text{g cm}^{-2}$  y el valor más alto de clorofila ( $48.5 \pm 1.2 \text{ g m}^{-2}$ ). Mientras que los cultivos de Remolacha y Patata mostraban el valor más alto de FVC y de LAI, caracterizados con valores de clorofila altos ( $44.3 \pm 1.4 \text{ g m}^{-2}$  y  $35.6 \pm 0.5 \text{ g m}^{-2}$ ) y biomasa igual a  $72 \pm 11 \mu\text{g cm}^{-2}$  y  $43 \pm 3 \mu\text{g cm}^{-2}$ , respectivamente (Fernández et al 2005).



**Figura II.4.** Variabilidad mostrada por diferentes tipos de cubiertas de la zona de estudio, como el Ajo (a), Cebolla (b), Alfalfa (c) y (d), Remolacha (e) y Patata (f).

### II.1.1 Campaña de campo SPARC

La adquisición de las medidas utilizadas para la validación directa se realizó durante la campaña de SPARC<sup>22</sup> (SPectra bARax Campaign), los días, 12, 13 y 14 de Julio del 2003 (figura II.5). Esta actividad surgió de un conjunto de iniciativas que contaban con la subvención de ESA, CNES, EU y EUMETSAT. Todas estas

---

<sup>22</sup> <http://gpds.uv.es/sparc>

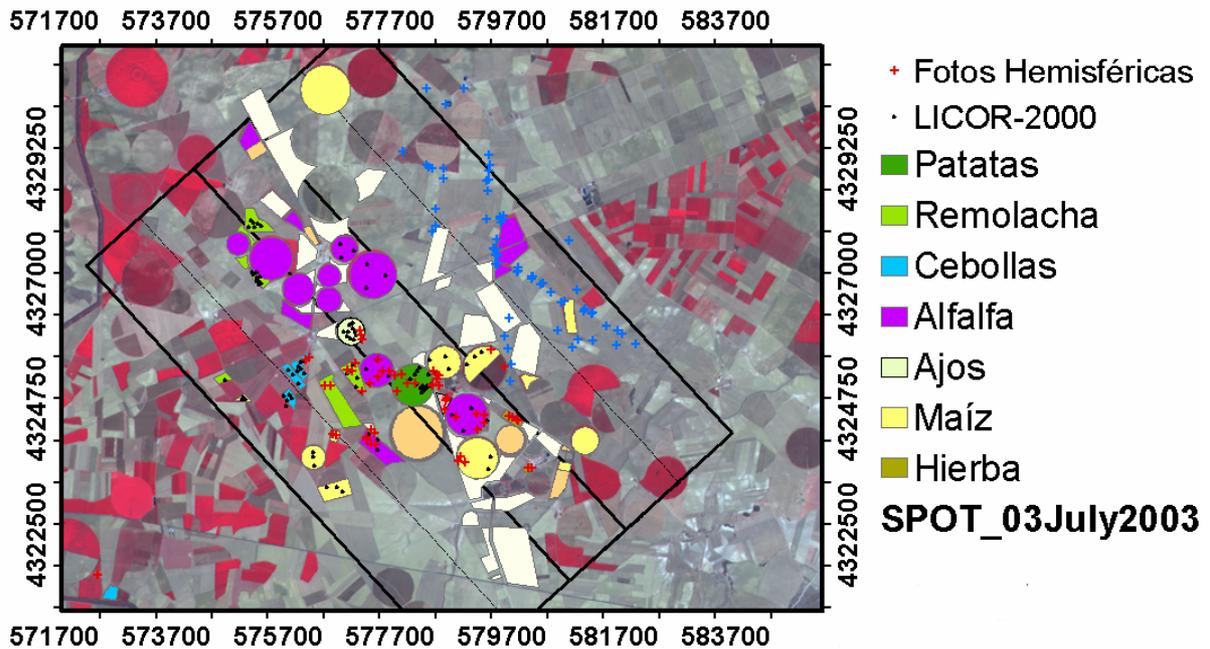
actividades compartían un interés común, la adquisición *in-situ* de parámetros biofísicos simultáneos al paso de satélite y de aviones con sensores aerotransportados para llevar a cabo actividades de validación de productos derivados de dichos sensores (CHRIS/PROBA, MERIS/ENVISAT y SEVIRI/MSG) como también, de los algoritmos utilizados. Finalmente, este conjunto de actividades se integraron en un proyecto común financiado por la ESA en el marco de la fase preparatoria asociada a la misión Spectra (*Surface Processes and Ecosystems changes Through Response*). Por otra parte, una segunda campaña del experimento SPARC tuvo lugar durante los días 13 a 17 de Julio del 2004 en la misma zona, con objetivos similares (Martínez et al 2005b).

La elección de las fechas de SPARC'03 estuvo condicionada principalmente por el paso del satélite CHRIS/PROBA sobre la zona de estudio además de las condiciones meteorológicas que se predecían favorables. El satélite voló el 12, 13 y 14 de Julio con una configuración de +20, -4 y -27 *across zenith angle*, respectivamente. Por otra parte, también favoreció la elección de estas fechas el que hubiera vuelos de diferentes sensores a bordo de satélites, como MERIS, Landsat y SPOT.

Además de varias unidades de la Universidad de Valencia (Unidad de Teledetección, Unidad de Cambio Global, Unidad de Radiación Solar y GPDS), participaron la Universidad de Castilla-La Mancha, el Instituto de Desarrollo Regional, el ITAP, el Centro de Investigaciones Energéticas, Medioambientales y Tecnológicas (CIEMAT), DLR-Alemania, la Università degli Studi di Napoli 'Federico II'-Italia, INRA-CSE-Avignon, Laboratoire du Télédétection at SIRS-Túnez y Météo-France.

Además de la adquisición de los parámetros LAI, FVC y FAPAR, se midieron durante la campaña diferentes parámetros relacionados con la cubierta vegetal, como la biomasa y clorofila. Por otra parte, se llevaron a cabo diferentes radiosondeos y medidas relacionadas con el contenido de aerosoles en la atmósfera en coincidencia con el paso de los diferentes sensores para corregir atmosféricamente las diferentes imágenes. También se adquirieron medidas radiométricas de la superficie para validar las imágenes corregidas junto con medidas de emisividad y temperatura, ver figura II.5.

Alrededor y durante los días que se realizaron las medidas *in-situ* se obtuvieron imágenes de la zona de estudio proporcionadas por sensores aerotransportados con diferentes características espectrales y espaciales, como ROSIS (1m) y HyMAP (5 m) y sensores a bordo de satélites, como HRVIR2/SPOT4 (20 m), TM/Landsat-5 (30 m), CHRIS/PROBA (34 m), MERIS/ENVISAT (300 m-1 km) y SEVIRI/MSG (3 km).



**Figura II.5.** Área de estudio de la campaña de campo SPARC junto con la localización de las diferentes medidas e información sobre los usos del suelo que se recogió durante la campaña. La imagen de fondo corresponde a la imagen HRVIR2/SPOT4 adquirida el 3 de Julio de 2003.

En el contexto de la validación directa, cabe destacar que la campaña SPARC'04 fue de gran interés para ensayar parte de la metodología descrita en este trabajo (e.g. medidas con la DHP) y aspectos nuevos, como la influencia de un muestreo espacial con la DHP diferente al realizado en SPARC'03 con el propósito de evaluar su influencia en la estimación de los mapas de alta resolución. En este experimento se utilizaron de nuevo los instrumentos, LICOR LAI2000 y cámara hemisférica para la caracterización *in-situ* de un área mayor. Aunque el conjunto de datos es similar, la metodología descrita en este trabajo solo se ha ensayado hasta el momento con los datos correspondientes al experimento SPARC'03.

### II.1.2 Imágenes de satélite

La imagen de alta resolución utilizada en este trabajo corresponde a HRVIR2/SPOT4 adquirida para la campaña de SPARC el día 3 de Julio de 2003. La imagen se compone de las bandas espectrales en el verde (G), rojo (R), infrarrojo cercano (NIR) e infrarrojo medio (MIR) sin corrección atmosférica. La imagen se corrigió geométricamente a la proyección UTM 30N-ED50. En el caso de la técnica de regresión multivariada, las estimaciones se muestran invariantes respecto a transformaciones lineales, como es el caso de los métodos para corregir de atmósfera en áreas pequeñas. Sin embargo en los modelos geostadísticos que utilizan información derivada de teledetección como variable secundaria (i.e. cokrigado colocalizado y el krigado con derivada externa) se espera un sesgo en

el valor estimado debido al efecto de la atmósfera. Esta cuestión se analizará con detalle más adelante.

Por otra parte, además de las imágenes proporcionadas durante la campaña SPARC, se adquirieron productos derivados de los sensores MODIS/Terra (1 km) utilizados en MODLAND, VEGETACION/SPOT (1 km) en CYCLOPES<sup>23</sup> y SEVIRI/MSG en LSA SAF, con el propósito de validar dichos productos con los mapas derivados en este trabajo. Se han escogido estos productos, por ser productos derivados de un nuevo algoritmo que debe ser validado, (e.g. VEGETATION/SPOT y SEVIRI/MSG) y comparados con otros productos actualmente en uso (e.g. MODIS LAI/FAPAR). Estos productos se describen con más detalle en el capítulo V.

### II.1.3 Clasificación de la zona de estudio

Con el objetivo de distinguir los diferentes comportamientos que pudieran existir entre los parámetros medidos y su respuesta espectral se ha realizado una clasificación supervisada de la zona de estudio a partir del algoritmo de máxima probabilidad (Richards 1999).

La clasificación supervisada consiste en segmentar la imagen en diferentes clases definidas que se han definido *a priori* basándonos en información recogida durante la campaña SPARC. En este proceso, se seleccionan diferentes regiones de entrenamiento perfectamente identificadas y relativamente homogéneas para cada una de las clases temáticas escogidas. El método de máxima probabilidad considera que cada clase viene descrita por una función de densidad de probabilidad normal multivariante. En base a las áreas de entrenamiento calcula los parámetros de dichas funciones y asigna a cada píxel una probabilidad *a posteriori* para cada una de las clases. Aquellos píxeles para los que la clase más probable no satisface el umbral de tolerancia preestablecido aparecen sin clasificar en la imagen.

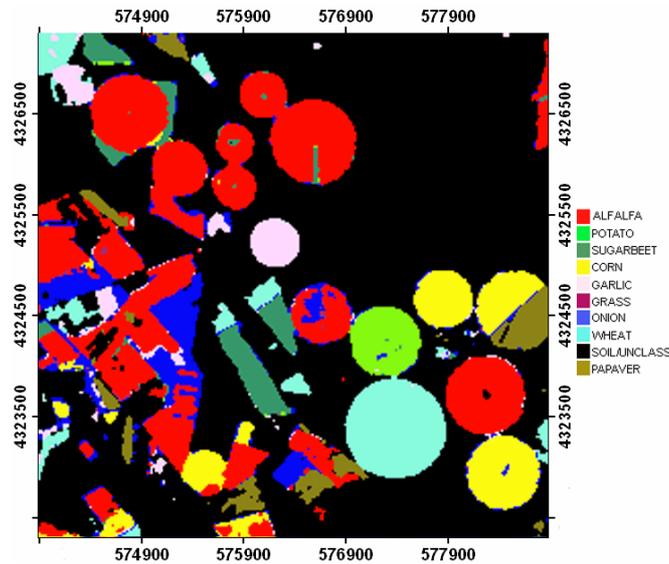
La clasificación se aplicó a las bandas espectrales de la imagen SPOT, utilizando un valor límite de probabilidad del 80%. Se utilizaron 10 clases basadas en la información recogida durante la campaña de campo, Suelo, Alfalfa, Trigo, Cebolla, Maíz, Patata, Remolacha, Hierba, Adormidera y sin clasificar. La clase más dominante muestra ser la de Suelo con 66% de presencia, seguido de la Alfalfa (14%), Trigo, Cebolla y Maíz con un 4% cada una (ver figura II.6).

Posteriormente a la clasificación, se precisa calcular la fiabilidad de los resultados analizando la exactitud global y por clase. En primer lugar se seleccionan una serie de áreas verdad terreno (*test*) pertenecientes a las clases definidas y se calcula la matriz de confusión, la cual consiste en una matriz bidimensional de doble entrada

---

<sup>23</sup> <http://www.avignon.inra.fr/cyclopes/>

en la que las filas representan los datos procedentes del resultado de clasificación y las columnas los datos de la verdad terreno. Esta matriz permite evaluar la exactitud por clases. La tabla II.1 muestra la matriz de confusión donde los elementos de la diagonal se refieren al número de píxeles clasificados correctamente en cada una de las clases y los situados fuera de la diagonal corresponden al porcentaje de píxeles que presentan errores en la clasificación.



**Figura II.6.** Clasificación de la zona de estudio realizada a partir de las bandas espectrales de la imagen SPOT. La imagen se ha clasificado en 10 clases según el método de clasificación supervisada de máxima probabilidad.

Los elementos agrupados por columnas, excepto los de la diagonal, corresponden a píxeles de las áreas *test* que no se incluyen en la clase que representa dicha área, se les denomina errores de comisión. Por otra parte, los elementos de una misma fila, excluyendo la diagonal, corresponden a píxeles que una vez clasificados fueron excluidos de esa clase. En nuestro caso, la matriz de confusión (tabla II.1) muestra porcentajes superiores al 90% para todas las zonas *test* excepto para el Ajo (*Test4*). Las regiones *Test1*, *Test4* y *Test7*, pertenecientes a los cultivos de Alfalfa, Ajo y Cebolla, son las que mayor confusión han presentado con un porcentaje de hasta 8% en la clase de Suelo.

La exactitud global se analiza en este caso a partir del estadístico Kappa ( $\kappa$ ), que mide la diferencia entre el acuerdo clasificación-verdad terreno y el que cabría esperar mediante una asignación al azar. Este estadístico se define de la forma:

$$\kappa = \frac{N \sum_k x_{kk} - \sum_k x_{k\Sigma} x_{\Sigma k}}{N^2 - \sum_k x_{k\Sigma} x_{\Sigma k}} \quad \text{[II.1]}$$

donde  $N$  es el número de clases,  $x_{kk}$  son los elementos de la diagonal de la matriz de confusión y  $x_{k\sigma}$  el resto de elementos. El resultado que se obtiene es un 97% de píxeles clasificados correctamente con un valor de  $k$  igual a 0.9.

**Tabla II.1.** Matriz de confusión derivada de la clasificación supervisada mediante el método de máxima probabilidad.

|                  | <i>Test1</i> | <i>Test2</i> | <i>Test3</i> | <i>Test4</i> | <i>Test5</i> | <i>Test 6</i> | <i>Test7</i> | <i>Test8</i> |
|------------------|--------------|--------------|--------------|--------------|--------------|---------------|--------------|--------------|
| <b>Alfalfa</b>   | <b>94.27</b> | 0.00         | 0.00         | 0.00         | 0.70         | 0.13          | 4.52         | 0.00         |
| <b>Trigo</b>     | 0.00         | <b>99.94</b> | 0.00         | 3.27         | 0.00         | 0.00          | 0.00         | 0.00         |
| <b>Patata</b>    | 0.04         | 0.00         | <b>97.65</b> | 0.00         | 0.00         | 0.13          | 0.00         | 0.00         |
| <b>Ajo</b>       | 0.20         | 0.06         | 0.26         | <b>87.91</b> | 0.06         | 0.00          | 0.00         | 0.00         |
| <b>Maíz</b>      | 0.06         | 0.00         | 0.00         | 0.00         | <b>98.06</b> | 0.00          | 1.07         | 0.00         |
| <b>Remolacha</b> | 1.05         | 0.00         | 0.78         | 0.00         | 0.00         | <b>99.24</b>  | 0.00         | 0.00         |
| <b>Cebolla</b>   | 3.12         | 0.00         | 1.31         | 0.00         | 1.00         | 0.13          | <b>90.83</b> | 0.00         |
| <b>Suelo</b>     | 1.26         | 0.00         | 0.00         | 8.82         | 0.18         | 0.38          | 3.57         | <b>100.0</b> |

#### II.1.4 Estudio de la heterogeneidad de la zona

En este apartado discutimos la heterogeneidad de la cubierta vegetal. Este estudio se ha llevado a cabo con el objetivo de analizar la variabilidad espacial presente en los cultivos donde se realizaron medidas y derivar conclusiones sobre la capacidad o limitaciones del muestreo utilizado para caracterizar dicha variabilidad. Además, este estudio será de gran utilidad en el análisis posterior que se realizará en el capítulo IV sobre la influencia del muestreo en las estimaciones. Cabe destacar que sería conveniente analizar la heterogeneidad de la zona de estudio antes de diseñar el muestreo y así decidir previamente a la adquisición *in-situ*, el número de ESUs necesarias, o su posición de acuerdo a la variabilidad mostrada en la zona.

El estudio que se presenta a continuación se ha realizado a partir del NDVI calculado de la imagen SPOT. El procedimiento ha consistido, en primer lugar, en crear una capa vectorial que contenga la información sobre los diferentes cultivos presentes en la zona y posteriormente superponerla sobre la de NDVI. En segundo lugar, se han calculado diferentes parámetros estadísticos que permitirán analizar la variabilidad espacial dentro de cada campo. Los parámetros estadísticos que se han elegido son la media, desviación estándar, coeficiente de variabilidad, los percentiles de 25% y 90% y su diferencia. El percentil de un cierto porcentaje, indica el valor de la magnitud por debajo del cual se encuentra el 90% de los datos. De este modo, cuánto más difieran los percentiles extremos (en este caso se han elegido los de 25% y 90%), mayor variación mostrará la magnitud medida.

La tabla II.2 muestra estos estadísticos para los campos de Alfalfa (A1, A9, A10), Remolacha (B3), Maíz (C1, C2 y C3), Cebolla (ON1), Patata (P1), Ajo (G1) y Hierba (GR). Los campos de Remolacha (B3) y Patata (P1) aparecen como los más densos,

dado su alto valor de NDVI (0.6), y homogéneos, dado los valores tan bajos de CV (8% y 3%), desviación estándar (0.05 y 0.017) y diferencia de percentiles (0.03 y 0.02). El campo menos denso muestra ser el de Ajo (i.e. valor medio 0.12), seguido de dos de los tres campos de Alfalfa, el A1 y A10 (i.e. valores medios 0.18). El cultivo de Alfalfa es el que presenta una mayor variabilidad en el estado fenológico de la cubierta y distribución espacial, siendo el campo A10 el más heterogéneo junto con el C1 y GR (i.e. CV y diferencia de percentiles más altos), tal como se observó *in-situ*.

**Tabla II.2.** Parámetros estadísticos calculados con los valores de NDVI para los diferentes campos donde se adquirieron medidas *in-situ*, Alfalfa (A1, A9, A10), Remolacha (B3), Maíz (C1, C2 y C3), Cebolla (ON1), Patata (P1), Ajo (G1) y Hierba (GR).

| Campo | $\sigma$ | Media | CV(%) | Per25% | Per90% | Per25%-Per90% |
|-------|----------|-------|-------|--------|--------|---------------|
| A1    | 0.016    | 0.18  | 8     | 0.17   | 0.20   | 0.03          |
| A9    | 0.03     | 0.42  | 7     | 0.40   | 0.45   | 0.05          |
| A10   | 0.06     | 0.18  | 16    | 0.15   | 0.21   | 0.07          |
| B3    | 0.017    | 0.58  | 3     | 0.57   | 0.59   | 0.02          |
| C1    | 0.05     | 0.47  | 11    | 0.44   | 0.53   | 0.09          |
| C2    | 0.04     | 0.57  | 7     | 0.53   | 0.60   | 0.07          |
| C3    | 0.02     | 0.57  | 4     | 0.54   | 0.58   | 0.04          |
| G1    | 0.019    | 0.12  | 15    | 0.11   | 0.15   | 0.04          |
| GR    | 0.04     | 0.31  | 12    | 0.29   | 0.36   | 0.07          |
| ON1   | 0.013    | 0.35  | 4     | 0.34   | 0.36   | 0.02          |
| P1    | 0.05     | 0.62  | 8     | 0.62   | 0.65   | 0.03          |

## II.2 Instrumentación y condiciones de adquisición

La caracterización *in-situ* de los parámetros biofísicos se llevo a cabo con los instrumentos LICOR LAI2000 y cámara hemisférica digital. Se eligieron ambos instrumentos para caracterizar el LAI, FVC y FAPAR por su uso extendido en la estimación de dichos parámetros, fácil manejo y disponibilidad de información extra sobre parámetros estructurales de la cubierta, como el ALA y *clumping* proporcionados por las DHPs (Martínez et al 2005a).

La cámara hemisférica se utilizó debido a que se trata de un método novedoso utilizado en proyectos de validación como VALERI y que permite, a diferencia del LICOR LAI2000, estimar los parámetros FVC, FAPAR y *clumping* (Baret et al 2005a, Martínez et al 2004b). Por otra parte, se contó con la presencia del grupo de INRA-Avignon encargado de caracterizar *in-situ* la zona de Barrax dentro del proyecto

VALERI, dado que era uno de los *test sites* de la red para la validación directa de productos MERIS y VEGETATION. Dicho grupo participó exclusivamente en la adquisición de los parámetros biofísicos junto con nuestro grupo. A continuación, se describen las condiciones de adquisición requeridas por ambos instrumentos para obtener estimaciones lo más exactas posibles.

### II.2.1 LICOR LAI2000 Plant Canopy Analyzer

El LICOR LAI2000, al medir radiación difusa, requiere condiciones uniformes de iluminación para estimar el LAI, siendo las mejores condiciones de iluminación cuando el Sol se sitúa casi en el horizonte (i.e. al amanecer y atardecer) o el cielo está cubierto de nubes. La minimización de estos factores en la medida se resuelve utilizando unas máscaras sobre el sensor que impiden el paso de la radiación para determinados ángulos. Se utilizan máscaras de 180° y de 270° para reducir la influencia de la radiación directa (Nackaerts & Coppin 2000), también se utilizan máscaras de 90° para reducir la influencia del operador aunque las condiciones de iluminación sean las adecuadas. Existen varias situaciones en las que la medida realizada debajo de la cubierta pueda exceder a la de arriba, (i) cambios en las condiciones de iluminación, (ii) error del operador o (iii) variaciones debidas al instrumento. La tabla II.3 describe diferentes consideraciones en la estimación del LAI con el LICOR LAI2000.

**Tabla II.3.** Consideraciones en la estimación del LAI con el LICOR LAI2000.

| Factores externos              |   |
|--------------------------------|---|
| <i>Iluminación</i>             | Mide radiación difusa, requiere condiciones uniformes de iluminación para estimar el LAI                                    |
| <i>Posición del operador</i>   | El operador debe situarse detrás del sensor. Se suele utilizar una máscara de 90° para minimizar la influencia del operador |
| Características de la cubierta |   |
| <i>Cubiertas bajas</i>         | No es posible realizar medidas en este tipo de cubiertas  |

En el caso del LICOR LAI2000 las adquisiciones se realizaron durante las dos primeras horas de la mañana y las dos últimas horas de la tarde para evitar que el sensor recibiera radiación directa. Se organizaron tres grupos compuestos como mínimo por dos personas, el operador y el que anotaba la posición GPS de la ESU, así como diferentes parámetros relacionados con la estructura y estado de la cubierta vegetal (i.e. altura, fracción de cubierta vegetal, presencia de vegetación seca, etc.). Se repartieron los diferentes campos entre los grupos y se muestrearon durante los días que duró la campaña. En todos los casos, se utilizó una máscara de 90° para evitar la posible influencia del operador en la radiación difusa.

## II.2.2 Cámara hemisférica

Las características de adquisición de las DHP son relativamente sencillas, sin embargo hay que tener en cuenta diferentes consideraciones y fuentes de error a la hora de adquirir la imagen. Las recomendaciones más destacadas se pueden clasificar según tres aspectos, (i) las características de la cámara, (ii) los factores externos y, por último, (iii) la altura de la cubierta (ver tabla II.4).

En general, cuanto mejor sea su resolución, las condiciones de brillo y compresión de la imagen, mejor será la calidad de la imagen y mejor será la separación espectral de los diferentes elementos que componen la cubierta como vegetación verde, seca, suelo y píxeles mezcla. En cuanto a la elección entre el modo de posición de la cámara, éste depende principalmente del tipo de cubierta (ver tabla II.5). Las imágenes adquiridas en modo *upward* son más fáciles de procesar debido al contraste entre cielo y vegetación (Jonckheere et al 2004), aunque es preferible evitar las horas donde el ángulo cenital solar es menor ya que la iluminación directa puede saturar algunas zonas de la imagen (Chen et al 1996). Sin embargo, en el caso de cubiertas muy densas, las imágenes realizadas en modo *downward* pueden perturbar la arquitectura de la cubierta al introducir la cámara en el interior de la cubierta. Por otra parte, se recomienda en las cubiertas bajas situar la cámara cerca de la cubierta para evitar que aparezcan en la imagen elementos muy lejanos situados a ángulos muy extremos. En este caso, los problemas debidos al campo de observación se pueden resolver limitando el campo de visión a un ángulo entre 0° y 60° grados.

Durante la campaña se dispuso de dos cámaras digitales, la NIKON Coolpix5000 y Coolpix45000 equipadas con una lente ojo de pez NIKON FC-E8. Las cámaras NIKON Coolpix 5000 y 45000 son capaces de captar imágenes con la más alta precisión con un tamaño de 2560 x 1920 y 2272 x 1704 píxeles, respectivamente. El zoom óptico, 3x, ofrece un rango focal de 7.1-21.4mm (i.e. equivalente a 28-85mm en el formato de 35mm). El zoom digital proporciona hasta 4 aumentos. Ambas lentes responden a una función de proyección polar donde el ángulo que forma dicho objeto con el eje óptico de la lente es directamente proporcional al radio de ese punto en la imagen (Frazer et al 2000).

Ambas cámaras se seleccionaron en el modo de alta resolución, con formato de las imágenes en modo JPG y factor de compresión medio proporcionando un tamaño de imagen aproximadamente de 1MB. La cámara se seleccionó en el modo automático y en alguna ocasión se modificaron los niveles de brillo debido a que la cubierta presentaba muchas sombras principalmente por las condiciones de iluminación.

**Tabla II.4.** Recomendaciones de adquisición según las características de la cámara, los factores externos y características de la cubierta.

| <b>Características de la cámara</b>             |  |
|---|--|
| <i>Resolución de la imagen</i>                  | Alta resolución (>1Megapíxel): permite discriminar mejor elementos pequeños de la vegetación y evitar los píxeles mezcla (Blennow 1995)                          |
| <i>Sensibilidad de la imagen</i>                | Alta sensibilidad: permite una mejor clasificación de la imagen.   |
| <i>Índice de compresión de la imagen</i>        | Baja compresión: una alta compresión de la imagen se traduce en un deterioro de la imagen y por tanto en pérdida de la información (Pennebaker & Mitchell 1993). |
| <b>Factores externos</b>                        |  |
| <i>Iluminación</i>                              | Las imágenes de una misma unidad deben ser tomadas en condiciones similares de iluminación para que no haya una gran variación en el color de las imágenes.      |
| <i>Horizontalidad</i>                           | La cámara se debe colocar lo más horizontalmente posible para que la adquisición sea desde el nadir (Walter & Torquebiau 2000).                                  |
| <i>Orientación de la cámara</i>                 | Es aconsejable localizar la posición de la cámara y del Sol para la estimación de diferentes parámetros relacionados con el régimen de radiación y el FAPAR.     |
| <i>Posición del operador</i>                    | El operador debe situarse siempre en la misma posición para poder enmascarar la misma zona de la imagen y no incluirla en la estimación.                         |
| <b>Características de la cubierta</b>           |  |
| <i>Cubiertas bajas (&lt;30 cm)</i>              | La cámara se sitúa en modo <i>downward</i> a una altura cercana a la cubierta para poder distinguir mejor el suelo de fondo.                                     |
| <i>Cubiertas intermedias (entre 30 y 70 cm)</i> | La cámara puede situarse tanto en modo <i>downward</i> como <i>upward</i> .  |
| <i>Cubiertas altas (&gt; 70 cm)</i>             | La cámara se sitúa en modo <i>upward</i> .   |

### II.3 Procesado de los datos

El procesado de los datos resulta más sencillo en el caso del LICOR LAI2000 que de las DHPs. El LICOR es un instrumento portátil que no requiere de la adquisición

de información adicional para el procesado de la *gap fraction*, y que estima de forma inmediata el LAI de una cubierta a partir de medidas simultáneas de la radiación difusa. Por otra parte, las DHPs precisan de mayor tiempo de procesado de las imágenes e intervención por parte del usuario para la estimación de los parámetros. A continuación se describen los diferentes parámetros que se estiman al procesar los datos.

### II.3.1 LICOR LAI2000

La estimación del LAI se realiza internamente en el LICOR teniendo en cuenta tres consideraciones importantes, (i) la superficie foliar se comporta como un cuerpo negro que absorbe toda la radiación que recibe, (ii) los componentes de la cubierta (i.e. hojas) se distribuyen aleatoriamente, y (iii) los componentes de la cubierta son pequeños en comparación con el área observada por cada anillo que compone el sensor.

El LAI que se obtiene corresponde a un LAI efectivo, puesto que las hipótesis realizadas para estimarlo suponen que las hojas se distribuyen aleatoriamente. Los parámetros que proporciona el LICOR LAI2000 son el LAI medio de las diferentes medidas realizadas en una ESU, el error estándar del LAI estimado (SEL), la radiación difusa no absorbida en el rango de longitud de onda corta (DIFN), el ángulo medio de inclinación de las hojas (MTA), el error estándar del MTA (SEM), el número de pares de observaciones que se han incluido en el cálculo (SMP). Por último, es posible obtener la *gap fraction* estimada en los cinco (tabla II.5).

**Tabla II.5.** Parámetros proporcionados por el LICOR LAI2000

| Parámetro | Descripción   |
|-----------|---|
| SEL       | Error estándar para el valor de LAI estimado.   |
| DIFN      | Radiación difusa no absorbida en el rango de longitud de onda corta (<490 nm). La DIFN considera que no existe dispersión en el interior de la cubierta.  |
| MTA       | Ángulo medio de inclinación de las hojas. Si las hojas se distribuyeran horizontalmente, $MTA=0^\circ$ , y si lo hicieran verticalmente, $MTA=90^\circ$ . |
| SEM       | Error estándar del MTA.   |
| SMP       | El número de pares de observaciones utilizado en los cálculos.  |

Además del LAI, también se ha ensayado con una estimación aproximada de la FVC a partir de la *gap fraction* obtenida por el sensor situado en el ángulo cenital de  $7^\circ$ , dado que es el que proporciona la observación más cercana al nadir. La FVC se obtiene restándole a la unidad la  $P_0(7^\circ)$ , la cual se comparará con la estimada a partir de las fotografías hemisféricas. No es posible estimar la FAPAR puesto que

el LICOR LAI2000 no proporciona una estimación continua de la *gap fraction* con el ángulo cenital y, por tanto, no es posible conocer la *gap fraction* estimada bajo el ángulo cenital solar.

### II.3.2 Cámara hemisférica

Aunque existen varios programas desarrollados para procesar este tipo de imágenes, todos ellos presentan la desventaja de un alto requerimiento computacional y de no permitir procesar más de una imagen a la vez. En nuestro caso, se ha utilizado el programa CAN\_EYE diseñado por el grupo de INRA-CSE en Avignon. El programa se ha desarrollado en el contexto del proyecto VALERI, dada la necesidad de un algoritmo que estimara diferentes parámetros biofísicos y estructurales de la cubierta que otros programas no estiman (e.g. LAI, FVC, FAPAR, *clumping* y ALA), permitiera el procesamiento de imágenes adquiridas tanto en modo *upward* como *downward* y, sobre todo, presentara un tiempo óptimo computacional. Durante la realización de este trabajo, el programa CAN\_EYE ha estado en fase de desarrollo y nuestro grupo ha colaborado, como *beta-user*, en encontrar errores del programa o proponer mejoras a partir del procesamiento de las imágenes adquiridas durante SPARC'03. Uno de los estudios en los que se ha participado ha sido la evaluación del programa frente a la influencia del usuario en la estimación de los parámetros. Para ello, el grupo de INRA y el nuestro procesamos el mismo conjunto de datos y, posteriormente, se compararon los resultados. El resultado de este estudio se presenta en el siguiente capítulo (Sección III.3).

#### II.3.2.1 Programa CAN\_EYE

El programa se ha diseñado en el entorno Matlab © y presenta la posibilidad de procesar hasta 20 imágenes, así como también analizar la *gap fraction* bidireccional y monodireccional en un rango cenital y acimutal determinado, lo que permite seleccionar la resolución angular a la que se desea estimar dichas variables. El tiempo medio de procesamiento de 12 imágenes es de aproximadamente 10 minutos, en un ordenador con 2 procesadores de 1.98 GHz y 768 MB RAM.

El procesamiento realizado con CAN\_EYE se basa en una secuencia de tres etapas, (i) estimar la *gap fraction* bidireccional, (ii) integrarla acimutalmente con el fin de obtener la *gap fraction* monodireccional, y (iii) derivar los parámetros biofísicos, LAIe, LAI, ALA, FVC y *clumping*. Finalmente, la FAPAR se calcula a partir de estos parámetros haciendo uso de la ecuación  $FAPAR=1-P_0(\theta_s)$ , donde  $P_0(\theta_s)$  es la *gap fraction* para la posición solar  $\theta_s$ .

El procesamiento comienza introduciendo una serie de parámetros referentes al tamaño de las imágenes, como radio de la imagen hemisférica, rango cenital para calcular el LAI, entre otros (ver figura II.7). Posteriormente, se cargan las imágenes y se seleccionan aquellas que se quieren procesar. Una vez seleccionadas, se reduce

el número de colores de las imágenes para disminuir el tiempo de procesamiento y se aplican diferentes técnicas de tratamiento de la imagen como por ejemplo, enmascarar aquellas zonas que no queremos incluir, aplicar contrastes de brillo para eliminar zonas muy oscuras o localizar en la imagen el ángulo cenital solar o el norte magnético. La disminución del número de colores no se realiza de forma lineal sino que se pone mayor énfasis en los valores bajos para proporcionar una mejor discriminación de las sombras.



**Figura II.7.** Descripción de los pasos seguidos por el programa CAN\_EYE para procesar las fotografías hemisféricas.

El siguiente paso consiste en la segmentación de las imágenes, el cual es el paso más crítico debido a que el resultado es dependiente del criterio que escoja el usuario para distinguir las diferentes clases. El proceso de segmentación consiste en elegir un número de clases (es preferible seleccionar sólo dos) y asignar colores a cada una de ellas, bien desde la propia imagen o a partir de una paleta de colores que se genera automáticamente. El CAN\_EYE incluye la herramienta del *convex hull* (Barber et al 1996) para realizar la segmentación. El *convex hull* de un determinado conjunto de datos se define como la mínima región convexa que incluye a todos los datos del conjunto. De este modo, en primer lugar, se asocia un determinado conjunto de píxeles a cada clase y se calcula el *convex hull* en el espacio RGB para cada clase. El resto de los píxeles de la imagen se clasifican dentro de una determinada clase si al representarlos en el espacio RGB se incluyen dentro de la región convexa definida para esta clase.

Posteriormente, se estima la *gap fraction* bidireccional media y se integra acimutalmente para obtener la *gap fraction* monodireccional de acuerdo a la resolución que elija el usuario (e.g. 5°, 10° y 15°). A partir de ella, se deriva el LAIe, el LAI real, el LAI interpolado en la dirección de observación de 57.5°, la FVC, la FAPAR para el ángulo cenital solar y el *clumping* de la cubierta. A continuación se describe con mayor detalle la estimación de estos parámetros.

## LAI

El LAI y el ALA se calculan a partir de la inversión del modelo de Poisson (Ec. [I.1]) utilizando la técnica de inversión Look-Up-Table y la *gap fraction* integrada en el rango cenital [0°-90°]. El modelo de Poisson en el que se basa el CAN\_EYE incluye la función de proyección,  $G(\theta_v, \varphi_v)$ , definida según la expresión [A.5] y una función de densidad de probabilidad,  $g(\theta_l, \varphi_l)$ , que depende sólo del ángulo cenital a la normal de la superficie foliar. De este modo,  $g(\theta_l, \varphi_l)$  se puede caracterizar a partir de un solo parámetro, el ángulo medio de inclinación de las hojas (Campbell 1990, Wang & Jarvis 1988, Campbell 1986).

El procedimiento consiste en crear una base de datos de la *gap fraction* estimada a partir de la combinación de diferentes valores de LAI y ALA. La simulación corresponde a 50000 casos de *gap fraction* resultantes de una distribución aleatoria de valores de LAI entre [0-9] y ALA entre [0°-90°]. El valor de LAI y ALA estimado a partir de la *gap fraction* derivada de las imágenes corresponde al valor medio de los 200 pares (LAI, ALA) que menor valor de  $C_i$  presente. El parámetro  $C_i$  se define como:

$$C_i = \sqrt{\sum_i w_i (P_{LUT}^i - P_{medido}^i)^2} ; w_i = \frac{N_{pix}^i - N_{mas}^i}{N_{pix}^i} \quad [II.2]$$

donde el  $P_{LUT}^i$  y  $P_{medido}^i$  corresponden a la *gap fraction* obtenida de la LUT y la estimada de las fotografías hemisféricas para el anillo acimutal. El termino  $w_i$  corresponde a un peso asignado que considera el hecho de que algunos anillos presenten una proporción alta de píxeles enmascarados,  $N_{mas}^i$ , donde  $N_{pix}^i$  corresponde a los píxeles totales en cada anillo a acimutal.

Además del LAI derivado de esta manera, el programa también proporciona el LAI estimado considerando sólo la *gap fraction* en la dirección cenital de 57.5° según la expresión siguiente:

$$LAI(57.5^\circ) = \frac{\log(57.5^\circ)}{-0.93} \quad [II.3]$$

El algoritmo utilizado para determinar el valor del LAI a un ángulo de 57.5° es una simplificación del modelo de Poisson, dado que supone que la función de proyección foliar  $G(\theta_v, \varphi_v)$  para dicho ángulo es independiente del ángulo de

inclinación de las hojas y por tanto se puede aproximar a un valor constante ( $G \approx 0.5$ ) (Warren-Wilson 1960, 1963; Jonckheere et al 2004). Bonhomme et al. (1974) aplicaron esta técnica en cultivos a partir de la medida de la *gap fraction* y encontraron buenas correlaciones entre el LAI real y el estimado.

### FVC

La fracción de cubierta vegetal se obtiene restándole a la unidad la *gap fraction* estimada en el nadir,  $P_0(0)$ , tal como se ha descrito en el apartado I.5. El CAN\_EYE, permite la posibilidad de integrar la *gap fraction* en un rango cenital. Dado que la  $P_0(0)$  sería el valor de un único píxel, se ha utilizado la *gap fraction* integrada en el rango cenital entre  $[0^\circ-10^\circ]$  para estimar la FVC según la expresión siguiente:

$$FVC = 1 - P_0(0^\circ-10^\circ) \quad \text{[II.4]}$$

### FAPAR

La FAPAR en el momento de la medida *in-situ* se obtiene aproximándola a la radiación incidente fotosintéticamente activa (FIPAR) según la siguiente expresión:

$$FAPAR(\theta_s) \approx FIPAR(\theta_s) = 1 - P_0(\theta_s) \quad \text{[II.5]}$$

donde  $P_0(\theta_s)$  corresponde a la *gap fraction* estimada para el ángulo cenital solar en el momento de la medida *in-situ*.

### Clumping

El *clumping* de la cubierta se obtiene según Lang et al (1991). El procedimiento consiste en segmentar la *gap fraction* bidireccional en celdas de  $5^\circ \times 5^\circ$ , en la dirección cenital y acimutal, de modo que en cada celda se supone valido el modelo de Poisson (i.e. distribución aleatoria de las hojas).

En primer lugar, se estima la *gap fraction* en cada celda y se obtienen las diferentes combinaciones de ALA recogidas en la LUT para dicha *gap fraction*. En segundo lugar, se calcula el logaritmo de la *gap fraction* para los diferentes valores de ALA, en el caso de una *gap fraction* igual a cero se considera un LAI de saturación igual a 10 y entonces se calcula la *gap fraction* con diferentes valores de ALA. Finalmente, el *clumping* se calcula como la razón entre el logaritmo ( $P_0$ ) y  $P_0$  integrado en el anillo acimutal. Esto proporciona un valor del *clumping* en función del ángulo cenital de observación y del ALA. El LAI verdadero se estima posteriormente utilizando una LUT que tenga en cuenta, además del ALA, el *clumping*.

## II.4 Caracterización de LAI, FVC y FAPAR a alta resolución

Como se ha comentado anteriormente, la caracterización a alta resolución de los parámetros LAI, FVC y FAPAR se realiza en la metodología propuesta mediante, (i) la técnica de regresión por mínimos cuadrados (OLS) multivariada y (ii) técnicas geoestadísticas. La caracterización de dichos parámetros a alta resolución a partir de estos métodos implicará resolver una serie de cuestiones ya planteadas en el capítulo I. Por una parte se evaluarán las técnicas en la estimación de los parámetros biofísicos de interés y se realizará una intercomparación entre ellos. Por otra parte, se analizará la influencia del muestreo espacial en las estimaciones y se asociará un error a los mapas debido al muestreo. Por último, se analizarán diferentes patrones espaciales con el objetivo de evaluar qué método y muestreo proporcionan la mejor caracterización de la variable para diferentes resoluciones espaciales. A continuación se describe el procedimiento llevado a cabo con cada técnica.

### II.4.1 Técnica de regresión multivariada

La estimación de los parámetros LAI, FVC y FAPAR se lleva a cabo utilizando la ecuación I.4 y un método iterativo de mínimos cuadrados en el que se asigna un peso a cada una de las observaciones. Como variables independientes ( $X_i$ ) se han utilizado los valores de las radiancias extraídas de la imagen SPOT en la localización donde se han medido *in-situ* los parámetros biofísicos. Las bandas utilizadas pertenecen al R, G, NIR y MIR, así como también al índice de vegetación NDVI. La relación lineal encontrada entre los valores de NDVI corregidos en el techo de la atmósfera y el NDVI sin corregir ( $r=0.99$  y pendiente de 1.1) indica que el método de regresión multivariada es válido para la estimación de parámetros biofísicos a partir de valores de radiancias.

Se han escogido estas bandas para incluirlas en la función de transferencia (FT) debido a la alta correlación que presentan con el estado de la cubierta vegetal (Gates et al 1965). Esta correlación ha dado lugar a un amplio uso de estas bandas e índices de vegetación para estimar parámetros biofísicos (Brown et al 2000, Fassnacht et al 1997, Nemani et al 1993, Baret et al 1988). Las variables dependientes para cada función de transferencia son las estimaciones de LAI, FVC y FAPAR obtenidas tanto con el LICOR LAI2000 como con la cámara hemisférica.

Este método se aplicará a la zona de estudio de Barrax (i.e.  $5 \times 5 \text{ km}^2$ ) y se analizarán las diferencias entre los mapas de LAI y FVC obtenidos con las medidas derivadas de los instrumentos, LICOR LAI2000 y cámara hemisférica. Puesto que los conjuntos de datos (i.e. LICOR y DHP) se diferencian en número de ESUs y muestreo realizado, los mapas obtenidos servirán para evaluar el muestreo espacial en la estimación de parámetros biofísicos en una zona agrícola y derivar conclusiones acerca del número mínimo de ESUs necesarias para caracterizar la zona.

Por otra parte, las funciones de transferencia obtenidas para los tres parámetros se aplicarán a un área mayor (i.e. 50×50 km<sup>2</sup>) con el propósito de disponer de un mapa de referencia para realizar la validación directa de productos de baja resolución en el capítulo V. Además, se evaluará la representatividad de la función de transferencia en diferentes zonas dentro del área de 50×50 km<sup>2</sup> con presencia de cubiertas vegetales que no se incluyeron dentro de la FT.

#### II.4.2 Técnicas geoestadísticas

Con el objetivo de evaluar las técnicas geoestadísticas en la estimación de parámetro biofísicos, se han elegido tres variantes del krigado: el krigado ordinario (KO), el krigado con deriva externa (KDE) y el cokrigado colocalizado (CKC). La técnica del KO es la más sencilla de las tres, en cuanto a que no necesita información secundaria y supone un modelo de tendencia constante y no conocido en un cierto radio de vecindad. Este modelo nos parece especialmente útil para estimar a resoluciones espaciales bajas, donde prima el valor medio y no tanto los detalles y la variabilidad espacial a nivel subpixel. El algoritmo de KDE asume un modelo de tendencia no estacionario, idóneo para nuestra área de interés, y proporciona información más detallada de la variable a escalas más finas. Por último, el CKC nos permitirá evaluar la influencia de la información secundaria en la estimación de la variable primaria.

Para el KDE y el CKC, utilizaremos una variable secundaria, el parámetro NDVI derivado de la imagen SPOT. Se ha escogido este parámetro por dos razones principalmente, (i) su fácil cálculo matemático a partir de las bandas del R e IRC, y (ii) la alta correlación que presenta con el LAI, FVC y FAPAR, tal como se ha descrito en el capítulo anterior. El error introducido al utilizar información derivada de teledetección no corregida atmosféricamente se evaluará en el capítulo siguiente mediante la comparación con los mapas derivados de la FT.

Los mapas resultantes de dicha aplicación se compararán con los obtenidos por el método de regresión lineal multivariada. Al igual que en la técnica multivariada, se evaluará la influencia del muestreo espacial en las estimaciones. Dado que una de las aplicaciones de estos mapas será su uso en la validación directa de productos de baja resolución, la comparación entre técnicas se realizará para diferentes resoluciones espaciales.

Por último, se incluye un estudio más detallado de la influencia del muestreo espacial en la estimación de los mapas en el área de Barrax. La finalidad consiste en derivar conclusiones referentes al muestreo óptimo, como número de ESUs necesarias o su localización. En el caso de las técnicas geoestadísticas, se evaluará la influencia de la variable secundaria y la configuración óptima para la que se minimiza su influencia.



## CAPÍTULO III

---

---

### CARACTERIZACIÓN *IN-SITU* DE LAI, FVC Y FAPAR

---

---

*En este capítulo se presentan los resultados obtenidos en la caracterización in-situ de los parámetros biofísicos LAI, FVC y FAPAR sobre un área particular de cultivos en la zona de estudio de Barrax (Albacete), después de aplicar la metodología descrita en el capítulo II. Uno de los objetivos principales de este capítulo es evaluar dos métodos de medida, por lo que se incluye el análisis de las estimaciones realizadas mediante el LICOR LAI2000 y la cámara hemisférica. En primer lugar, se describe el muestreo espacial llevado a cabo con cada instrumento (Sección III.1) y, posteriormente, se presenta el procesado llevado a cabo para estimar los parámetros de interés (Sección III.2). También, se incluye una evaluación de la influencia del operador en el procesado de las fotografías hemisféricas con el programa CAN\_EYE (Sección III.3). Por último, se presenta la comparación entre las estimaciones obtenidas con ambos instrumentos (Sección III.4) y se detallan las principales conclusiones que se derivan de este capítulo (Sección III.5).*

Una vez descrito el experimento y la metodología a seguir en la zona de estudio, se presenta en este capítulo los resultados de la caracterización *in-situ* realizada durante la campaña de campo SPARC'03. Tal como se ha comentado en los dos capítulos anteriores, dicha caracterización consta de diferentes pasos (i.e. elección de la variable a caracterizar, instrumentos utilizados, diseño del muestreo espacial, etc.), donde el muestreo espacial es uno de los pasos más crítico. El muestreo espacial es complicado en cuanto que debe caracterizar la variabilidad mostrada en el área y considerar, además de los factores descritos en el capítulo I (i.e. áreas de muestreo, dimensiones de la ESU, etc.), otros factores externos a esta, como son el número de personas e instrumentos disponibles para medir, la duración de la campaña de campo, horas óptimas de medida, etc.

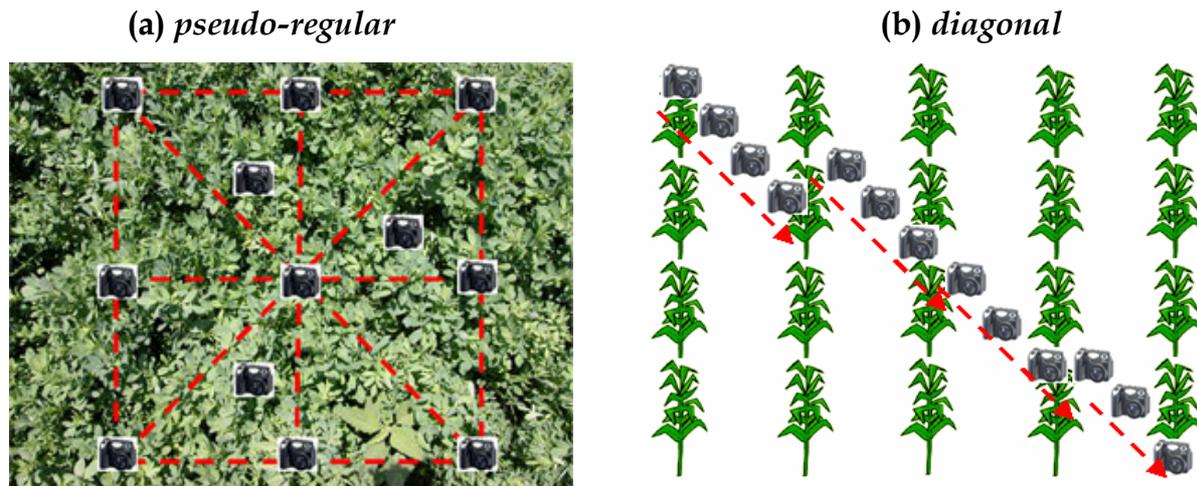
### III.1 Muestreo espacial

El muestreo realizado por ambos instrumentos adoptó el criterio común de caracterizar lo mejor posible la variabilidad presente en la zona de estudio, es decir, tanto la descrita por todo el conjunto de cultivos de la zona como la mostrada dentro de cada campo. Tal como se ha descrito en el capítulo I, el diseño requiere decidir una serie de aspectos importantes para obtener un conjunto de medidas que caractericen correctamente la variabilidad de la zona, como las zonas de estudio, las dimensiones de la ESU, su localización y número necesarias.

El muestreo espacial que se realizó dentro de cada ESU con ambos instrumentos fue ligeramente diferente, debido principalmente a que se disponía de un mayor número de instrumentos LICOR (5 LICOR frente a 2 cámaras) y a las diferencias en el funcionamiento de ambos instrumentos, lo que permitía adquirir el doble de medidas con el LICOR en el mismo tiempo. El muestreo llevado a cabo con la cámara hemisférica se basa en criterios similares utilizados por el proyecto de validación VALERI (Baret et al 2005a). Las dimensiones de la ESU correspondía a un área de 20×20 m<sup>2</sup> (aproximadamente el área de un píxel SPOT), donde la posición central se georeferenciaba con un GPS.

Con la cámara hemisférica se realizaron 12 medidas en cada ESU distribuidas según los esquemas de la figura III.1, lo que nos proporciona el valor promedio del parámetro biofísico en dicha área. El esquema de la figura III.1a (*pseudo-regular*) se aplicó en aquellos cultivos que presentaban una distribución homogénea, como la Alfalfa, la Remolacha y el Maíz, mientras que el diseño de la figura III.1b (*diagonal*) se aplicó en aquellos cultivos distribuidos por filas, como era el caso de la Viña, para caracterizar la variabilidad presente en la cubierta determinada por la distribución de las plantas (Weiss et al 2004). En el contexto del proyecto VALERI se han analizado las diferencias en el valor medio de la ESU atribuidas a diferentes configuraciones donde se ha variado la distribución de las 12 medidas dentro de la ESU (Garrigues 2004). En este estudio se analizan diferentes combinaciones donde tres de ellas son variaciones del esquema III.1a y cuyas tres medidas alrededor del centro se distribuyen, (i) de forma simétrica, (ii) muy cerca del centro y de forma

aleatoria o (iii) muy alejadas del centro y también de forma aleatoria. Por último, analizan una cuarta configuración donde las 12 medidas se distribuyen en forma de cruz dentro de la ESU. Los resultados muestran pocas diferencias entre las varianzas asociadas a cada esquema cuando se trata de estimar mapas de alta resolución concluyendo que el muestreo dentro de cada ESU depende principalmente de las características y limitaciones que pudiera presentar el cultivo.



**Figura III.1.** Esquemas de muestreo espacial utilizado en la adquisición de medidas *in-situ*. El muestreo (a) se llevó a cabo en aquellos cultivos que presentaban una distribución homogénea mientras que el muestreo (b) se aplicó en los cultivos que presentaban una distribución por filas.

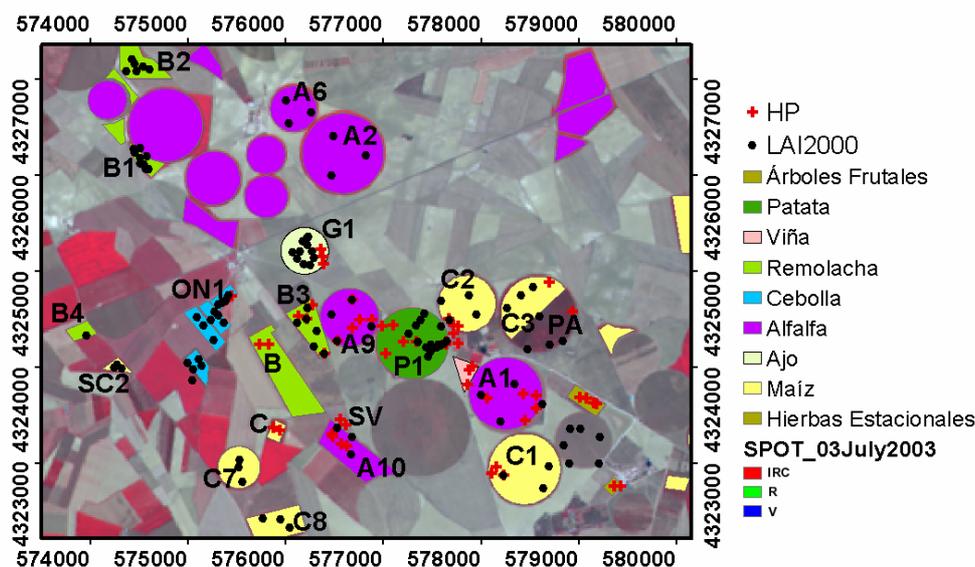
Por otra parte, el muestreo llevado a cabo con el LICOR LAI2000 dentro de cada ESU fue diferente. En este caso, cada ESU, también con dimensiones aproximadas de 20×20 m<sup>2</sup>, se caracterizó a partir de 24 medidas, 3 sobre la cubierta por 8 debajo de la cubierta, distribuidas de forma aleatoria en la superficie de la ESU.

Una vez definido el muestreo en una ESU, el siguiente paso consiste en caracterizar la heterogeneidad existente en los diferentes cultivos. Para ello, se trató de obtener, para ambos instrumentos, un mínimo de 12 ESUs por cultivo con el objetivo de proporcionar valores de la media y desviación estándar estadísticamente fiables (Huber 1981, Steel & Torrie 1980). En general, el número de ESUs por campo fue mayor para los cultivos con un número menor de campos. La localización de las ESUs en cada campo se realizó de forma aleatoria, pero evitando siempre los bordes de los cultivos. Con el LICOR LAI2000 se realizaron medidas en 100 ESUs correspondientes a 6 cultivos (ver tabla III.1). Sin embargo, con la cámara hemisférica el número de ESUs fue inferior (53), pero mayor el de cultivos muestreados (9), lo que reduce la significación estadística por cultivo. Se caracterizaron un total de 9 tipos cultivos, obteniéndose un rango de valores de LAI entre 0 y 6, de FVC entre 0 y 100%, y de FAPAR entre 0 y 1, los cuales cubren todo el rango de valores posibles (Jonckheere et al 2004).

**Tabla III.1.** Descripción de las ESUs adquiridas por cada instrumento y de los campos muestreados para cada cultivo.

| Cultivo          | Campos    | ESUs LICOR | Campos    | ESUs DHP  |
|------------------|-----------|------------|-----------|-----------|
| Maíz             | 7         | 21         | 4         | 10        |
| Alfalfa          | 6         | 19         | 3         | 16        |
| Remolacha        | 4         | 19         | 1         | 6         |
| Cebolla          | 2         | 16         | 2         | 2         |
| Ajo              | 1         | 11         | 1         | 2         |
| Patata           | 1         | 14         | 1         | 6         |
| Viña             | 0         | 0          | 1         | 1         |
| Hierba           | 0         | 0          | 1         | 6         |
| Árboles frutales | 0         | 0          | 2         | 2         |
| <b>TOTAL</b>     | <b>21</b> | <b>100</b> | <b>16</b> | <b>53</b> |

La figura III.2 muestra la localización de las medidas en la zona de estudio sobre la imagen SPOT. Las cruces rojas corresponden a las ESUs adquiridas con la cámara hemisférica y los puntos negros a las ESUs medidas con el LICOR LAI2000. Sobre la imagen se ha representado información sobre el uso del suelo recogida durante la campaña de campo. Las etiquetas asignadas a cada campo identifican los diferentes cultivos de la zona, Alfalfa (A), Maíz (C), Patata (P), Remolacha (B), Ajo (G), Cebolla (ON), Dormidera (PA) y Vegetación dispersa (SV). Los cultivos donde se realizaron medidas con ambos instrumentos fueron tres campos de Alfalfa (A1, A9 y A10), dos de Maíz (C1 y C2) y uno de Patata (P1), Ajo (G1), Remolacha (SB3) y Cebolla (ON1). En la figura III.3 se muestran algunas fotografías hemisféricas de los cultivos caracterizados durante este experimento.



**Figura III.2.** Unidades Elementales de Medida (ESUs) adquiridas por la cámara hemisférica (cruces) y por el LICOR LAI2000 (puntos) sobre el área de estudio. La imagen de fondo corresponde a la composición RGB de las bandas NIR, R y G.



**Figura III.3.** Imágenes hemisféricas adquiridas en los cultivos más representativos del área de estudio durante la campaña de SPARC'03. Las imágenes de la fila inferior corresponden a los mismos cultivos de arriba adquiridos con la cámara en modo *downward* para los cultivos de Remolacha, Maíz, Patata, Alfalfa y Ajo.

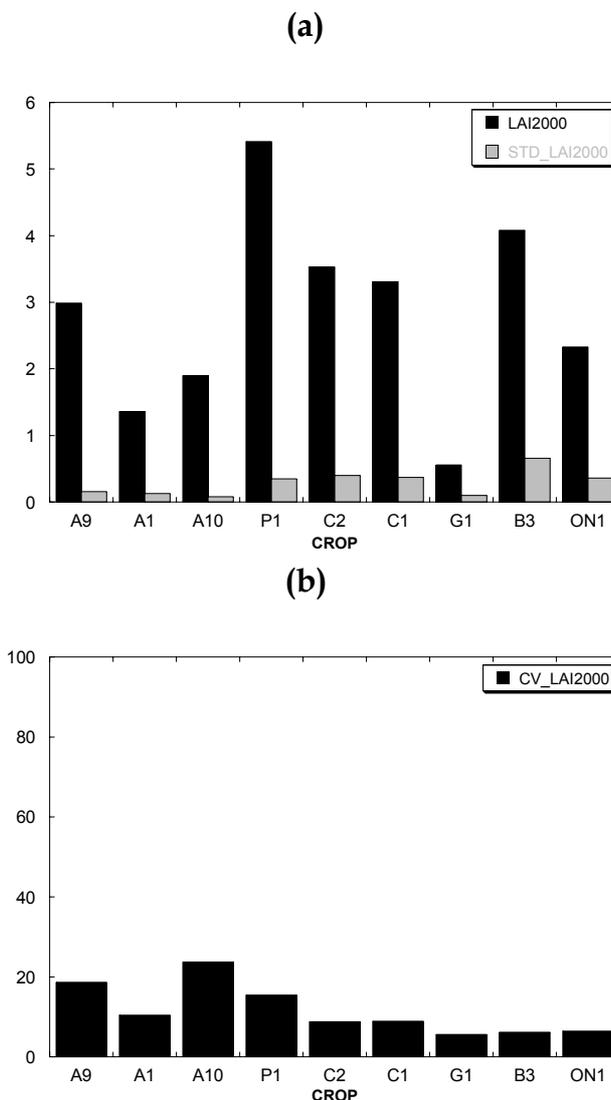
## III.2 Procesado de los datos

Dado que el LICOR LAI2000 estima el LAI en el mismo momento de su adquisición, no es necesario realizar ningún procesado posterior a la adquisición para estimar lo. Por otra parte, sí que sería necesario trabajar con los valores de la *gap fraction* en caso de que se quisieran obtener otros parámetros relacionados con la vegetación, como podría ser la FVC o el FAPAR. En el caso de los datos obtenidos con la cámara hemisférica, es necesario llevar a cabo un procesado de las fotos para poder calcular la *gap fraction* y estimar el LAI así como demás parámetros biofísicos. A continuación se describe el procesado llevado a cabo con cada instrumento y los resultados obtenidos.

### III.2.1 LICOR LAI2000

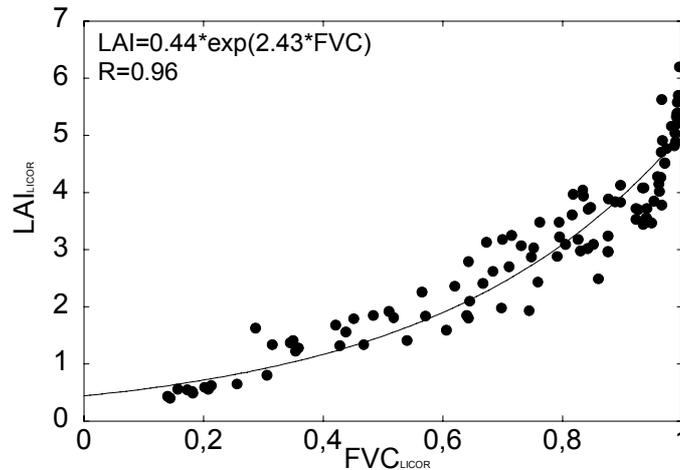
La figura III.4a muestra los valores medios junto con la desviación estándar de las medidas realizadas en los campos donde también se midió con la cámara hemisférica. Se observa, como la Patata y el Ajo son los cultivos con mayor y menor LAI respectivamente, con valores típicamente alrededor de 0.5 y 5. Las medidas con el LICOR LAI2000 reflejan la variabilidad encontrada en el cultivo de Alfalfa siendo el campo A9 el de mayor LAI y el campo A10 el más heterogéneo, tal como muestra el alto coeficiente de variación obtenido con estos datos (figura III.4b) y el estudio de heterogeneidad presentado en el apartado II.1.4. Por otra parte, el cultivo de Maíz presenta valores medios y coeficiente de variación muy

similares, reflejando la poca variabilidad que se encontraba en el campo para este cultivo, tal como muestra también el estudio de heterogeneidad del capítulo II.1.4.



**Figura III.4.** (a) Valores medios de LAI junto con la desviación estándar de las medidas realizadas en los campos donde también se realizaron medidas con la cámara hemisférica, Alfalfa (A9, A1 y A10), Patata (P1), Maíz (C2, C1), Ajo (G1), Remolacha (B3) y Cebollas (ON1). (b) Coeficientes de variación para esos campos.

Respecto a la FVC obtenida a partir del LICOR LAI2000, este parámetro se ha estimado utilizando la *gap fraction* medida por el sensor situado a 7° y aplicando la expresión descrita en el apartado I.5. La figura III.5 muestra los valores de LAI estimados por el LICOR LAI2000 respecto a la FVC, donde se observa una relación exponencial, tal como era de esperar, con un coeficiente de correlación cercano a la unidad (0.96). El rango de variación de FVC oscila entre 0.1 y 1, donde los valores altos corresponden a los campos de mayor LAI como la Patata y Remolacha. Por otra parte, los campos con menor FVC coinciden con el Ajo y la Cebolla, tal como se observó experimentalmente.



**Figura III.5.** Relación entre el LAI y la FVC estimados a partir del LICOR LAI2000. El comportamiento entre ambas variables se ha ajustado a una relación exponencial con un coeficiente de correlación  $r=0.96$ .

### III.2.2 Cámara digital hemisférica

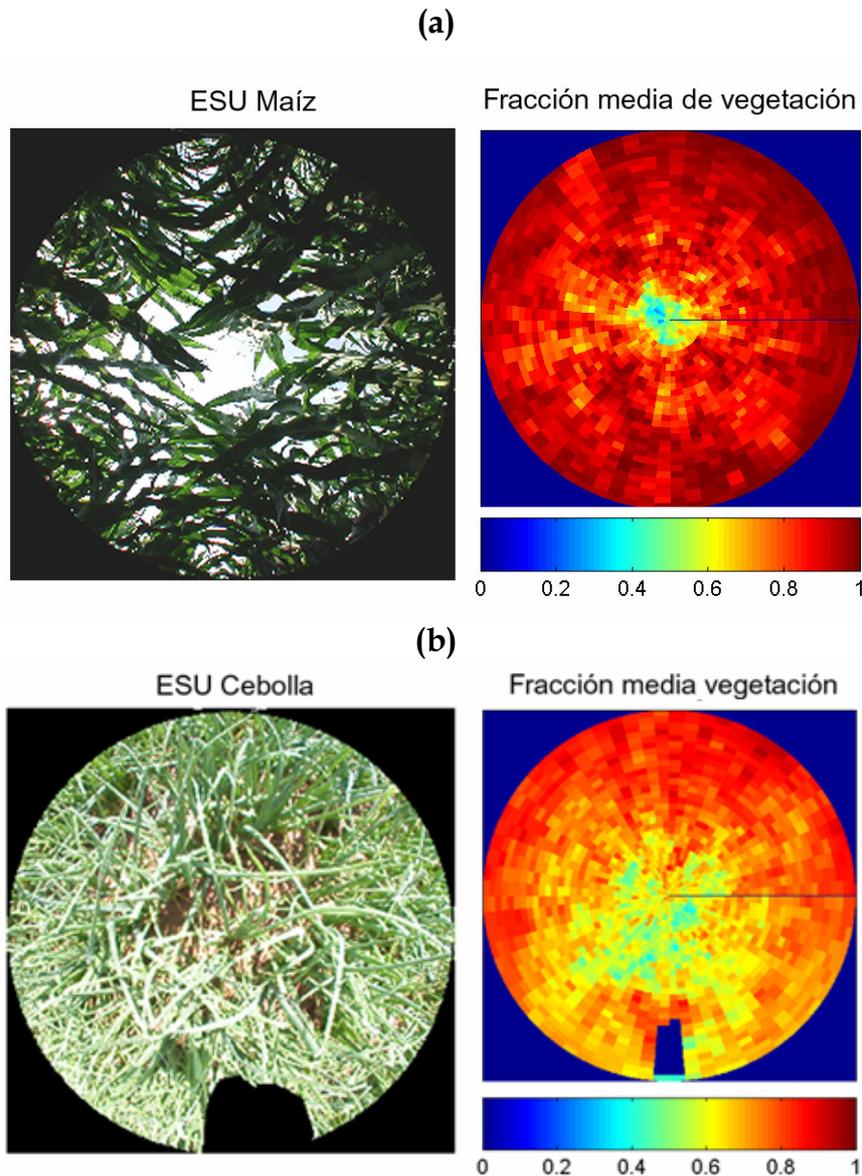
El procesado de las fotografías hemisféricas se ha basado en tres etapas secuenciales, (i) estimar la *gap fraction* bidireccional, (ii) integrarla acimutalmente con el fin de obtener la *gap fraction* monodireccional, y (iii) derivar los parámetros biofísicos LAI, FVC, FAPAR y el *clumping index* aplicando un algoritmo de inversión.

#### *Gap fraction* bidireccional

La *gap fraction* bidireccional proporciona información sobre la distribución de los huecos y, por tanto, sobre la proporción de vegetación observada en el hemisferio. La figura III.6 muestra la fracción de vegetación media (que se obtiene promediando las 12 imágenes hemisféricas clasificadas) de dos ESUs correspondientes a Maíz y Cebolla. En ambos casos se observa una mayor fracción de huecos (colores azulados) alrededor del nadir (centro de la imagen), huecos que van desapareciendo a medidas que el ángulo cenital aumenta (radios exteriores de la imagen), efecto conocido como *gap effect* (Camacho-de Coca et al 2003). Este efecto es más marcado en el caso del Maíz debido a la altura de la plantas.

A partir de la segmentación de la *gap fraction* bidireccional en celdas de  $5^{\circ} \times 5^{\circ}$ , en la dirección cenital y acimutal, se estima el *clumping* en función del ángulo cenital de observación y del ALA. La tabla III.2 muestra algunos ejemplos donde se ha obtenido el LAI corregido del *clumping* (Ec. [I.2]). En general, se observan valores más altos para el LAI corregido, como era de esperar, puesto que la fracción de radiación interceptada por la cubierta es mayor. Las diferencias más importantes entre éste LAI y el afectado por *clumping* (LAI<sub>e</sub>) se observan para los cultivos de Patata, Maíz y Alfafa. El LAI corregido de la Patata es dos veces mayor que el LAI<sub>e</sub>, aproximándose a las estimaciones del LAI derivadas por un método

destruccion durante la campaña de campo. El LAI obtenido a partir de este método fue de 7.34, el cual se calculó a partir del factor de biomasa fresca de una hoja por unidad de área y aplicándolo a la biomasa fresca de un conjunto de siete plantas de Patata. Los cultivos menos afectados por este efecto son la Remolacha, el Ajo, la Cebolla y la Hierba. En ellos la corrección del efecto *clumping* fue menor del 26%.



**Figura III.6.** Fracción media de vegetación en función del ángulo de observación cenital y azimutal para las ESUs de Maíz y Cebolla. En cada ejemplo, la imagen de la izquierda muestra una de las 12 fotografías adquiridas dentro de la ESU y la imagen de la derecha muestra la fracción media de vegetación de las 12 imágenes que componen la ESU.

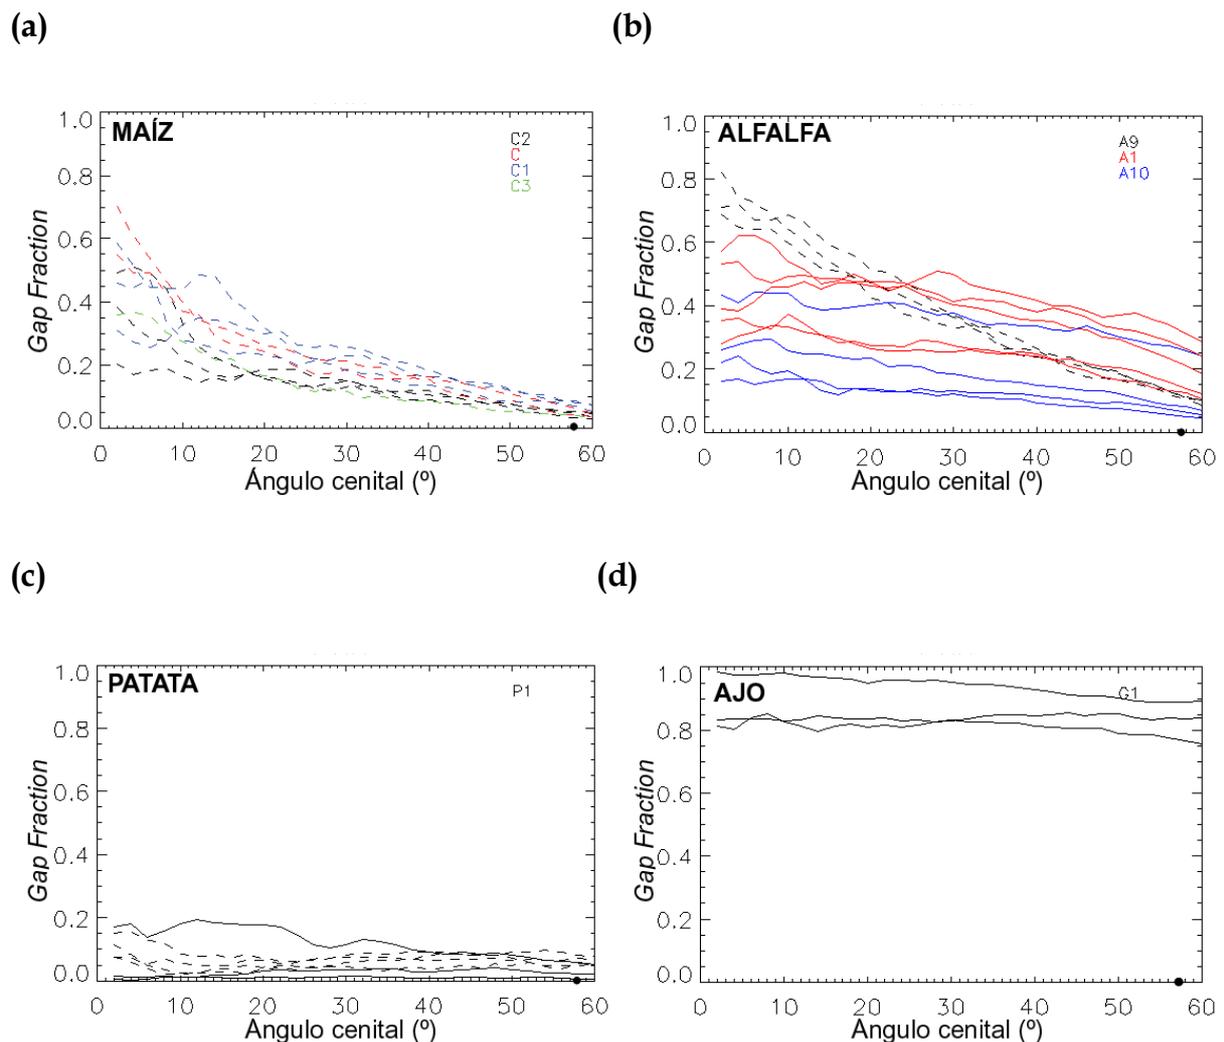
**Tabla III.2.** LAI corregido del efecto de acoplamiento de los elementos de la cubierta y LAI efectivo para algunas de las ESUs presentes en la zona de estudio.

| Campo     | ESU | LAI <sub>e</sub> | Clumping | LAI  |
|-----------|-----|------------------|----------|------|
| Patata    | P1  | 2.60             | 0.45     | 5.79 |
| Alfalfa   | A9  | 2.30             | 0.61     | 3.76 |
| Maíz      | C2  | 3.10             | 0.65     | 4.80 |
| Ajo       | G1  | 0.20             | 0.74     | 0.27 |
| Remolacha | B3  | 5.60             | 0.93     | 6.00 |
| Alfalfa   | A10 | 3.80             | 0.83     | 4.60 |
| Cebolla   | ON1 | 2.30             | 0.88     | 2.60 |
| Hierba    | GR  | 2.50             | 0.96     | 2.60 |
| Maíz      | C1  | 2.70             | 0.60     | 4.50 |

### *Gap fraction* monodireccional

La figura III.7 muestra la *gap fraction* monodireccional para los cultivos más representativos del área de estudio en función del ángulo cenital de observación. Las líneas de un mismo color representan las ESUs de un mismo campo, mientras que el trazo de las líneas refleja el modo de adquisición de las imágenes: discontinua en el caso de que la imagen se haya adquirido en modo *upward*, (e.g. Ajo), y continua cuando la imagen se ha adquirido en modo *downward* (e.g. Maíz).

La figura III.7 pone de manifiesto que la variación de la *gap fraction* con el ángulo cenital de observación depende de las características estructurales de la cubierta vegetal. Así, las cubiertas más densas (i.e. Patata) y las más dispersas (i.e. Ajo) presentan poca variación de la *gap fraction* con el ángulo cenital en el intervalo considerado [0-60°]. Sin embargo, las cubiertas con vegetación intermedia-alta (e.g. Maíz y Alfalfa) presentan una variación muy importante, con diferencias de hasta el 60%. Podemos también apreciar diferencias significativas entre la adquisición realizada con ambos modos de adquisición (e.g. Alfalfa). En general, se ha obtenido una mayor significación de los resultados obtenidos en modo *upward* con las estimaciones del LICOR como se demuestra más adelante. Este hecho debe ser especialmente tenido en cuenta en campañas posteriores.



**Figura III.7.** *Gap fraction* monodireccional para los cultivos más representativos del área de estudio en función del ángulo cenital de observación, Maíz (C), Alfalfa (A), Patata (P) y Ajo (G). La línea discontinua se refiere a las imágenes adquiridas en modo *upward* y la línea continua a las adquiridas en modo *downward*.

Por otra parte, es posible extraer información sobre la heterogeneidad del cultivo a partir de la *gap fraction* estimada para cualquier ángulo cenital, y en concreto para el ángulo cenital de 57.5°. En el caso de la Alfalfa, la variabilidad mostrada por la *gap fraction* para este ángulo pone de manifiesto la diferencia en la distribución espacial de la cubierta observada experimentalmente en los tres campos (A9, A1 y A10). De forma opuesta, la poca variabilidad de la *gap fraction* para este ángulo en el caso del cultivo del Maíz refleja la similitud en la distribución espacial de los tres campos observada experimentalmente.

### Estimación de LAI, FVC y FAPAR

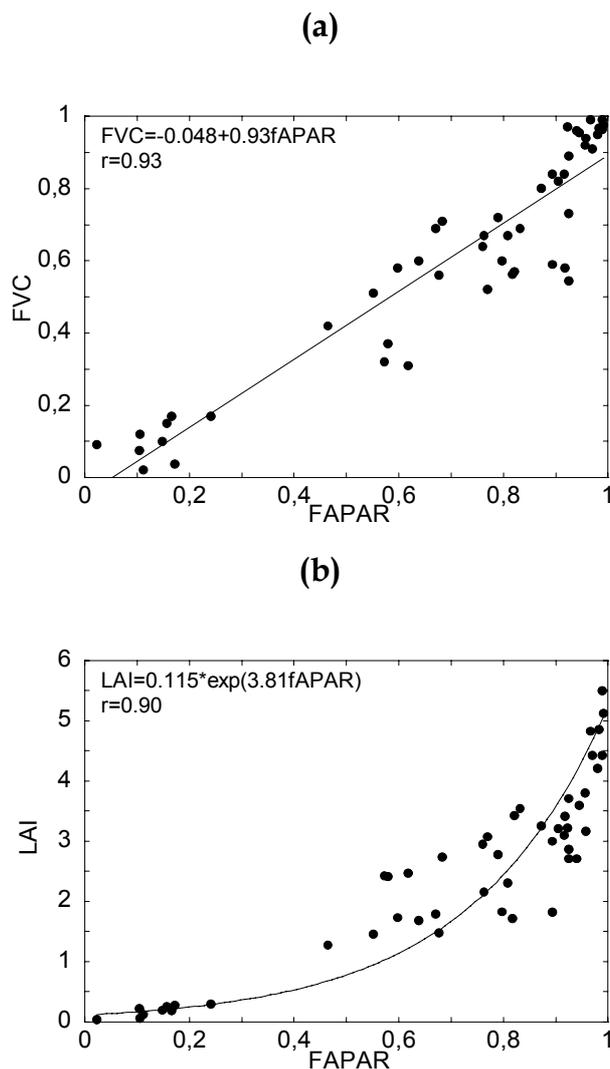
La tabla III.3 muestra el valor medio, la desviación estándar y coeficiente de variabilidad del LAIe, FVC y FAPAR obtenidos a partir de la *gap fraction* monodireccional para cada campo. Dado que el LICOR LAI2000 proporciona una estimación del LAI efectivo, utilizaremos el LAIe estimado mediante el método de la DHP para poder comparar todos los resultados y mapas que se deriven en adelante. De este modo nos referiremos, a partir de ahora, al LAIe como LAI.

Los resultados muestran una buena correspondencia con los valores esperados y con los obtenidos a partir del NDVI en el capítulo II. Por ejemplo, la Patata y Remolacha aparecen como los cultivos con mayor desarrollo fenológico y mas densos, dado el alto valor medio de los tres parámetros y los valores tan bajos de la desviación estándar y coeficiente de variabilidad. Por el contrario, el cultivo del Ajo muestra ser el menos denso y con mayor variabilidad. Por otra parte, las estimaciones realizadas con la cámara digital también reflejan la variabilidad del cultivo de Alfalfa a partir del rango de valores de LAI, FVC y FAPAR, donde el LAI y la FVC presentan diferencias de un 40% y 54%, respectivamente.

**Tabla III.3.** Valores medios, desviación estándar y coeficiente de variabilidad de los parámetros LAI, FVC y FAPAR.

| ESU | LAI ± $\sigma$ | CV <sub>LAI</sub> (%) | FVC ± $\sigma$ | CV <sub>FVC</sub> (%) | FAPAR ± $\sigma$ | CV <sub>FAPAR</sub> (%) |
|-----|----------------|-----------------------|----------------|-----------------------|------------------|-------------------------|
| A9  | 2.40±0.10      | 4                     | 0.33±0.03      | 9                     | 0.59±0.02        | 3                       |
| A1  | 1.7±0.3        | 17                    | 0.55±0.09      | 16                    | 0.72±0.18        | 25                      |
| A10 | 2.8±0.8        | 28                    | 0.73±0.12      | 16                    | 0.80±0.10        | 12                      |
| P1  | 4.0±0.9        | 22                    | 0.94±0.06      | 6                     | 0.94±0.03        | 3                       |
| C2  | 3.5±0.2        | 5                     | 0.71±0.12      | 16                    | 0.91±0.01        | 1                       |
| C1  | 2.9±0.3        | 10                    | 0.63±0.08      | 12                    | 0.79±0.13        | 16                      |
| G1  | 0.23±0.15      | 62                    | 0.17±0.09      | 52                    | 0.13±0.07        | 53                      |
| SB3 | 4.6±0.4        | 8                     | 0.95±0.03      | 3                     | 0.97±0.01        | 1                       |
| ON1 | 2.2±0.4        | 18                    | 0.63±0.05      | 8                     | 0.72±0.11        | 15                      |

Por último, con el objeto de analizar la consistencia entre los productos estimados mediante las fotografías hemisféricas, se ha buscado la relación existente entre los valores de FVC y el LAI frente a la FAPAR (figura III.8). Las relaciones encontradas entre los parámetros responden a un comportamiento lineal entre la FVC y la FAPAR. Una relación similar se ha observado en diferentes trabajos ([Turner et al 2002](#), [Myneni & Williams 1994](#)).



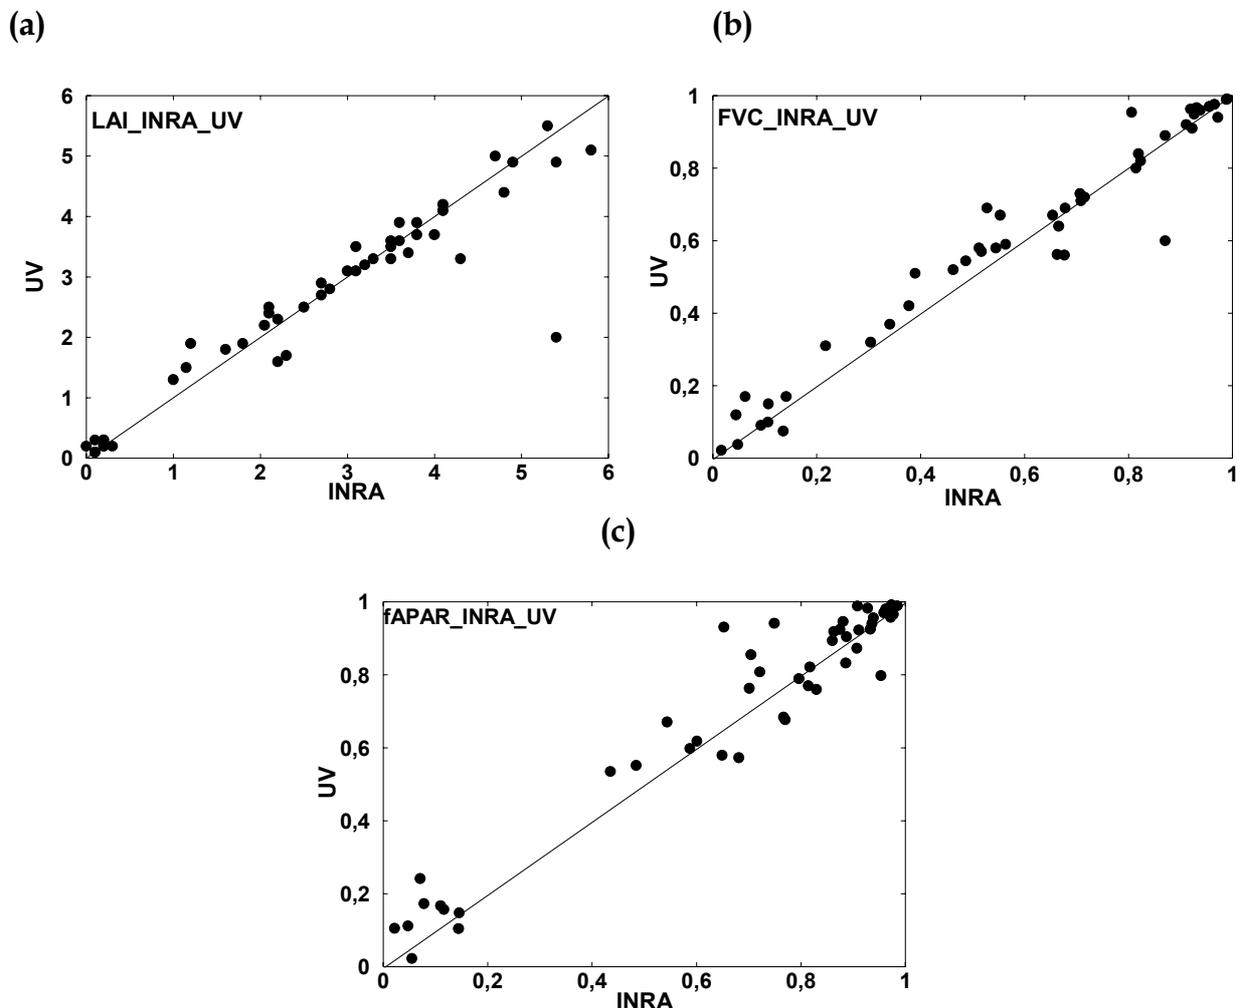
**Figura III.8.** Relación entre los parámetros LAI, FVC y FAPAR estimados a partir de la cámara hemisférica. La FVC y la FAPAR se relacionan linealmente (a) mientras que el LAI y la FAPAR lo hacen a partir de una función exponencial (b).

### III.3 Influencia del operador en el procesado de las fotografías hemisféricas

Tal como se comentó al principio, el procesado de las fotografías hemisféricas depende del criterio que se escoja para separar espectralmente los diferentes elementos que componen la cubierta (i.e. vegetación verde, seca, suelo, píxeles mezcla, etc.). Dado que el CAN\_EYE se encontraba en fase de desarrollo, realizamos una evaluación de la influencia del operador en el procesado junto con el grupo de INRA. Esta evaluación se ha llevado a cabo mediante el procesado del mismo conjunto de imágenes DHP adquirido durante SPARC'03 de forma independiente por los dos grupos. La versión del programa ha sido la misma para ambos, por lo que el único factor importante a tener en cuenta en las posibles

diferencias de los resultados se refiere al proceso de segmentación de la imagen realizado por el usuario.

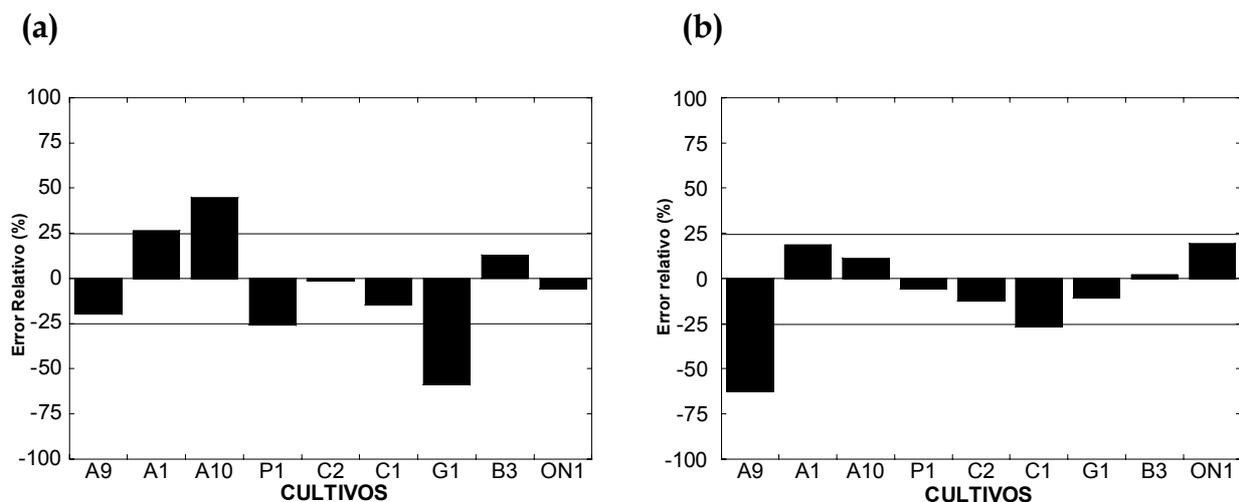
Los resultados se muestran en la figura III.9. En general, se observa una buena correlación entre los resultados, donde las estimaciones de LAI y FVC muestran una alta concordancia excepto en algunos casos como la ESU 52 perteneciente a la clase de Hierba. En este caso, la altura de la cubierta era muy baja y la determinación del ALA no es muy fiable, lo que también puede conducir a errores en la determinación del LAI. La mayoría de las diferencias aparecen en imágenes tomadas desde arriba de la cubierta con una tendencia a obtener valores más altos por parte del grupo de INRA (ESUs 13, 19, 22, 44, 59). En el caso de la FAPAR se observan discrepancias altas en aquellas ESUs medidas en condiciones de ángulo solar cenital alto ( $> 60^\circ$ ) como es el caso de las ESUs 12 (Alfalfa), 15 (Ajo) y 55 (Maíz).



**Figura III.9.** Comparación entre el LAI (a), la FVC (b) y la FAPAR (c) derivada a partir del procesado con el programa CAN\_EYE por dos usuarios diferentes, el grupo de la Universidad de Valencia (UV) y el grupo INRA-CSE (Avignon).

### III.4 Comparación entre LICOR LAI2000 y cámara hemisférica

Por último, se ha llevado a cabo una comparación entre el LAI y la FVC estimados a partir de los dos instrumentos y evaluado la discrepancia entre ambos métodos. Cabe destacar que, en la comparación realizada, las superficies de medida (i.e. ESUs) generalmente no se localizaron exactamente sobre el mismo punto y que el número de ESUs y medidas dentro de cada ESU fue aproximadamente el doble para el LICOR LAI2000.

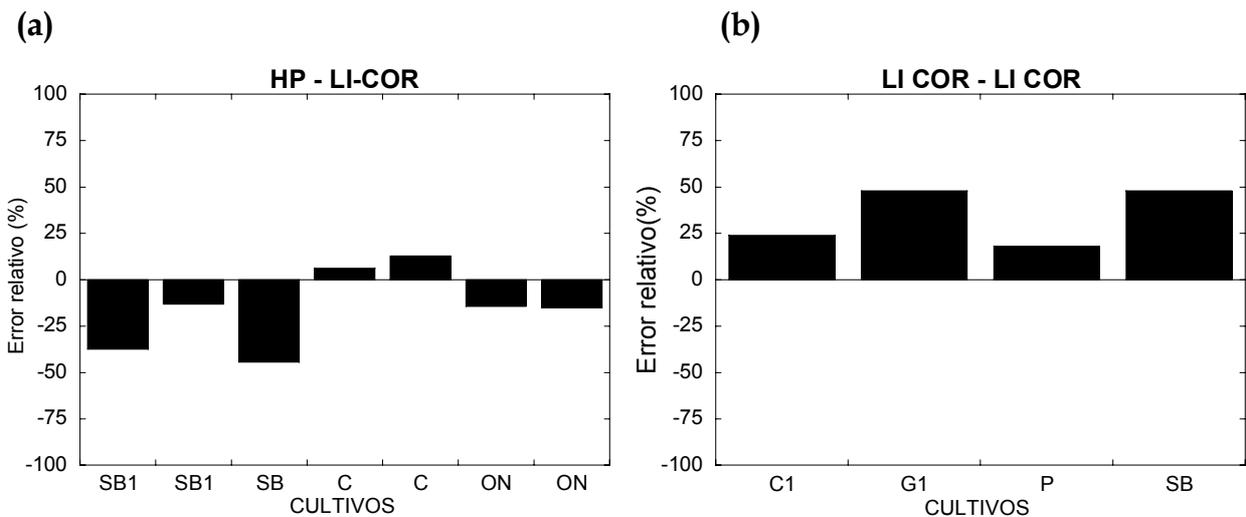


**Figura III.10.** Diferencia entre los valores medios de LAI (a) y FVC (b) estimados por los dos instrumentos relativa al valor medio estimado por el LICOR LAI2000 para cada cultivo.

La figura III.10 muestra la diferencia entre los valores de LAI (a) y FVC (b) medios por ambos instrumentos en relación al valor medio estimado por el LICOR LAI2000 para cada cultivo. Los valores negativos indican una subestimación de la cámara frente al LICOR LAI2000, mientras que valores positivos indican una sobreestimación de la cámara.

En general se observa para el LAI discrepancias menores del 25%, excepto para los campos de Ajo (G1) y Alfalfa (A10), donde las discrepancias son mayores. En el caso del campo G1, cabe destacar que, a diferencia del LICOR LAI2000, la estimación del LAI a partir de las fotografías hemisféricas permitió corregir la presencia de vegetación seca, proporcionando así un valor más bajo del LAI y, por tanto, una sobreestimación por parte del LICOR LAI2000. Respecto al campo A10, las imágenes disponibles para estimar el LAI presentaban una alta proporción de sombras debido, principalmente, a la alta densidad de la cubierta y al bajo ángulo cenital solar en el momento de adquisición. Estos factores introdujeron confusión en la clasificación de suelo de fondo, lo que dio lugar a valores altos del LAI y, por tanto, a una sobreestimación respecto al LICOR LAI2000. Con excepción de un cultivo de Alfalfa, los errores relativos en la estimación de la FVC son menores, típicamente inferiores al 20%. El orden de magnitud es igual al que se comete

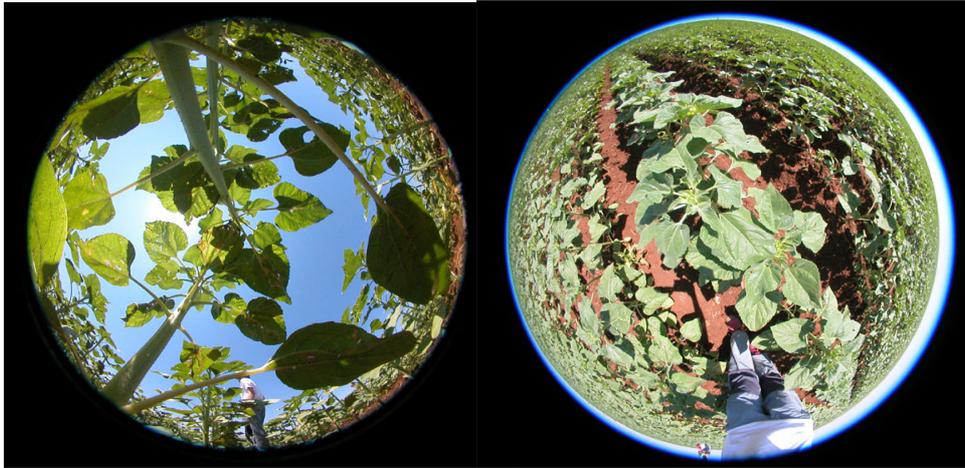
cuando medimos una superficie utilizando dos LICORs. Este comportamiento se ha estudiado con un poco más de detalle en SPARC'04, donde se realizaron medidas simultáneas en la misma superficie con dos LICORs. También se llevaron a cabo medidas simultáneas con el LICOR LAI2000 y la DHP, pero en 6 superficies diferentes. La figura III.11a muestra el error relativo entre LICOR y DHP, y la figura III.11b entre LICORs. Las discrepancias entre estimaciones realizadas con LICORs diferentes muestran un error típico entre el 10% y el 50%, dependiendo del tipo de cubierta, del mismo orden de magnitud que los obtenidos entre el LICOR y la DHP (ver figura III.11a y III.10a).



**Figura III.11.** Diferencia en las estimaciones de LAI para una misma ESU entre cámara hemisférica y LICOR (a) y LICORs (b).

Por otra parte, cabe destacar en la estimación del LAI un mayor error relativo respecto al LICOR LAI2000 cuando la imagen se ha adquirido en modo *downward* (e.g. A1, A10, P1 y G1). Tal como se ha comentado anteriormente, la imagen adquirida desde esta posición es más difícil de clasificar debido a la mayor confusión en distinguir el suelo sombreado de la vegetación. Un estudio realizado con los datos de SPARC'04 ha permitido cuantificar en algunos campos el error que se comete en el valor del LAI cuando la imagen se adquiere utilizando los dos modos (i.e. *upward* y *downward*). La figura III.12 muestra un ejemplo de una ESU localizada en un campo de Girasol (a) y Maíz (b). El error cometido en la estimación del LAI al adquirir la imagen en modo *downward* se corresponde a una sobreestimación entre el 37% y 57%, obteniéndose un valor de LAI casi el doble que en modo *upward*. De los resultados obtenidos de las dos campañas SPARC, se concluye que es conveniente situar la cámara en posición *upward* siempre que sea posible, dado que es más sencillo clasificar la imagen y las estimaciones en el LAI se asemejan más a las obtenidas con el LICOR LAI2000.

(a) GIRASOL



(b) MAÍZ



**Figura III.12.** Ejemplo de dos ESUs, Girasol (izquierda) y Maíz (derecha), adquiridas en modo *upward* y *downward* durante la campaña de SPARC'04. El error relativo cometido en la estimación del LAI al realizar la adquisición en modo *downward* se sitúa entre un 37% y 57%.

### III.5 Conclusiones

Por último, se detallan algunas conclusiones respecto a las ventajas y limitaciones que presenta la cámara hemisférica respecto al LICOR en estimación de los parámetros biofísicos LAI, FVC y FAPAR.

1. La estimación de los parámetros estructurales de la cubierta como el LAI, FVC, ALA, *clumping* y parámetros relacionados con la actividad fotosintética como la FAPAR permite estimar el LAI corregido del efecto *clumping* y de la vegetación seca respecto a otros instrumentos como el LICOR LAI2000.

2. El campo continuo de visión de la cámara (0-90°) permite evaluar la *gap fraction* en un rango más amplio que el LICOR LAI2000, con la limitación de que para cubiertas caracterizadas desde arriba es recomendable limitar el campo de visión a un rango cenital entre 0° y 60°. De este modo, se evita que el procesado incluya elementos de la cubierta que estén muy alejados del nadir.
3. La cámara permite estimar la *gap fraction* bajo un amplio rango de condiciones de iluminación, con la limitación de posibles saturaciones del brillo cuando la imagen se adquiere en modo *upward* en horas centrales del día y presencia de sombras cuando la imagen se adquiere en modo *downward* en horas extremas del día.
4. Es recomendable adquirir las fotografías en modo *upward* cuando es posible, debido a una sobreestimación en el LAI que puede llegar a ser el doble cuando se realiza la adquisición en modo *downward*.
5. El procesado de las fotografías requiere invertir mayor tiempo respecto al procesado llevado a cabo con el LICOR, sin embargo pueden utilizarse, posteriormente, como entrada de modelos que permiten estimar un número mayor de parámetros de la cubierta.
6. El proceso de segmentación se presenta como el paso más crítico, dado que depende en gran parte del criterio del operador para distinguir la vegetación verde de la seca, que es especialmente complicado en cubiertas muy densas adquiridas desde arriba. En este tipo de situaciones, la resolución de la cámara y la posición son dos factores importantes a considerar para extraer la máxima información relativa a la cubierta vegetal.
7. El error relativo cometido en las estimaciones del LAI y FVC realizadas con la cámara y el LICOR es típicamente inferior al 25%, alcanzando en algunos casos (e.g. G1, A10 y SB1) discrepancias del 50%. Los resultados obtenidos de SPARC'04 muestran que estos errores son del mismo orden de magnitud que los obtenidos al estimar el LAI en una misma ESU con diferentes instrumentos LICORs.
8. Por último, se concluye que las estimaciones de LAI y FVC derivadas a partir de dos instrumentos diferentes muestran ser adecuadas para llevar a cabo la caracterización a alta resolución. El hecho de disponer de dos conjuntos de datos para cada parámetro permitirá evaluar aspectos relacionados con el patrón espacial como, la influencia del muestreo utilizado en la estimación de la función de transferencia, la extensión de superficie caracterizada con cada instrumento y el número de adquisiciones por cultivo.



## CAPÍTULO IV

---

---

### CARACTERIZACIÓN DE LAI, FVC y FAPAR A ALTA RESOLUCIÓN

---

---

*En este capítulo se incluye la evaluación de los métodos de regresión multivariada y geoestadísticos para la estimación de mapas a partir de medidas in-situ y la comparación entre ellos (Sección IV.1 y IV.2). Además, dado que se dispone de dos muestreos espaciales diferentes, se ha evaluado su influencia en las estimaciones derivadas en cada método, asociando un error a cada mapa debido al muestreo espacial (Sección IV.1.3 y IV.2.3). Por otra parte, se ha ensayado un método para derivar una imagen de calidad (QF) asociada a las estimaciones derivadas a partir del método de regresión multivariada, de modo que permita evaluar si dicho método caracteriza correctamente los diferentes tipos de cubiertas de la zona de estudio (Sección IV.1.4). Por último, se presenta un estudio más detallado sobre la influencia del muestreo espacial a partir de la simulación de cuatro diseños espaciales, con el objetivo de analizar a diferentes resoluciones espaciales qué método y muestreo presentan el menor RMSE y la menor influencia de la variable secundaria (Sección IV.3).*

En este capítulo se presentan los resultados obtenidos en la estimación de los parámetros biofísicos LAI, FVC y FAPAR a alta resolución a partir de dos técnicas distintas. En primer lugar, se aplica la técnica de regresión multivariada (e.g. función de transferencia) para la estimación de los tres parámetros a partir de medidas *in-situ* sobre dos áreas con dimensiones diferentes, (i) la zona donde se han concentrado las medidas *in-situ* (e.g. 5×5 km<sup>2</sup>) y (ii) otra mayor (e.g. 50×50 km<sup>2</sup>) que también será utilizada para realizar la validación directa de productos derivados a baja resolución. El capítulo incluye, el cálculo de la función de transferencia para extender espacialmente las medidas *in-situ* a alta resolución (Sección IV.1.1 y IV.1.2), el cálculo del error asociado a dichas estimaciones, un análisis de la influencia del muestreo espacial en las estimaciones (Sección IV.1.3), la aplicación de un método para derivar una imagen de calidad asociada al producto que evalúe el modelo (Sección IV.1.4) y la evaluación de la FT sobre el área de 50×50 km<sup>2</sup> (Sección IV.1.5).

En segundo lugar y con el objetivo de evaluar los modelos geostatísticos anteriormente descritos frente a las estimaciones derivadas a partir de la FT, se aplican los métodos del krigado ordinario (KO), cokrigado colocalizado (CKC) y krigado con deriva externa (KDE) (Sección IV.2). Como se ha descrito en el capítulo de fundamentos teóricos (Sección I.6.2), el krigado consiste en un estimador lineal que considera información sobre la correlación espacial de las variables y proporciona la estimación de una posición a partir de la combinación lineal de diferentes observaciones (e.g. medidas *in-situ*) incluidas dentro de un radio de influencia. En este caso, sólo se utilizará una variable como información auxiliar (e.g. variable secundaria) la cual corresponde a un índice de vegetación (e.g. NDVI) derivado de la imagen de alta resolución, dado que se puede conocer en todos los puntos donde se desea estimar. En este apartado se incluyen los dos pasos importantes para llevar a cabo las estimaciones con cada método, el análisis de la continuidad espacial (Sección IV.2.1) y la correlación con la variable secundaria (Sección IV.2.2). También se incluye la comparación entre los diferentes métodos y el análisis del muestreo espacial (Sección IV.2.3), así como la influencia de la resolución espacial en las estimaciones (Sección IV.2.3).

Por último, se evalúa con mayor detalle la influencia del muestreo espacial a partir de las estimaciones obtenidas con cuatro muestreos espaciales simulados (Sección IV.3). El principal interés de este análisis es responder algunas cuestiones como dónde medir y cuántas ESUs son necesarias adquirir para minimizar los esfuerzos en el campo y obtener el mayor rendimiento de los métodos propuestos. Las observaciones de cada muestreo se han extraído del mapa derivado a partir de la FT con el conjunto de datos LAI<sub>LICOR</sub>. El estudio se ha realizado con ambas técnicas y a diferentes resoluciones espaciales con el objetivo de determinar una configuración óptima (e.g. modelo, muestreo y resolución espacial). En el caso de las técnicas geoestadísticas, se evaluará la influencia de la variable secundaria y la configuración óptima para la que se minimiza su influencia.

## IV.1 Técnica de regresión multivariada

El algoritmo de regresión multivariada utiliza un método iterativo para asignar un factor de escala o peso a cada variable independiente. Este método permite minimizar la influencia de aquellas ESUs que no se ajustan correctamente al comportamiento general del resto de observaciones (i.e. *outliers*), detectando de esta forma posibles errores en los datos. Los pesos toman valores desde cero a uno, de modo que cuanto menor sea su valor más diferirá dicha observación del comportamiento general.

El algoritmo de regresión multivariada con un método iterativo incluye el factor de ajuste en la formulación original del modelo OLS según la siguiente expresión:

$$\min_p S = \sum_{i=1}^n \omega_i (Y_i - \hat{Y}_i)^2 \quad \text{[IV.1]}$$

donde  $\hat{Y}_i$  representa el valor estimado,  $Y_i$  el medido *in-situ* y  $\omega_i$  los pesos asociados. En cada iteración, el valor estimado de la iteración anterior es utilizado para recalcular los pesos a partir de una función bicuadrada definida como:

$$\omega_i = \begin{cases} (1 - (u_i)^2)^2 & |u_i| < 1 \\ 0 & |u_i| \geq 1 \end{cases} \quad \text{[IV.2]}$$

donde  $u_i$  corresponde a los residuos estandarizados según la expresión:

$$u_i = \frac{r_i}{\hat{\sigma} \cdot K \cdot \sqrt{1 - h_i}} \quad \text{[IV.3]}$$

con  $r_i$  definido como los residuos derivados del modelo OLS;  $h_i$  como un factor de ajuste de dichos residuos;  $K$  como una constante empírica igual a 4.685 en el caso de la función bicuadrada y  $\hat{\sigma}$  como la desviación estandar del ajuste, la cual se estima a partir de la desviación media absoluta (MAD). MAD se obtiene como la desviación media absoluta de los residuos respecto de su media dividido por el factor 0.6745 (DuMouchel & O'Brien 1989).

En nuestro caso, el modelo de regresión multivariada por OLS definido en la ec. [I.4] toma la forma siguiente:

$$P_{in-situ} = \beta_0 + \sum_{i=1}^4 \beta_i \cdot C_i + \varepsilon \quad \text{[IV.4]}$$

donde  $P_{in-situ}$  hace referencia al parámetro biofísico medido *in-situ* (i.e. LAI<sub>LICOR</sub>, FVC<sub>LICOR</sub>, LAI<sub>DHP</sub>, FVC<sub>DHP</sub> y FAPAR<sub>DHP</sub>);  $C_i$  a los canales de radiancias derivados de la imagen de alta resolución (i.e. R, G, NIR y MIR);  $\beta_i$  a los coeficientes asignados a las radiancias;  $\varepsilon$  a la diferencia entre el valor observado y el predicho por la regresión, y  $\beta_0$  al término constante que tiene en cuenta el sesgo debido a una serie de errores, como por ejemplo la corrección atmosférica.

Las FTs se han obtenido a partir de los diferentes conjuntos de datos,  $LAI_{LICOR}$ ,  $FVC_{LICOR}$ ,  $LAI_{DHP}$ ,  $FVC_{DHP}$  y  $FAPAR_{DHP}$  y  $LAI_{DHP}$ . Para cada caso, se calculan todas las funciones que relacionan los parámetros biofísicos con todas las combinaciones de bandas espectrales posibles y se obtienen una serie de errores que serán utilizados para evaluar cuál es la función que mejor caracteriza el parámetro estimado en la zona de estudio, es decir, que introduzca menor error en las estimaciones. Estos errores corresponden al error cuadrático medio proporcionado por la regresión clásica (R), al error cuadrático medio de la regresión con pesos (RW) y por último, el error de validación cruzada (RC). El RC, tal como se ha introducido en el apartado I.6.1, se presenta como una herramienta adecuada para evaluar el modelo en la estimación de valores donde no se ha medido. En este caso, el RC se ha calculado a partir del método *leaving-one-out* descrito en el apartado I.6.2. Para ello, se obtienen los diferentes modelos de regresión obtenidos al eliminar una observación del conjunto de  $n$  datos *in-situ*, y prediciendo su valor a partir del modelo ajustado a las  $n-1$  observaciones restantes. De modo que cuanto más se aproxime el valor estimado al observado menor será el RC y, por tanto, mejor será el modelo considerado. Mientras que R y RW subestiman el error, RC proporciona un valor más realista y menos sesgado. Por tanto será un indicador más preciso para evaluar la capacidad del modelo elegido para estimar los parámetros de interés.

Las FTs y mapas derivados a partir de este procedimiento se presentan a continuación. El primer apartado, presenta los resultados para los parámetros LAI, FVC y FAPAR estimados a partir de las DHPs, mientras que el siguiente apartado incluye los resultados de los parámetros LAI y FVC estimados a partir del LICOR LAI2000.

#### IV.1.1 Cámara hemisférica

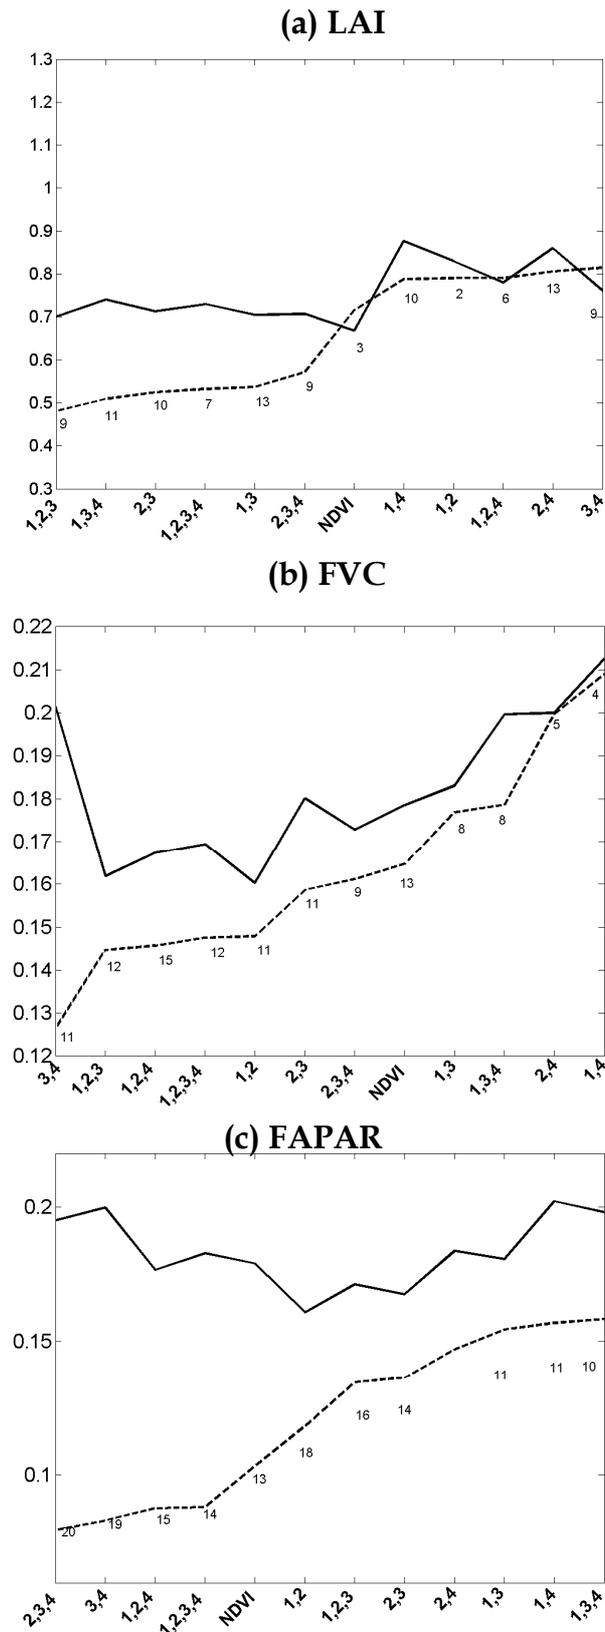
La elección de la FT para cada parámetro combina simultáneamente tres criterios de error, menor RW, RC y número de ESUs con pesos inferiores a 0.7. Esta metodología es similar a la propuesta por Weiss (2004b) para el cálculo de mapas de alta resolución en el contexto del proyecto VALERI. La figura IV.1 muestra en ordenadas los errores RW (línea discontinua) y RC (línea continua) para todas las combinaciones de bandas espectrales (abscisas). Los números de las abscisas hacen referencia a las bandas espectrales utilizadas, G (1), R (2), NIR (3) y MIR (4). Los números situados debajo del RW muestran las ESUs con pesos inferiores a 0.7 obtenidas a partir del método iterativo de regresión. En nuestro caso, se ha observado que las medidas *in-situ* con un comportamiento diferente del general presentan pesos menores de 0.7 y corresponden, principalmente a ESUs, (i) localizadas cerca del borde de un campo de cultivos, de modo que la respuesta radiométrica esté contaminada por los efectos de borde, o (ii) cuyo LAI medido *in-situ* difiere del real debido a posibles errores, como por ejemplo un mal uso del instrumento, errores de procesamiento o muestreo espacial no adecuado.

Bajo estos criterios, se seleccionó la combinación de bandas 123 (G, R, NIR) para el LAI, la cual presenta valores aceptables de RW y RC (0.5 y 0.7, respectivamente) si consideramos la variabilidad del LAI presente en la zona de estudio (entre 0 y 6). Cabe destacar diferencias entre todas las posibles combinaciones de alrededor de 0.25 para ambos errores (ver figura IV.1a), obteniéndose los valores más altos (RC=0.85 y RW=0.7) para aquellas combinaciones que no incluyen la banda del NIR, como son la 14, 12, 124 y 24. Las funciones que incluyen el NIR y una de las bandas del G o el R (e.g. 123, 124, 23, 1234 y 13) proporcionan los errores más bajos.

Para la FVC (ver figura IV.1b), el RC presenta valores entre un 16% y 21%, mientras que el RW muestra un mayor rango de variación con valores entre el 13% y 21%. Aunque la combinación 34 (NIR, MIR) es la que presenta menor RW, también proporciona uno de los RC más altos, por lo que se ha considerado la función 123 (G, R, NIR) con uno de los valores de RC más bajos (RC=0.16 y RW=0.14). Una vez más, se observa cómo las funciones que no incluyen la banda del NIR (e.g. 24 y 14) proporcionan los valores más altos de RW (0.2) y RC (0.21). Por otra parte, también se ha considerado la función del NDVI por su amplio uso en la estimación de dichas variables, tal como lo demuestran múltiples trabajos ([Berterretche et al 2005](#), [Turner et al 1999](#), [Fassnacht et al 1997](#), [Tucker 1979](#)). El RC y RW aumentan en menos de un 2% y 3% respectivamente al considerar dicha función en lugar de la 123. Más adelante se analizarán las diferencias en las estimaciones derivadas de ambas funciones.

Por último, la FAPAR (ver figura IV.1c) proporciona valores de RC similares a los obtenidos para la FVC, pero RW menores (entre 5% y 15%). En este caso, la combinación 234 (R, NIR, MIR) es la que presenta menor RW, pero valor máximo de RC y de ESUs con pesos menores de 0.7 (20). La siguiente combinación con menor RC es la 12 (G, R), sin embargo se observan un mayor número de ESUs con pesos menores de 0.7 (18). Finalmente, las combinaciones elegidas son la 123 (G, R, NIR) y NDVI al igual que para la FVC. Por una parte, la 123 muestra un RC similar a la combinación 12, pero con menor número de pesos (16). Por otra parte, el NDVI muestra menor RW y menor número de pesos (13) que la combinación 12.

Con el objetivo de evaluar el error introducido al seleccionar la combinación de bandas, se han obtenido diferentes estadísticos a partir de las estimaciones derivadas de las funciones. Se ha calculado la media y el RMSE de cada función respecto a la FT elegida y se ha evaluado según el nivel de cobertura en función del NDVI. Se han seleccionado para este estudio, las funciones que muestran RW y RC mínimo, máximo e intermedio.



**Figura IV.1.** RW (línea discontinua) y RC (línea continua) asociados a las FTs correspondientes al LAI (a), FVC (b) y FAPAR (c) estimados a partir de las DHPs. En abscisas se representan la combinación de las bandas espectrales utilizadas G (1), R (2), NIR (3) y MIR (4) respectivamente.

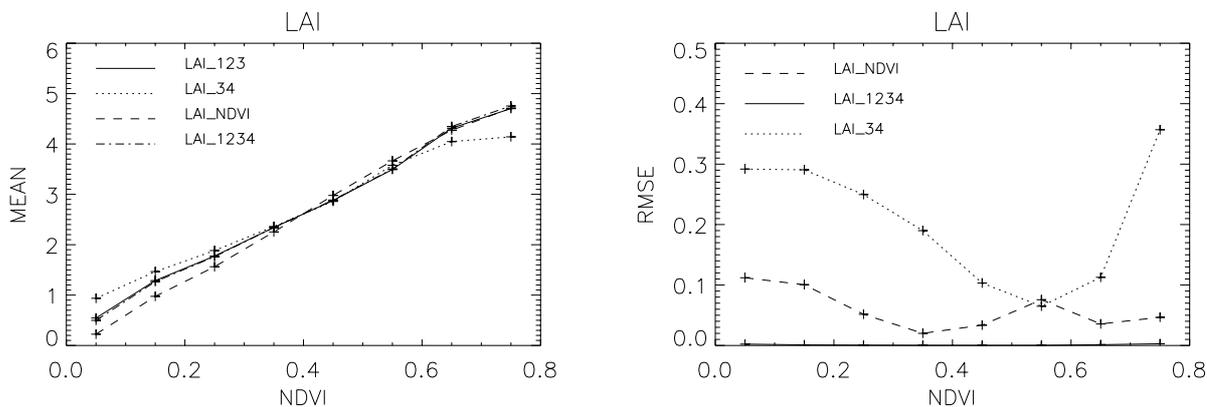
En el caso del LAI, se han escogido las combinaciones 123, 1234, NDVI y 34. Se observa en la figura IV.2a la media (izquierda) y el RMSE (derecha) en función del nivel de cobertura. La media proporciona información de las diferencias a resoluciones más bajas puesto que se ha integrado para diferentes niveles de cobertura, mientras que el RMSE muestra las diferencias a alta resolución. En general, no se observan diferencias significativas en los valores medios. En cuanto al RMSE, la combinación 34 es la que presenta mayores discrepancias (hasta 0.35) con respecto a la función 123, sobre todo en niveles bajos ( $NDVI < 0.4$ ) y altos de cobertura ( $NDVI > 0.6$ ). Se observa cómo aquellas funciones que incluyen las bandas más correlacionadas con la estructura de la cubierta (i.e. R y NIR) no introducen grandes diferencias, como es el caso del NDVI (diferencias menores del 0.1) y la combinación 1234, donde la influencia del MIR es casi despreciable.

Para la FVC, al igual que en el caso anterior se observan mayores discrepancias para las combinaciones que no incluyen la banda del NIR. Por ejemplo, la función 14 proporciona valores medios de FVC altos (0.35) cuando el nivel de cobertura es muy bajo (figura IV.2b izquierda). Las diferencias respecto al NDVI son menores del 7%, siendo casi nula para la función 123. La combinación 123 sobreestima la FVC para niveles bajos de cobertura respecto a la función NDVI y subestima para niveles altos de cobertura. Este comportamiento se analizará con más detalle más adelante.

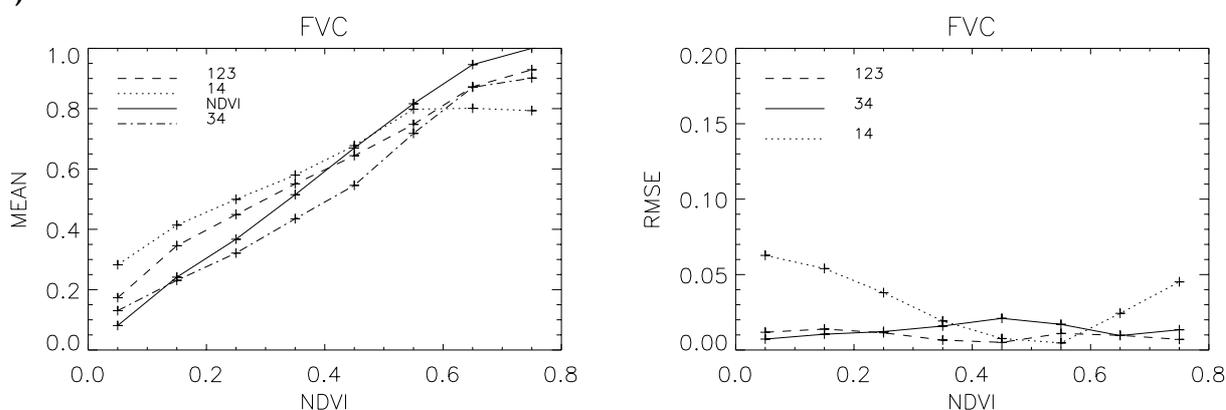
Por último, las estimaciones de FAPAR a partir de las bandas 123, 134 y 234 no presentan importantes diferencias respecto al NDVI (figura IV.2c derecha). Las discrepancias se observan principalmente en niveles bajos de cobertura donde todas las funciones sobreestiman el valor medio de FAPAR respecto al derivado con el NDVI (figura IV.2c izquierda). Las diferencias derivadas de la función 123 y NDVI se analizarán con más detalle más adelante.

A continuación se muestran en la figura IV.3 los parámetros estimados a partir de las FTs elegidas en función de las medidas *in-situ*. Para el LAI se ha representado las estimaciones derivadas de la combinación (G, R, NIR) y para la FVC y FAPAR las estimaciones derivadas de la función NDVI. Los puntos negros hacen referencia a las ESUs con pesos superior a 0.7, los puntos en blanco representan las ESUs con pesos inferiores a 0.7 pero distinto de cero, y las cruces negras son las ESUs con pesos iguales a cero. En rojo se ha incluido la recta 1:1 con el objetivo de visualizar la dispersión entre valores predichos y medidos. En la parte superior izquierda se muestran los coeficientes que multiplican a cada una de las bandas espectrales, donde el último de ellos corresponde al término aditivo de la función. En la parte inferior derecha se muestran los valores de los errores, R, RW y RC, respectivamente.

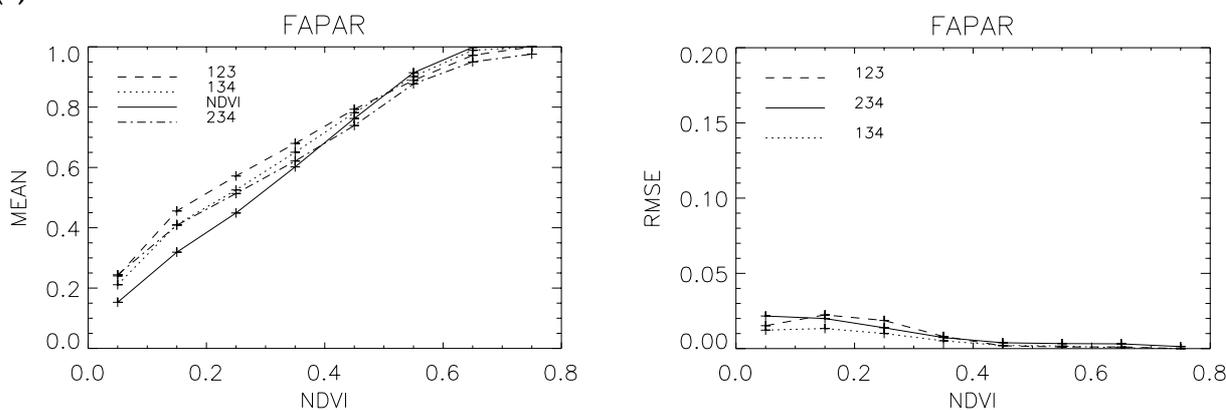
**(a) LAI**



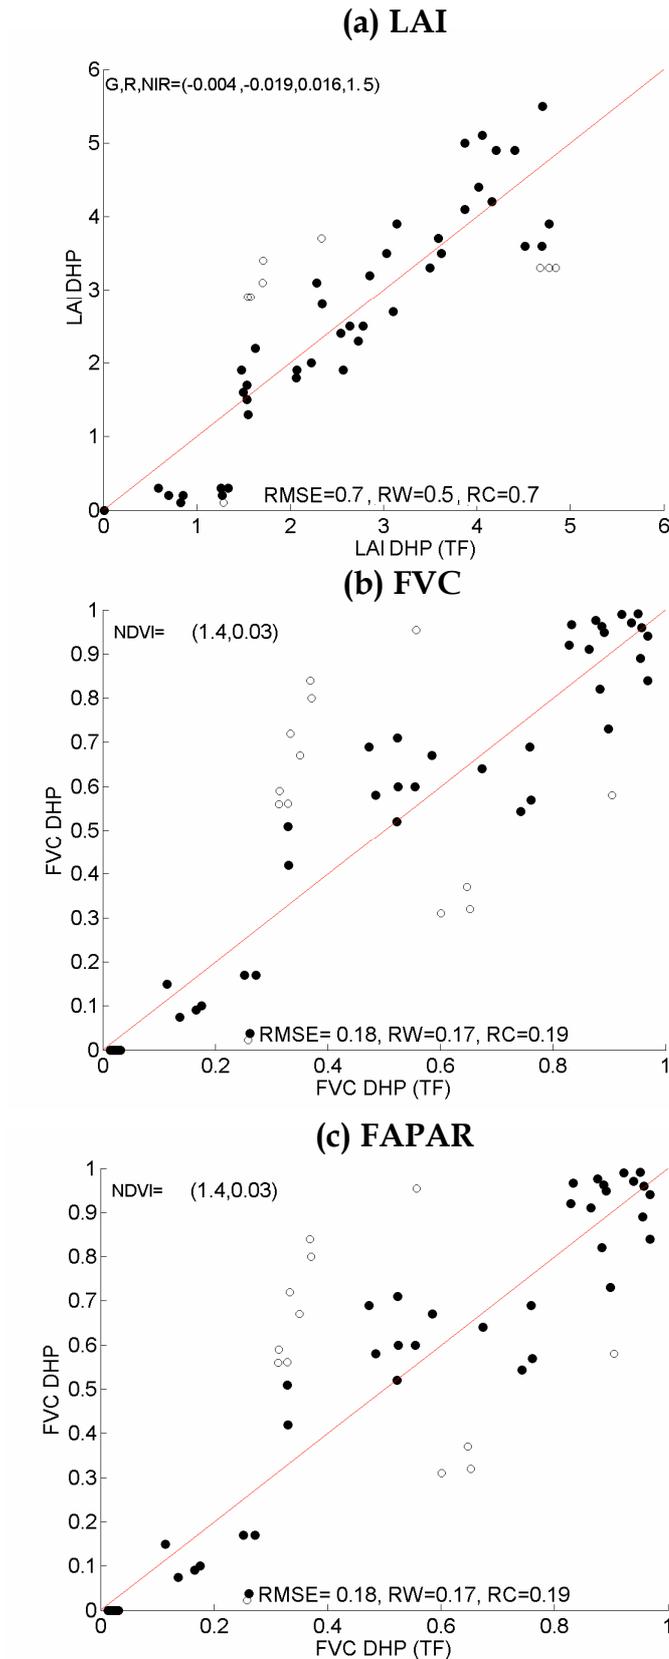
**(b) FVC**



**(c) FAPAR**



**Figura IV.2.** Valor medio (izquierda) y RMSE (derecha) de las estimaciones proporcionadas por las funciones con RW y RC mínimo, máximo e intermedio para los parámetros LAI (a), FVC (b) y FAPAR (c) derivados de la cámara hemisférica.



**Figura IV.3.** Representación de las medidas *in-situ* con la cámara hemisférica frente a las estimadas por la FT para el LAI (a), la FVC (b) y la FAPAR (c). En cada caso se han incluido los coeficientes de la función junto con el RMSE, RW y RC.

Se observa en la figura IV.3 cómo sólo entre 9 y 13 ESUs presentan un comportamiento diferente al general. En particular, se obtiene que las ESUs 14 (G1), 21 (A10), 27 (A10), 28 (A10) y 35 (GR) presentan pesos inferiores a 0.7 para los tres parámetros. Estas unidades corresponden a las clases de Ajo, Alfalfa y Hierba. En el caso del LAI y FVC, las estimaciones en los campos de Ajo y Alfalfa presentaban menos fiabilidad debido a la alta discrepancia mostrada con las estimaciones derivadas del LICOR (figura III.10). En el caso de la superficie de Hierba, su alta densidad de vegetación y poca altura de la cubierta hace que esta cubierta sea difícil de caracterizar obteniéndose estimaciones poco fiables. Dicho comportamiento se ha podido observar a partir de las diferencias mostradas entre las estimaciones del grupo de INRA y el nuestro. El resto de ESUs con pesos menores de 0.7 corresponden a unidades localizadas cerca de los bordes entre superficies.

En el caso de la FAPAR, las ESUs con pesos menores de 0.7 corresponden, además de las descritas anteriormente, a adquisiciones realizadas bajo condiciones de iluminación con ángulos cenital solar extremos (e.g. A1). En este caso, la adquisición de la imagen de alta resolución fue al medio día, lo que da lugar a que puedan existir diferencias de hasta un 28% (ver figura I.7) debido al desplazamiento temporal con las medidas *in-situ*. Sólo en el caso de la FAPAR se obtienen ESUs con pesos nulos, las cuales corresponden a la cubierta de Hierba, ESUs situadas en el borde del campo y también adquiridas bajo condiciones de ángulo cenital alto.

Los resultados obtenidos ponen de manifiesto la idoneidad del método de regresión propuesto para predecir los parámetros LAI, FVC y FAPAR con errores aceptables. Además, el criterio adoptado para elegir la función de transferencia muestra ser también adecuado proporcionando errores menores de 0.3, 0.06 y 0.02 para el LAI, la FVC y la FAPAR, respectivamente. El método iterativo de regresión multivariada se diferencia del método simple por mínimos cuadrados en que, (i) permite localizar aquellas ESUs con un comportamiento diferente al que se podría esperar, (ii) asociar un factor de ajuste a esas ESUs para que su influencia en las estimaciones sea mínima y (iii) proporcionar estimaciones con un error cuadrático medio menor.

#### IV.1.2 LICOR LAI2000

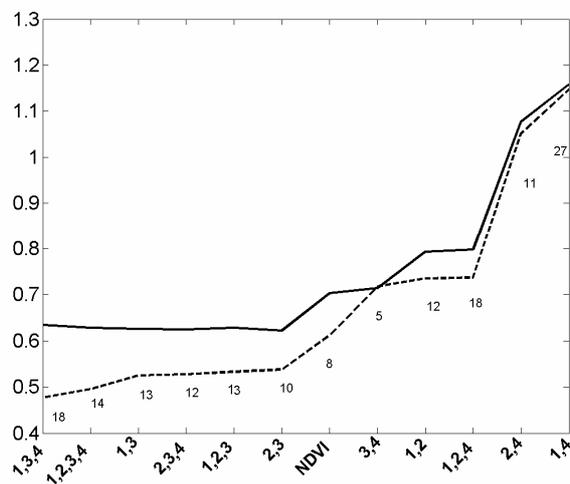
A partir del conjunto de datos LAI<sub>LICOR</sub> se han calculado las FTs para los parámetros LAI y FVC. Al igual que se ha realizado con los datos de la cámara hemisférica, se obtienen los errores RW y RC para todas las funciones calculadas con todas las posibles combinaciones de bandas espectrales y se elige aquella función óptima combinando los mismos criterios en el caso de la cámara hemisférica.

La figura IV.4 muestra los errores RW y RC obtenidos para las diferentes combinaciones de bandas en el caso del LAI (figura IV.4a) y la FVC (figura IV.4b).

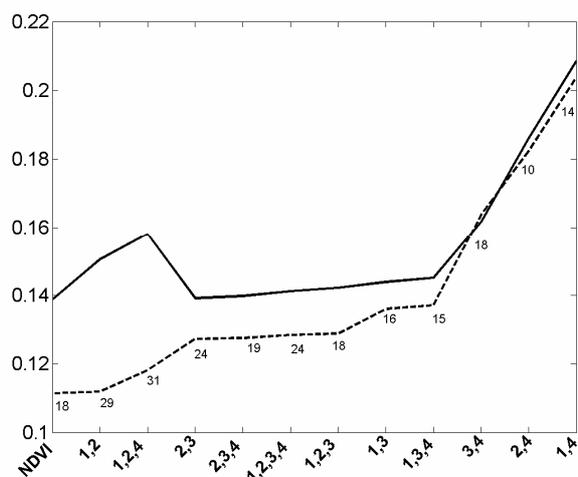
La combinación de bandas escogida para estimar el LAI corresponde a la función (G, R, NIR), dado que es una de las que proporciona menor número de ESUs con pesos menores de 0.7 (13) y errores RW y RC bajos (0.5 y 0.6, respectivamente). Dado que no se observan importantes diferencias con las funciones 13 y 23, esta función se ha elegido con el objetivo de poder compararla con la obtenida para el conjunto de datos LAI<sub>DHP</sub>. Al igual que para la cámara hemisférica, se obtienen valores de RW y RC mayores cuando no se considera la banda del NIR (e.g. 12, 124, 24 y 14), siendo casi el doble que para la combinación 123.

En el caso de la FVC (figura IV.4a), se obtienen valores similares a los obtenidos con el conjunto de datos FVC<sub>DHP</sub>, siendo la función del NDVI la que menor RC (0.13) y RW (0.11) presenta. Al igual que para la FVC<sub>DHP</sub>, las funciones 24 y 14 son las que mayor RC y RW proporcionan, siendo el RW casi el doble que para el NDVI.

(a) LAI



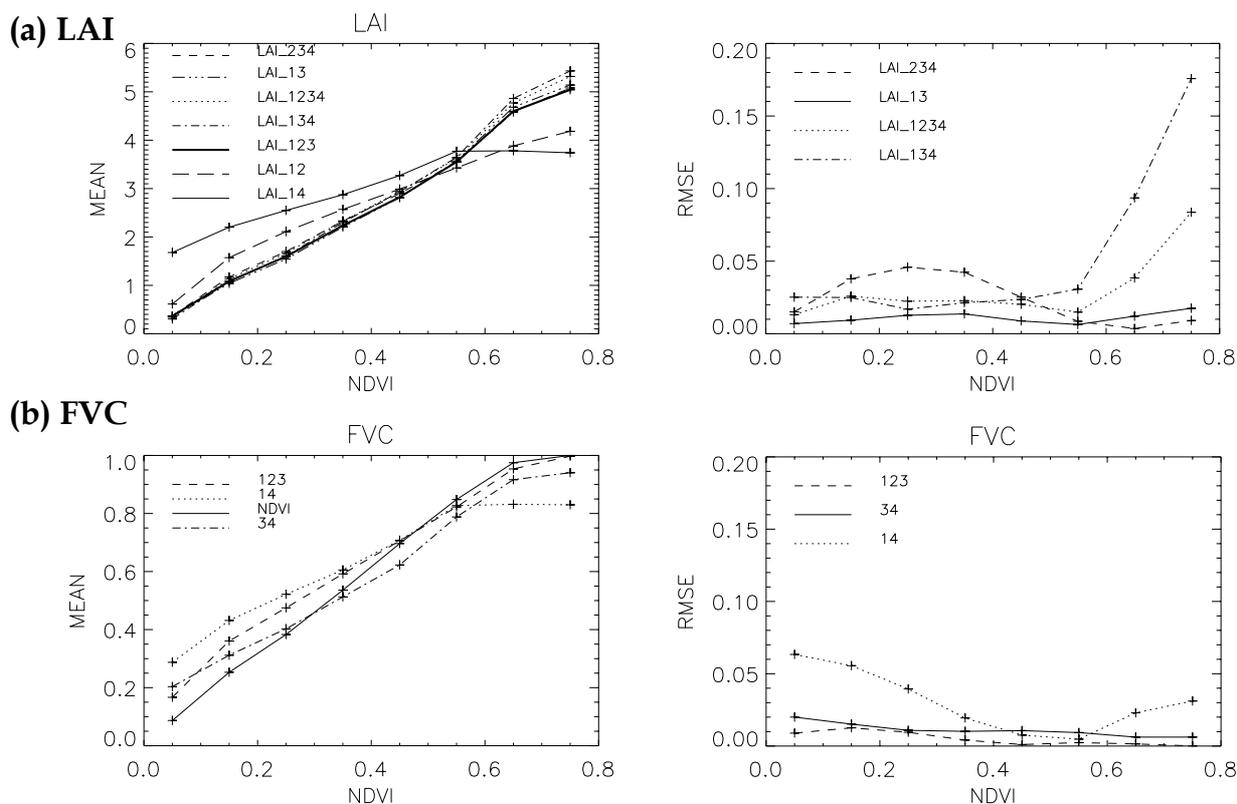
(b) FVC



**Figura IV.4.** RW (línea discontinua) y RC (línea continua) asociados a las FTs para el LAI<sub>LICOR</sub> (a) y FVC<sub>LICOR</sub>.

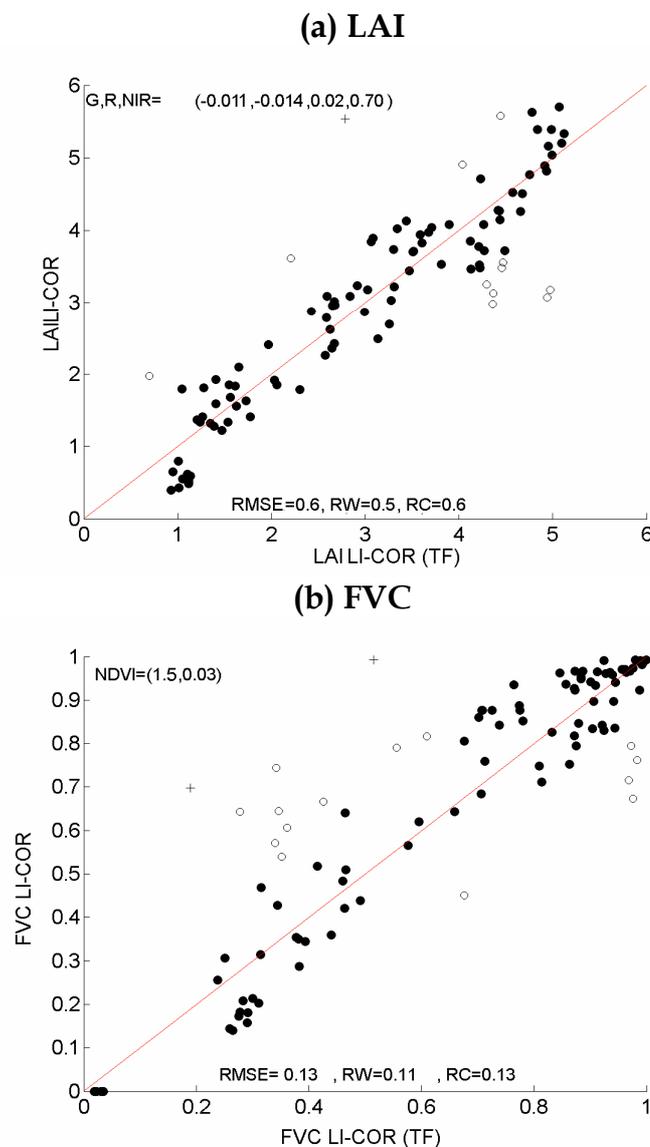
El error asociado a la elección de la función para ambos parámetros se ha evaluado del mismo modo que con la cámara hemisférica. En el caso del LAI, se han seleccionado las funciones que mostraban menor RC y RW que la función elegida 123, y se ha evaluado el error introducido al elegir dicha combinación. También se han incluido las combinaciones con errores intermedios (e.g. 12) y máximo (e.g. 14). En general, sólo se observan diferencias importantes en los valores medios proporcionados por las funciones 12 y 14 (ver figura IV.5a izquierda), las cuales sobrestiman respecto a las demás para valores bajos de NDVI y subestiman para valores altos de NDVI. En aquellas funciones con RC y RW similar a la función 123, el error cometido es menor del 0.05 para niveles de cobertura bajos e intermedios ( $NDVI < 0.6$ ) y menor del 0.18 para cubiertas altas ( $NDVI > 0.6$ ) (ver figura IV.5b). En el caso de las funciones 12 y 14, no se ha representado el error puesto que se obtienen valores mayores desde 0.5 hasta 2.

El error asociado al parámetro FVC se ha evaluado con las funciones 123, 34 y 14 con valores de RC y RW intermedios y máximo, respectivamente. Se observa un comportamiento similar al mostrado para el caso  $FVC_{DHP}$ . Se sobrestima el valor medio de la FVC respecto al NDVI para valores bajos de cobertura y se subestima para valores altos. El RMSE obtenido también es menor del 0.07 para las funciones consideradas.



**Figura IV.5.** (a) Valor medio y (b) RMSE de las estimaciones derivadas de las funciones con RW y RC mínimo, máximo e intermedio para el LICOR LAI2000.

Por último, se muestra en la figura IV.6 los parámetros LAI (figura IV.6a) y FVC (figura IV.6b) obtenidos a partir de la combinación de bandas espectrales (G, R, NIR) y el NDVI en función de los medidos *in-situ*. En el caso del LAI, se observa un menor número de ESUs con pesos inferiores a 0.7 que para la FVC, la cual presenta una mayor dispersión de los valores. En ambos casos, la mayoría de las ESUs con pesos menores de 0.7 se localizan muy cerca del borde del cultivo, de las cuales sólo una tiene asignado peso nulo en el caso del LAI (campo P1) y dos en el de la FVC (campo P1 y A10). Para el parámetro FVC, no se ha encontrado explicación de por qué se les asocia estos pesos al resto de las ESUs que no están cerca del borde. Cabe destacar que la estas unidades muestran valores superiores respecto al valor medio de todas las ESUs adquiridas en un campo en particular, como es el caso del campo de Cebolla (ON1) y de Ajo (G1).



**Figura IV.6.** Coeficientes asociados a la FT elegida para estimar los parámetros LAI y FVC a partir de las medidas *in-situ* realizadas con el LICOR LAI2000.

### IV.1.3 Evaluación de la función de transferencia

En este apartado se evalúan las diferentes funciones obtenidas para estimar los parámetros LAI, FVC y FAPAR mediante el análisis de los coeficientes obtenidos para cada una, así como también los errores RW y RC. Posteriormente, se evalúan las estimaciones obtenidas con cada función a partir de sus histogramas de frecuencias y de los estadísticos RMES y *bias*. La tabla IV.1 muestra los coeficientes y errores obtenidos para los tres parámetros con los dos conjuntos de datos.

En el caso del LAI, se observa para ambos conjuntos de datos una relación negativa del LAI con las bandas del R y G, representativa de la disminución de la absorción de la radiación en este rango espectral debido a los pigmentos presentes en las hojas. Por otra parte, el LAI presenta una relación positiva con la banda del NIR debido, principalmente, a la dispersión múltiple de la radiación en el interior de la cubierta (Gates et al 1965). Cabe destacar la similitud en el orden de magnitud de los coeficientes asociados a las bandas del R y NIR para los dos conjuntos de datos. La figura IV.7a y IV.7b muestra los mapas de alta resolución obtenidos a partir de las funciones LAI<sub>LICOR</sub> y LAI<sub>DHP</sub>, los cuales muestran un alto coeficiente de correlación de Pearson (0.98) y valores bajos de RMSE y *bias* (0.26 y 0.20). Este RMSE representa un indicador de la incertidumbre asociada al LAI debido al modelo y al muestreo espacial. Estas diferencias se analizarán con mayor detalle en la sección siguiente.

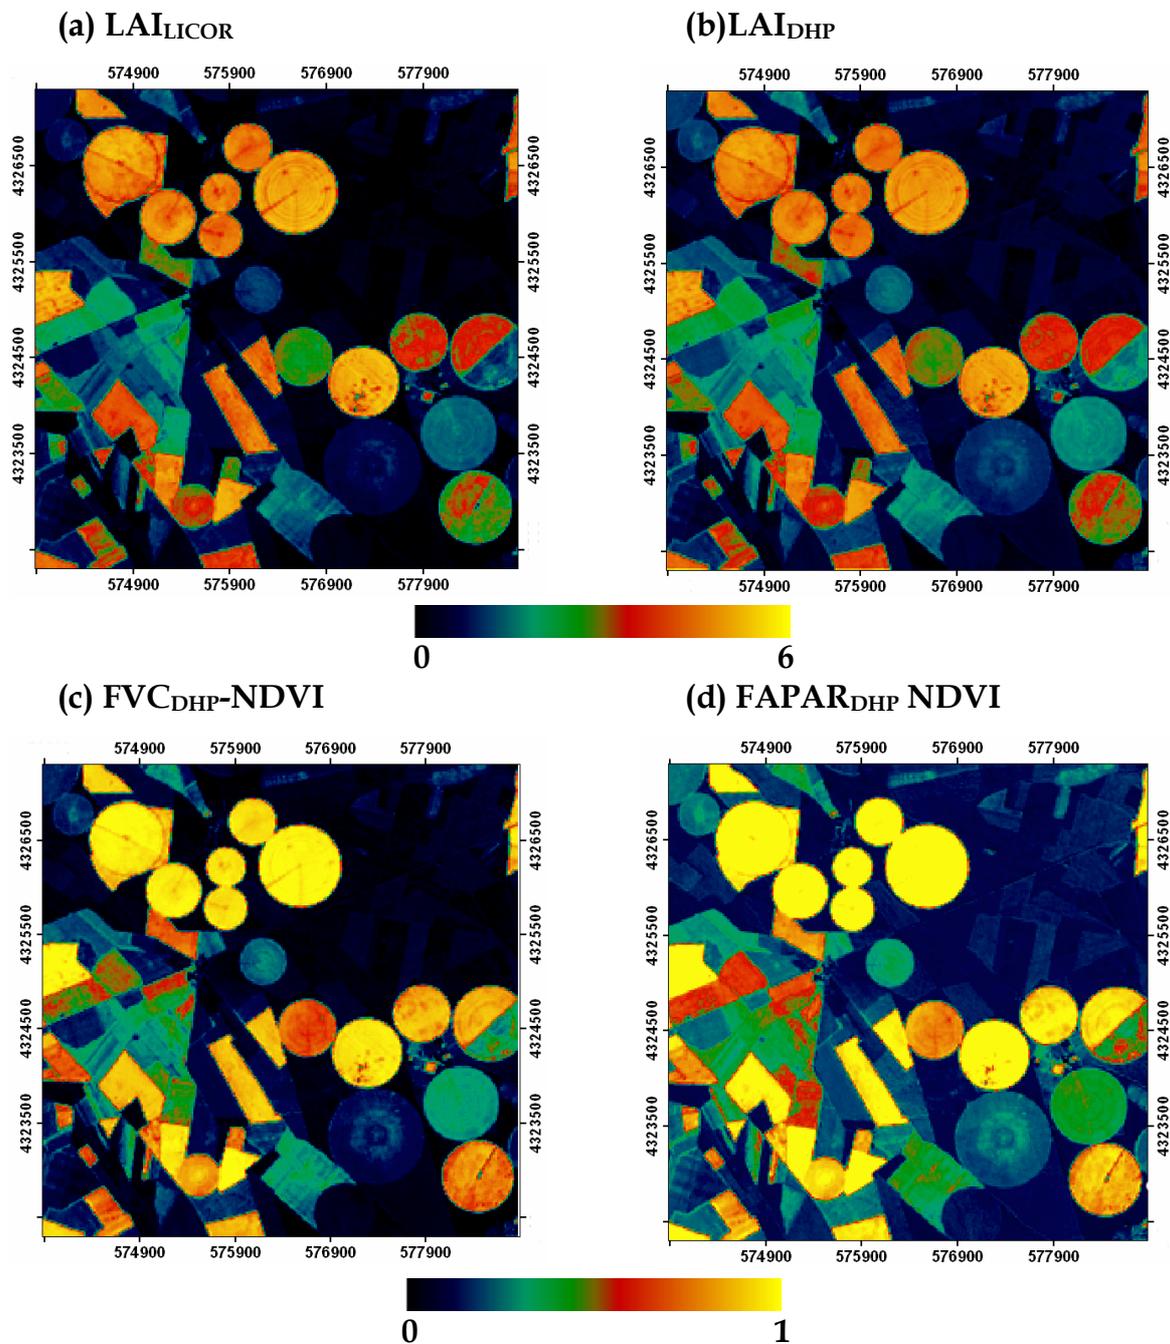
**Tabla IV.1.** Coeficientes obtenidos en las distintas FTs de los parámetros LAI, FVC y FAPAR.

| Función              | Variable                                | Ordenada | RMSE | RW   | RC   |
|----------------------|---|----------|------|------|------|
| LAI <sub>LICOR</sub> | (G, R, NIR):<br>(-0.011, -0.014, 0.02)  | 0.7      | 0.6  | 0.5  | 0.6  |
| LAI <sub>DHP</sub>   | (G, R, NIR):<br>(-0.004, -0.019, 0.016) | 1.5      | 0.7  | 0.5  | 0.7  |
| FVC <sub>LICOR</sub> | NDVI: 1.5                               | 0.03     | 0.13 | 0.11 | 0.13 |
| FVC <sub>DHP</sub>   | NDVI: 1.4                               | 0.03     | 0.18 | 0.17 | 0.19 |
| FAPAR <sub>DHP</sub> | NDVI: 1.5                               | 0.1      | 0.17 | 0.10 | 0.18 |

Para la FVC, cabe destacar la alta similitud de los coeficientes obtenidos para los dos conjuntos de datos. Los dos modelos de regresión proporcionan un error menor del 19% para el rango de variación mostrado por la FVC (entre 0 y 1), con un alto coeficiente de correlación entre las estimaciones (0.99) y RMSE y *bias* muy bajos (0.016 y 0.012). Debido a la alta correlación entre las estimaciones, sólo se ha representado el mapa de FVC obtenido con una de las funciones (i.e. FVC<sub>DHP</sub>).

Por último, la función de la FAPAR muestra valores de RC menores del 18% para el rango encontrado en el área de estudio (entre 0 y 1). Los coeficientes de esta

función están de acuerdo a los propuestos por Fensholt et al (2004) en cultivos. Sin embargo esta función tiene el problema de que para valores de NDVI muy altos satura el valor de la FAPAR, tal como se puede observar en la figura IV.7d si nos fijamos en los cultivos de Maíz o Patata. En la sección siguiente evaluaremos este problema al analizar las estimaciones proporcionadas por la combinación de bandas 123 ( $FAPAR_{DHP-BANDAS}$ ) y el NDVI ( $FAPAR_{DHP-NDVI}$ ).



**Figura IV.7.** Mapas de LAI, FVC y FAPAR obtenidos a partir de las funciones del  $LAI_{LICOR}$  (a),  $LAI_{DHP}$  (b),  $FVC_{DHP-NDVI}$  (c) y  $FAPAR_{DHP-NDVI}$  (d).

A continuación, se evaluarán las diferencias en las estimaciones debido al modelo y al muestreo espacial según el nivel de cobertura. Para ello se ha analizado el

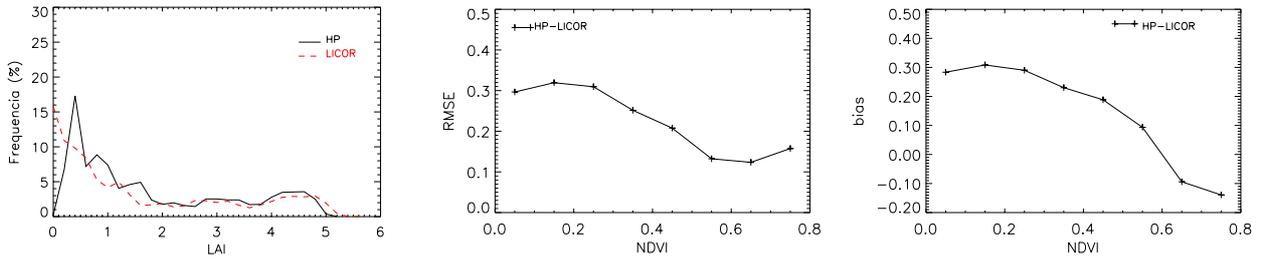
histograma, RMSE y *bias* para los tres parámetros en función del NDVI. En el caso del LAI y FVC, se han comparado las estimaciones derivadas de los dos conjuntos de datos. Dada la similitud en los coeficientes de la función para ambos, la comparación permitirá evaluar el error introducido debido al muestreo espacial. Además, se ha incluido en el estudio la comparación entre las estimaciones derivadas de las funciones 123 y NDVI para la FVC y la FAPAR. La figura IV.8 muestra el histograma, RMSE y *bias* para las siguientes estimaciones, (a)  $LAI_{DHP} : LAI_{LICOR}$ , (b)  $FVC_{DHP} : FVC_{LICOR}$ , (c)  $FVC_{DHP-BANDAS} : FVC_{DHP-NDVI}$ , y (d)  $FAPAR_{DHP-BANDAS} : FAPAR_{DHP-NDVI}$ .

En el caso del LAI, existe una tendencia por parte de la función  $LAI_{LICOR}$  a obtener un mayor porcentaje para valores cercano a 0, mientras que la función  $LAI_{DHP}$  muestra dicha tendencia para valores entre 0.5 y 2. El RMSE entre ambas estimaciones pone de manifiesto que se obtiene el error más alto para niveles de cubierta bajo (alrededor de 0.3) y el más bajo para cubiertas densas (alrededor de 0.1), siendo en general un error aceptable dentro del rango de variación del LAI. Las diferencias en términos del *bias* muestran una sobreestimación por parte de la función  $LAI_{DHP}$  con valor medio de hasta 0.3 para cubiertas poco densas e intermedias ( $NDVI < 0.6$ ). El *bias* muestra valores menores de cero a partir de cubiertas densas ( $NDVI > 0.6$ ) debido a la mayor proporción de valores que muestra la función  $LAI_{LICOR}$  a partir de valores superiores a 5.

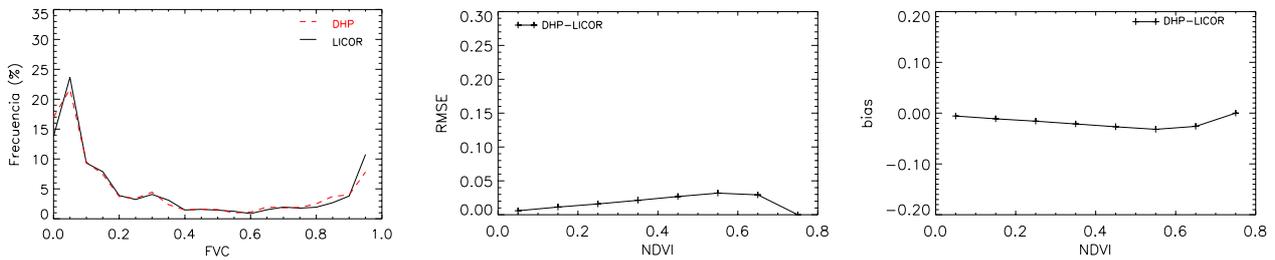
En el caso de la FVC, la figura IV.8b muestra la alta correlación en las estimaciones derivadas de las funciones  $FVC_{LICOR}$  y  $FVC_{DHP}$ , con un *bias* aproximadamente nulo y un RMSE muy bajo que no alcanza valores superiores a 0.04 en las cubiertas densas. Por otra parte, se han evaluado las diferencias para la  $FVC_{DHP}$  entre las estimaciones derivadas de la función por bandas 123 y el NDVI. La figura IV.8c muestra el histograma, RMSE y *bias* obtenido para ambas estimaciones. Aunque no se observan diferencias importantes en términos de *bias* y RMSE, el histograma de ambas funciones muestra una tendencia por parte de la función  $FVC_{DHP-BANDAS}$  a sobreestimar la FVC en cubiertas donde se observó experimentalmente que correspondían a suelo desnudo o vegetación senescente.

Por último, en el caso de la FAPAR también se han analizado las diferencias debido a las estimaciones obtenidas con la función 123 y el NDVI. La figura IV.8c muestra una mayor proporción de valores entre (0.4-0.6) para la función por bandas que para el NDVI. La diferencia en las estimaciones realizadas por ambas funciones, se traduce en un RMSE mayor para cubiertas bajas e intermedias de hasta 0.14. El *bias* confirma cómo la función  $FAPAR_{DHP-BANDAS}$  proporciona valores más altos de FAPAR para cubiertas baja e intermedias.

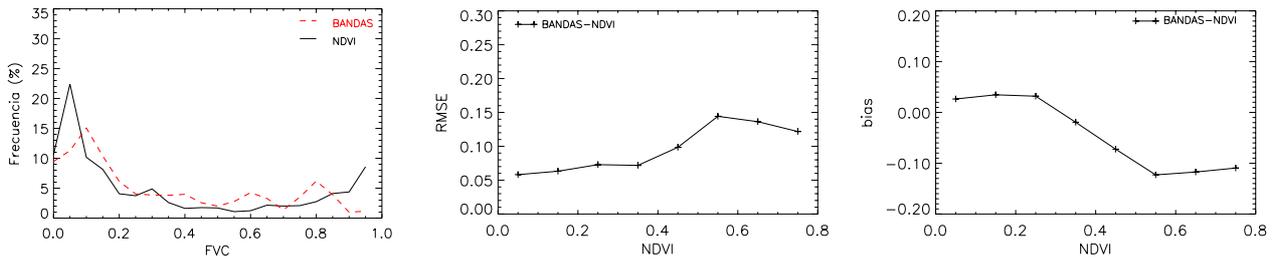
(a)  $LAI_{DHP} : LAI_{LICOR}$



(b)  $FVC_{DHP} : FVC_{LICOR}$



(c)  $FVC_{DHP-BANDAS} : FVC_{DHP-NDVI}$



(d)  $FAPAR_{DHP-BANDAS} : FAPAR_{DHP-NDVI}$

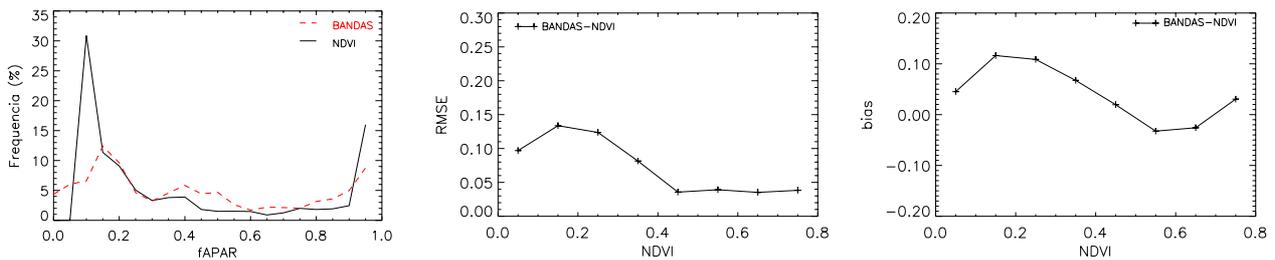


Figura IV.8. Histograma, RMSE y bias obtenido entre las siguientes parejas de funciones: ( $LAI_{DHP}$ ,  $LAI_{LICOR}$ ), ( $FVC_{DHP}$ ,  $FVC_{LICOR}$ ), ( $FVC_{DHP-BANDAS}$ ,  $FVC_{DHP-NDVI}$ ) y ( $FAPAR_{DHP-BANDAS}$ ,  $FAPAR_{DHP-NDVI}$ ).

IV.1.4 Quality Flag (QF)

En este apartado se propone la técnica *convex hull* para evaluar las limitaciones del modelo en la caracterización de la zona de estudio. A partir de la información

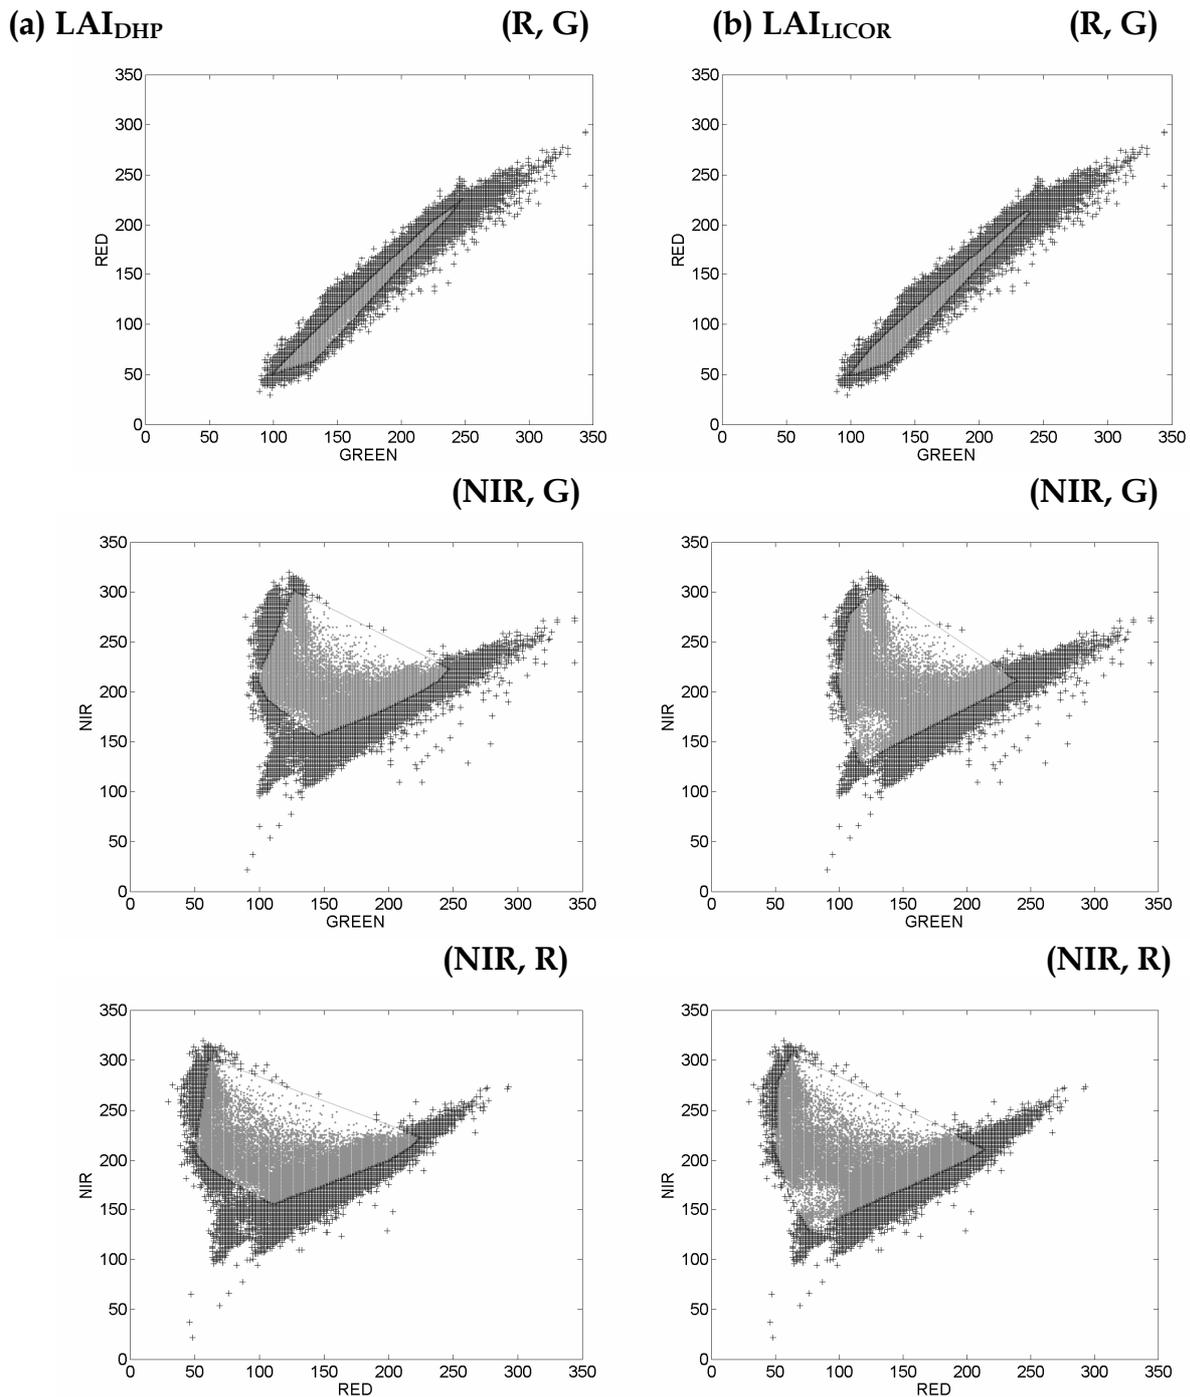
proporcionada por el *convex hull* se crea una imagen de calidad o *quality flag* (QF) que indica si los píxeles a los que se aplica la FT han sido interpolados o extrapolados por la función. Tal como se ha explicado anteriormente, el *convex hull* es la mínima región convexa definida por un conjunto de datos. Este método se ha demostrado de gran utilidad para técnicas de clasificación y selección de *edmembers* en una imagen. Dado que se obtienen diferentes regiones convexas al variar las bandas, el número de medidas y su posición, esta técnica será adecuada tanto para evaluar el modelo como para evaluar el muestreo espacial.

En nuestro caso, el procedimiento consiste en el cálculo del *convex hull* a partir de cada conjunto de datos *in-situ* (i.e. LAI<sub>LICOR</sub>, LAI<sub>DHP</sub>, FVC<sub>LICOR</sub>, FVC<sub>DHP</sub> y FAPAR<sub>DHP</sub>) y los valores de radiancias que se localizan en la misma posición que las medidas *in-situ*. De este modo, los píxeles de la imagen localizados dentro de la región convexa definida por este conjunto de datos se considerarán interpolados por el modelo (Weiss 2004b), mientras que los situados fuera de la región serán tratados como extrapolados por el modelo.

En el caso del LAI<sub>LICOR</sub> y LAI<sub>DHP</sub>, se ha calculado el *convex hull* en dos dimensiones para todas las posibles combinaciones de las bandas que intervienen en la FT (i.e. G, R y NIR). Posteriormente, se ha creado una imagen QF donde aquellos píxeles situados dentro de la región convexa (e.g. interpolados por la función) se les han asignado el valor de 1. En el caso de que no se localicen dentro de ninguna región definida por los *convex hulls*, se les asociará el valor QF=0 indicando que la FT no representa adecuadamente estos píxeles y, por tanto, se consideran extrapolados por la función.

La figura IV.9 muestra los tres *convex hulls* obtenidos para el LAI<sub>DHP</sub> (a) y el LAI<sub>LICOR</sub> (b) a partir de las combinaciones de bandas (R, G), (NIR, G) y (NIR, R). Los *convex hulls* se han superpuesto junto con todos los píxeles de la imagen de alta resolución. En gris se muestran aquellos píxeles incluidos dentro de la región convexa y en negro los extrapolados por la FT. En este último caso, dichos píxeles no están considerados en el modelo y por tanto habría que realizar un muestreo más intensivo en esas localizaciones para disponer de una mejor caracterización de esta clase.

Con el objetivo de evaluar cómo afecta en las estimaciones el hecho de que la FT se defina a partir de un conjunto de datos con un cierto error, se ha calculado el *convex hull* con los datos del LAI añadiendo a los valores de radiancias un error relativo del 5%. Se ha considerado este error como representativo del SNR (*Signal to Noise Ratio*) de los datos y, por tanto, del nivel de tolerancia asociado a los datos. La figura IV.10 muestra las imágenes QF derivadas a partir del *convex hull* calculado con el conjunto de datos LAI<sub>DHP</sub> (a) y LAI<sub>LICOR</sub> (b). Los píxeles en blanco corresponden a los interpolados por la función (QF=1), en negro los extrapolados (QF=0) y en azul los píxeles que se han obtenido al calcular el *convex hull* con el error relativo del 5% en las radiancias (QF=1).



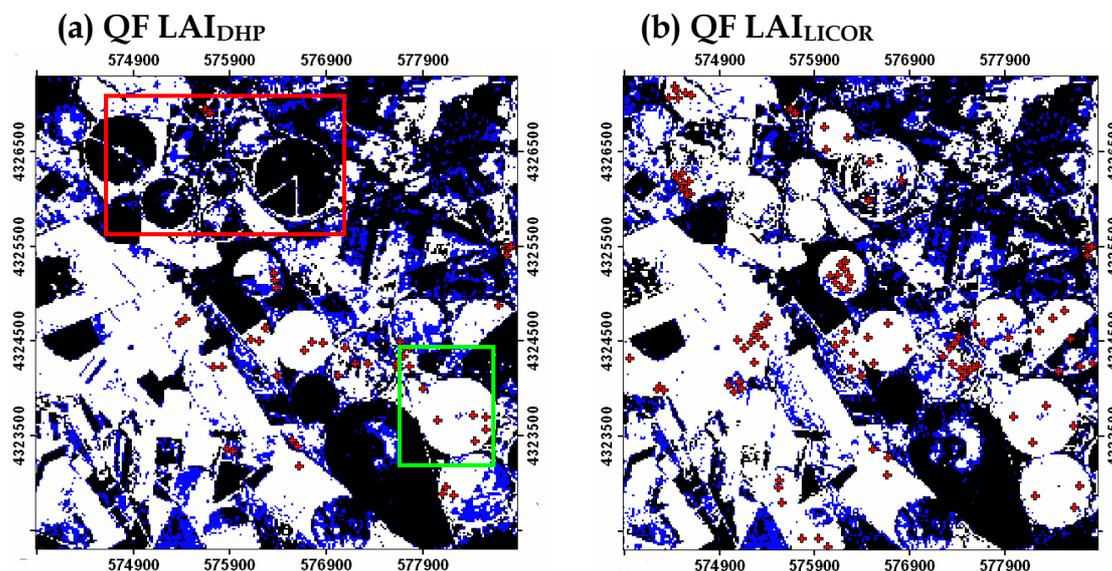
**Figura IV.9.** *Convex hulls* bidimensionales obtenidos a partir de los valores de radiancias colocados con las medidas *in-situ* LAI<sub>DHP</sub> (a) y LAI<sub>LICOR</sub> (b). Los tres *convex hull* pertenecen a las combinaciones (R, G), (NIR, G) y (NIR, R). En gris se muestran los píxeles de la imagen que se localizan dentro de la mínima región convexa.

Al considerar el error relativo del 5%, los píxeles interpolados aumentan en un 18.2% (de 42.8% a 61%) para la función LAI<sub>DHP</sub> y un 19.7% (de 53.3% a 73%) para la LAI<sub>LICOR</sub>. La diferencia de píxeles extrapolados entre ambas funciones es del 8%

(e.g.  $LAI_{DHP}$ : 39% y  $LAI_{LICOR}$ : 27%), la cual corresponde principalmente a la clase de suelo. Puesto que las FTs en ambos casos presentaban las mismas bandas y coeficientes similares, esta diferencia se atribuye, principalmente, al muestreo espacial realizado con cada instrumento.

Si se comparan las figuras IV.10a y IV.10b se observa una mejor caracterización de algunos cultivos en las estimaciones derivadas del  $LAI_{LICOR}$  debido a una mejor localización de las ESUs en este conjunto de datos. Un ejemplo son las tres ESUs adquiridas en el campo de Maíz (C2) situado en la esquina inferior derecha de la imagen (recuadro verde) y las seis ESUs adquiridas en dos de los seis campos de Alfalfa (A6 y A2) localizados en la esquina superior izquierda (recuadro rojo). En el primer caso se ha obtenido una mejor caracterización del cultivo cambiando la posición de las ESUs y sin necesidad de añadir más unidades, mientras que en el segundo se ha conseguido la caracterización de los seis campos de Alfalfa midiendo solamente en dos de ellos.

En el caso del campo C2, este comportamiento puede ser explicado por la alta heterogeneidad espacial observada al analizar el parámetro NDVI (ver Sección II.1.4) y experimentalmente durante la campaña. De modo que, se obtendrá una mejor caracterización de la variabilidad del parámetro si se distribuyen las ESUs por todo el campo que si se agrupan en una misma zona. Por el contrario, en el caso de la Alfalfa los campos mostraban, tanto experimentalmente como a partir de la imagen de NDVI, una distribución espacial muy homogénea con valores de NDVI alrededor de 0.6. De modo que, caracterizando sólo dos campos fue suficiente para describir la variabilidad del resto.



**Figura IV.10.** Imágenes de QF correspondientes a las FTs obtenidas para el  $LAI_{DHP}$  (a) y el  $LAI_{LICOR}$  (b). Los píxeles en negro corresponden a  $QF=1$ , en blanco a los valores de  $QF=0$  y en azul a los píxeles con  $QF=1$  al considerar el *convex hull* añadiendo el error relativo.

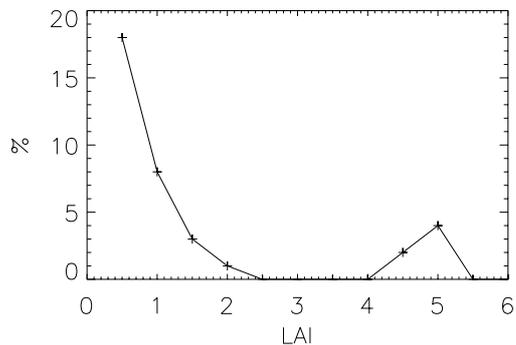
En el caso de la FVC y FAPAR, las imágenes de QF se han obtenido a partir del *convex hull* calculado al descomponer el NDVI como el producto de dos factores, (NIR-R) y (NIR+R)<sup>-1</sup>. En el caso de la FVC, la diferencia de píxeles no interpolados entre FVC<sub>DHP</sub> y FVC<sub>LICOR</sub> corresponde a un 9% (e.g. 20.2% y 11.7%), el cual se asume que se debe principalmente al muestreo realizado con cada instrumento. Al igual que para el LAI, se obtiene un mayor porcentaje de píxeles caracterizados por el muestreo del LICOR. En el caso de la FAPAR, el porcentaje de píxeles no interpolados corresponde a un 18.9%.

La figura IV.11 muestra el porcentaje de píxeles no interpolados por las funciones LAI<sub>DHP</sub>, LAI<sub>LICOR</sub>, FVC<sub>DHP</sub>, FVC<sub>LICOR</sub> y FAPAR<sub>DHP</sub>. En general, se observa para los tres parámetros que los valores más bajos son los peor caracterizados, como es el caso del suelo desnudo y vegetación dispersa. En el caso del LAI (figura IV.11a y IV.11b), se obtiene el máximo de píxeles no interpolados (20%) para valores de LAI alrededor de 0.5 y un pico alrededor de 5, que aunque contribuye con un porcentaje pequeño pone de manifiesto la necesidad de caracterizar mejor este rango.

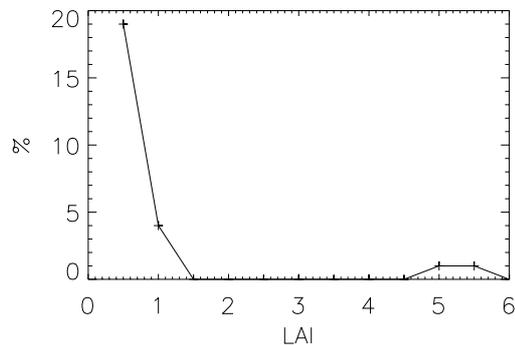
Para la FVC (figura IV.11c y IV.11d), dicho máximo se sitúa en valores alrededor de 0.1, mientras que para la FAPAR, se observa cómo el rango peor caracterizado corresponde a cubiertas con valores alrededor de 0.2 (figura IV.11e). Por último, la imagen de QF obtenida con el muestreo realizado con el LICOR muestra una distribución de píxeles no interpolados concentrada en un rango menor de LAI y FVC, lo que pone de manifiesto este muestreo como el más adecuado para caracterizar la variabilidad del LAI y FVC presente en la zona de estudio. Debido a este comportamiento, se han elegido los mapas de LAI<sub>LICOR</sub> y FVC<sub>LICOR</sub> para realizar la validación de productos en el capítulo siguiente.

Por último, se ha evaluado el error asociado a los píxeles extrapolados. El procedimiento llevado a cabo para obtener este error consiste en eliminar del conjunto de datos original (i.e. LAI<sub>LICOR</sub> o LAI<sub>DHP</sub>) un subconjunto de observaciones (entre 11 y 15) y volverlas a estimar con la nueva función de transferencia. El error de extrapolación se ha evaluado para dos casos, (i) eliminando datos localizados fuera de la región convexa y no más del 5% de los valores de radiancia que definen dicha región (CH1) y (ii) eliminando datos localizados en el interior del *convex hull*, concretamente dentro de la región definida por el 5% de las radiancias del valor central de la región convexa (CH2). Este análisis permitirá evaluar el muestreo y la influencia que tienen las ESUs en la FT según su localización respecto al *convex hull*. El error se ha evaluado sólo para el LAI y con el conjunto de datos derivado del LICOR, puesto que proporcionaba un mayor número de ESUs.

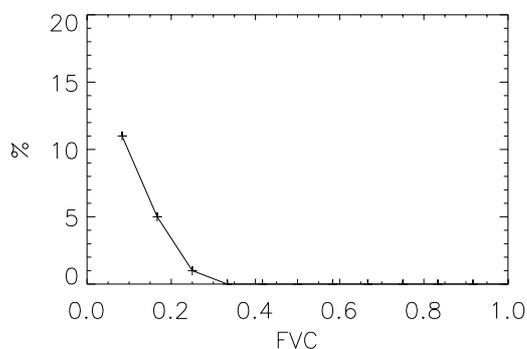
(a) LAI<sub>DHP</sub>



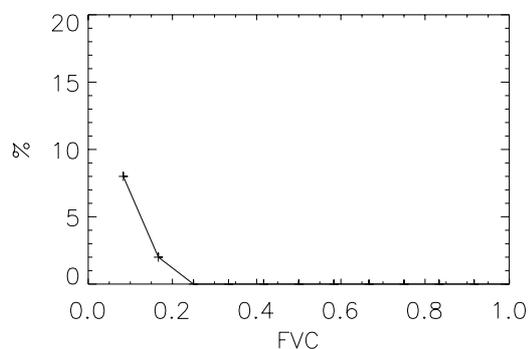
(b) LAI<sub>LICOR</sub>



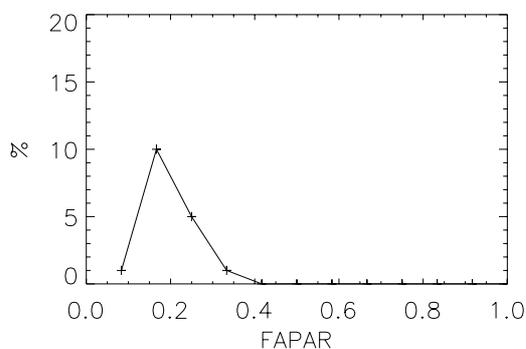
(c) FVC<sub>DHP</sub>



(d) FVC<sub>LICOR</sub>



(e) FAPAR<sub>DHP</sub>



**Figura IV.11.** Porcentaje de píxeles no interpolados por las funciones LAI<sub>DHP</sub> (a), LAI<sub>LICOR</sub> (b), FVC<sub>DHP</sub> (c), FVC<sub>LICOR</sub> (d) y FAPAR<sub>DHP</sub> (e).

La tabla IV.2 muestra los coeficientes y errores (i.e. RMSE, RW y RC) de las FTs obtenidas para los casos CH1 y CH2. Se observan errores y coeficientes asociados a las bandas similares a los obtenidos con la FT original (G: -0.011, R: 0.014, NIR: 0.02, RMSE=0.6, RW=0.5 y RC=0.6). Las diferencias más importantes hacen referencia a la ordenada en el origen, la cual aumenta considerablemente (1.6) cuando se eliminan datos fuera de la región del *convex hull*.

El error asociado a la extrapolación se ha evaluado comparando las estimaciones de los datos no incluidos en el cálculo de las nuevas funciones (i.e. FT1 y FT2) con las medidas *in-situ* del LICOR LAI2000. También se han comparado estas estimaciones con las proporcionadas por la función original (i.e. FT) para analizar el error asociado entre funciones. En principio, cabe esperar pequeñas diferencias entre funciones dado que sus coeficientes eran similares a la FT original.

La tabla IV.3 muestra el error de extrapolación obtenido, el cual alcanza valores de 0.9 cuando los datos extrapolados se localizan fuera del *convex hull* (CH1\_*in-situ*). En el caso de datos situados dentro del *convex hull*, el error es sólo de 0.3 aunque la correlación con los datos *in-situ* es menor (0.81). Por otra parte, las diferencias entre funciones muestran ser menores con valores máximo de 0.2 y una alta correlación con las estimaciones derivadas de la FT original ( $r=0.99$ ). En este caso, el modelo de regresión utilizado es poco sensible a la eliminación de datos del interior del *convex hull*, los cuales muestran un error casi nulo con las estimaciones de la FT original (0.018).

**Tabla IV.2.** Coeficientes y errores RMSE, RW y RC asociados a las funciones de transferencia obtenidas con los conjuntos de datos CH1 y CH2.

|         | Coeficientes<br>(G, R, NIR) | Ordenada | RMSE | RW  | RC  |
|---------|-----------------------------|----------|------|-----|-----|
| CH1_FT1 | (-0.012, -0.015, 0.018)     | 1.6      | 0.5  | 0.5 | 0.6 |
| CH2_FT2 | (-0.004, -0.018, 0.020)     | 0.4      | 0.6  | 0.6 | 0.7 |

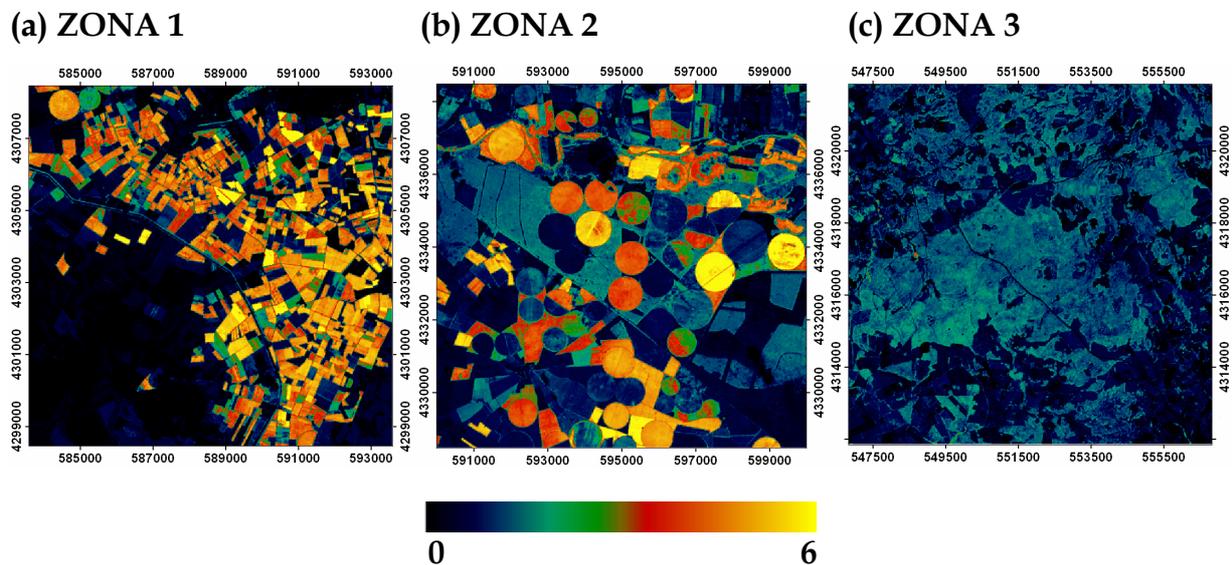
**Tabla IV.3.** RMSE y coeficiente de correlación entre las estimaciones de los datos eliminados con las funciones FT1 y FT2 respecto a las estimaciones de la FT original (i.e. CH1\_FT y CH2\_FT) y respecto a los valores *in-situ* (i.e. CH1\_*in-situ* y CH2\_*in-situ*).

|                     | RMSE  | r    |
|---------------------|-------|------|
| CH1_ <i>in-situ</i> | 0.9   | 0.91 |
| CH2_ <i>in-situ</i> | 0.3   | 0.80 |
| CH1_FT              | 0.2   | 0.99 |
| CH2_FT              | 0.018 | 0.99 |

#### IV.1.5. Evaluación de la FT en el área 50×50 km<sup>2</sup>.

En este apartado se incluye un análisis estadístico de la FT para los tres parámetros en el área de 50×50 km<sup>2</sup> y, de este modo, evaluar la función de transferencia en otras cubiertas no incluidas en el muestreo *in-situ*. Para ello, se han elegido tres zonas de 10×10 km<sup>2</sup> representativas de los diferentes tipos de cubiertas presentes dentro del área de 50×50 km<sup>2</sup>. Las funciones a evaluar corresponden a los mapas que utilizaremos en el capítulo siguiente, LAI<sub>LICOR</sub>, FVC<sub>LICOR</sub> y FAPAR<sub>DHP</sub>. La figura IV.12 muestra los mapas de LAI obtenidos con la función LAI<sub>LICOR</sub> para las

tres zonas. La zona 1 se ha seleccionado por su alta presencia de cultivos y suelo desnudo al igual que el área de  $5 \times 5 \text{ km}^2$ . La zona 2 presenta una mezcla de cultivos y bosque, mientras que en la zona 3 predomina cubierta de bosque y suelo desnudo.

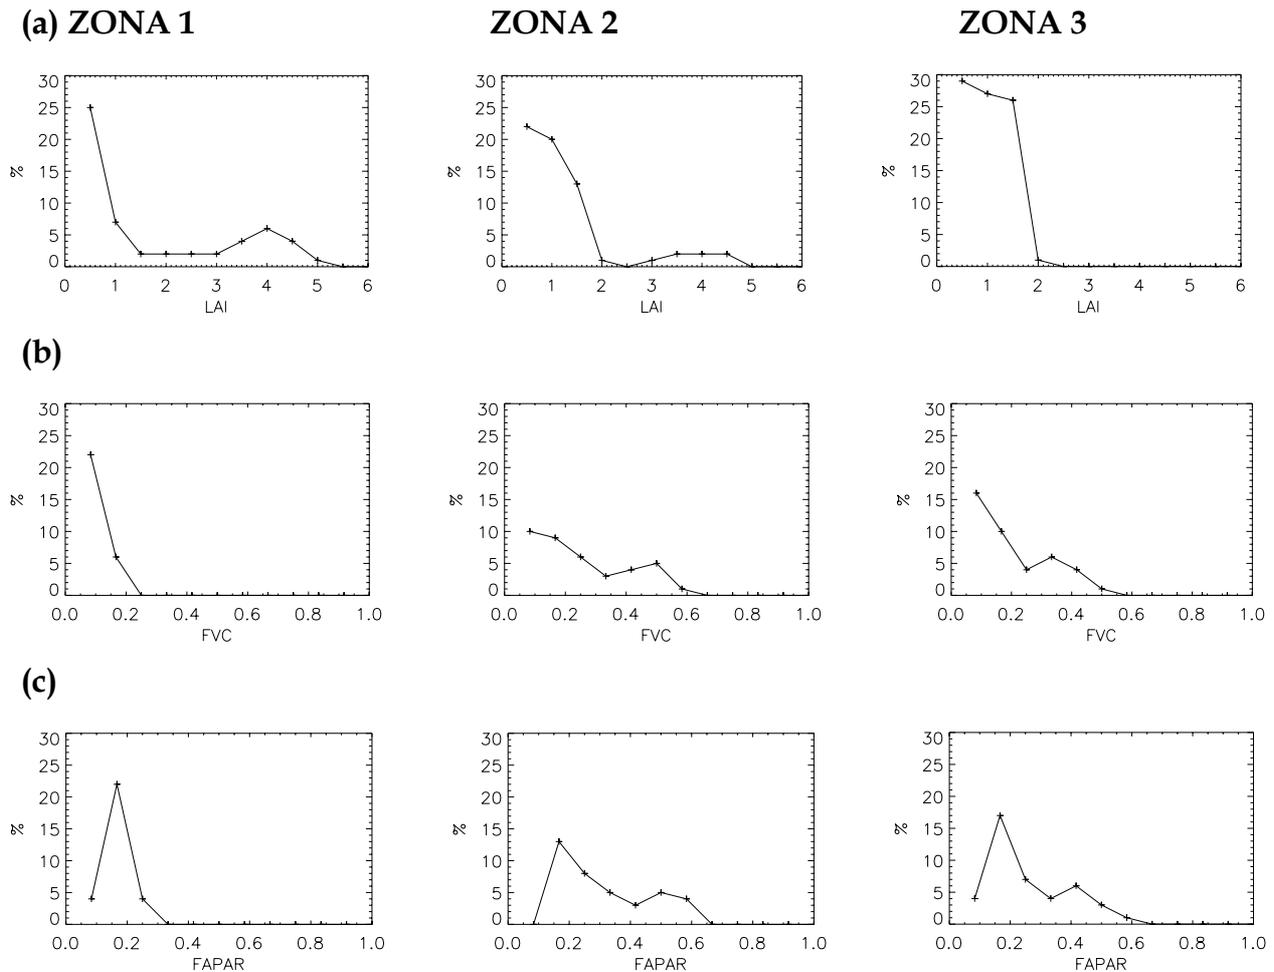


**Figura IV.12.** Mapas de LAI<sub>LICOR</sub> para tres zonas de  $10 \times 10 \text{ km}^2$  dentro del área de  $50 \times 50 \text{ km}^2$ . Las zonas corresponden a un área con (a) alta presencia de cultivos, (b) predominio de bosque y cultivos y (c) alta presencia de bosque y suelo desnudo.

Se ha calculado la imagen de QF para cada zona con el método anteriormente descrito y se han analizado las diferencias en las distribuciones de píxeles no interpolados en función del rango de variación de cada parámetro. La figura IV.13 muestra la distribución de porcentajes de píxeles no interpolados en función de cada parámetro con el fin de determinar que rango de valores no ha sido caracterizado por la función.

Para el LAI (figura IV.13a), se observa en las tres áreas que los valores más bajos son los que están peor caracterizados por la función LAI<sub>LICOR</sub>. En el caso de la zona 1, se observa una mala caracterización del suelo desnudo y cubiertas dispersas dado el alto porcentaje mostrado para valores de LAI muy bajos (e.g. 0.5). En esta zona también se observa un 5% de píxeles no caracterizados por la función alrededor de valores de LAI igual a 4. Para la zona 2, se observa un desplazamiento del histograma respecto a la zona 1 hacia valores de LAI alrededor de 1. Este comportamiento se debe a la menor presencia de suelo desnudo sustituida por cubiertas de bosque. Se mantiene el pico alrededor de 4 observado en la zona 1, dada la presencia de cultivos. Por último, se observa para el área 3 cómo el histograma se sitúa entre valores de 0 y 2 dada la alta presencia de suelo desnudo y cubiertas de bosque. Se concluye una buena caracterización por parte de la función LAI<sub>LICOR</sub> en las cubiertas de cultivos mientras que se presentará una mayor incertidumbre en las cubiertas de suelo desnudo y bosque.

Para la FVC y FAPAR los resultados son similares (figura IV.13b y 13c). Se observa el máximo de píxeles no interpolados para valores del parámetro muy bajo en la zona 1 debido a la alta presencia de suelo, el cual se desplaza hacia valores más altos de FVC y FAPAR en las zonas 2 y 3 debido a una mayor presencia de cubierta de bosque no incluida en la función de transferencia. El porcentaje de píxeles no interpolados aumenta para la FVC y FAPAR en una 14% de la zona 1 a la zona 3 (e.g. Zona 1: 30%-32.4%, Zona 2: 44%-44% y Zona 3: 44.7%-46.2%).



**Figura IV.13.** Distribución de píxeles no interpolados por las funciones LAI<sub>LICOR</sub> (a), FVC<sub>LICOR</sub> (b) y FAPAR<sub>DHP</sub> (c) en función del rango de variabilidad mostrado por cada parámetro.

Para finalizar, se resumen a continuación las principales conclusiones derivadas de este estudio:

1. Las funciones de transferencia para el LAI, FVC y FAPAR presentan un RC de aproximadamente 0.7, 0.19 y 0.18, respectivamente, que puede considerarse un estimador realista del error.
2. La alta correlación ( $r=0.98$ ) y bajo error (RMSE=0.26) entre los mapas LAI<sub>LICOR</sub> y LAI<sub>DHP</sub> indica una alta consistencia entre ambos productos

- derivados a partir de muestreos espaciales y funciones de transferencia diferentes.
3. El mapa  $FVC_{LICOR}$  es casi idéntico al  $FVC_{DHP}$  y, por tanto, se confirma la validez de ambos métodos para estimar la FVC.
  4. La alta consistencia entre los mapas derivados con muestreos diferentes, pone de manifiesto que el número de ESUs adquiridas con la cámara hemisférica (aprox. 50) es adecuado para caracterizar la variabilidad de la zona de estudio.
  5. El *convex hull* que definen los espectros de las medidas es una herramienta adecuada para evaluar la influencia del muestreo en las estimaciones.
  6. ESUs localizadas fuera de la región convexa proporcionan errores de extrapolación del orden de 0.9. El modelo de regresión muestra ser poco sensible cuando no se consideran ESUs localizadas dentro del *convex hull* (RMSE=0.3).
  7. El alto porcentaje de píxeles no interpolados obtenido para suelo desnudo y vegetación dispersa indica la falta de representatividad y, por tanto, un mayor error de LAI, FVC y FAPAR bajos en este tipo de superficies.
  8. Los mapas estimados de  $LAI_{LICOR}$  y  $FVC_{LICOR}$  muestran una mejor caracterización de la variabilidad dado que la distribución de píxeles no interpolados para el  $LAI_{LICOR}$  y  $FVC_{LICOR}$  se concentra en un rango menor de LAI y FVC respecto al caso de  $LAI_{DHP}$  y  $FVC_{DHP}$ . Por ello, se han escogido los mapas de  $LAI_{LICOR}$  y  $FVC_{LICOR}$  para llevar a cabo el ejercicio de validación de productos.

A continuación se plantea el problema de estimar los mapas a alta resolución a partir de varios modelos de interpolación basados en la geoestadística. La estimación se llevará a cabo sólo con el parámetro LAI para simplificar el estudio.

## IV.2 Técnicas geoestadísticas

En este apartado se evalúan los resultados derivados de la aplicación de técnicas geoestadísticas para la estimación de mapas de parámetros biofísicos. Las técnicas aplicadas fueron el krigado ordinario, el krigado con deriva externa y el cokrigado colocalizado. La forma de evaluar los tres métodos consistirá en comparar las estimaciones con las obtenidas por la función de transferencia en la sección anterior. El estudio se realizará sólo con el parámetro LAI para simplificar el problema y se utilizarán los dos conjuntos de datos disponibles (e.g.  $LAI_{LICOR}$  y  $LAI_{DHP}$ ) y, así, evaluar la influencia del muestreo en las estimaciones, como se hizo en el apartado anterior.

Tal como se ha comentado en el capítulo I (Sección I.6.3.1), el procedimiento para estimar los mapas de LAI implica, en primer lugar, conocer el patrón de

continuidad desespacial de las variables en juego. Para el estimador CKC utilizando un modelo Markov (Sección I.6.2.4), se requiere conocer el coeficiente de correlación entre la variable primaria y secundaria.

Los códigos utilizados para aplicar los tres algoritmos geoestadísticos pertenecen a la librería GSLIB<sup>24</sup> (Geostatistical Software LIBrary) escrita en Fortran (Deutsch & Journel 1998). Esta librería consiste en una colección de programas geoestadísticos de libre distribución desarrollados por estudiantes y profesores de la Universidad de Stanford.

### IV.2.1 Análisis de la continuidad espacial

El primer paso consiste en calcular el variograma omnidireccional para la variable primaria. A continuación, se calculan los variogramas direccionales. En nuestro caso, se han elegido 9 direcciones entre 0 y 180° separadas 20° (10°, 30°, 50°, 70°, 90°, 110°, 130°, 150° y 170°). El ajuste de los modelos se ha realizado de forma interactiva, variando los parámetros en el menú facilitado por el programa Variowin (Pannatier 1996) hasta que el parámetro estadístico que indica la bondad del ajuste proporcione el menor valor. Dicho parámetro se define según la expresión (Pannatier 1996):

$$IGF = \frac{1}{N} \sum_{k=1}^N \sum_{i=0}^{n(k)} \frac{P(i)}{\sum_{j=0}^{n(k)} P(j)} \cdot \frac{D(k)}{d(i)} \cdot \left[ \frac{\gamma(i) - \hat{\gamma}(i)}{\sigma^2} \right]^2 \quad \text{[IV.5]}$$

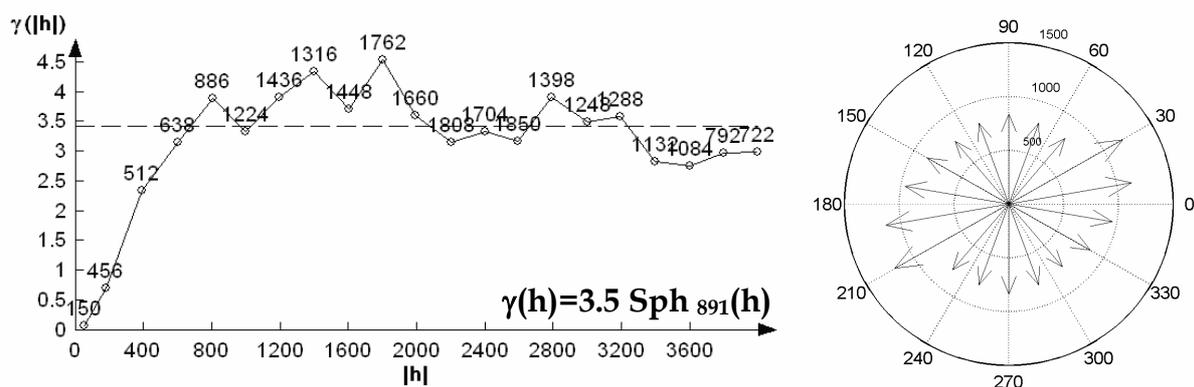
donde  $N$  es el número de variogramas direccionales considerados en el modelo,  $n(k)$  el número de direcciones de separación ( $\mathbf{h}(i)$ ) para el variograma  $k$ ,  $D(k)$  la distancia máxima para la que se calcula el variograma  $k$ ,  $P(i)$  el número de parejas de puntos para  $\mathbf{h}(i)$ ,  $d(i)$  la distancia media a la que se encuentran las parejas de puntos para  $\mathbf{h}(i)$ ,  $\gamma(i)$  el variograma experimental para el  $\mathbf{h}(i)$ ,  $\hat{\gamma}(i)$  el variograma modelado para el  $\mathbf{h}(i)$  y  $\sigma^2$  la varianza del conjunto de observaciones.

En nuestro caso, el conjunto de datos presenta una distribución espacial irregular, de modo que, tal como se ha descrito en el capítulo I, la distancia de separación conviene calcularla como la distancia media de separación entre las observaciones (200 m y 400 m para el conjunto de datos LAI<sub>DHP</sub> y LAI<sub>LICOR</sub>). La distancia media se obtiene como la mitad de la distancia máxima de separación entre observaciones (2000 m y 3050 m para LAI<sub>DHP</sub> y LAI<sub>LICOR</sub>, respectivamente). Estos parámetros se mantienen tanto para el variograma omnidireccional como para los direccionales. La dirección y tolerancia angular para el variograma omnidireccional corresponden a 0° y 90°, respectivamente, mientras que para los variogramas direccionales la

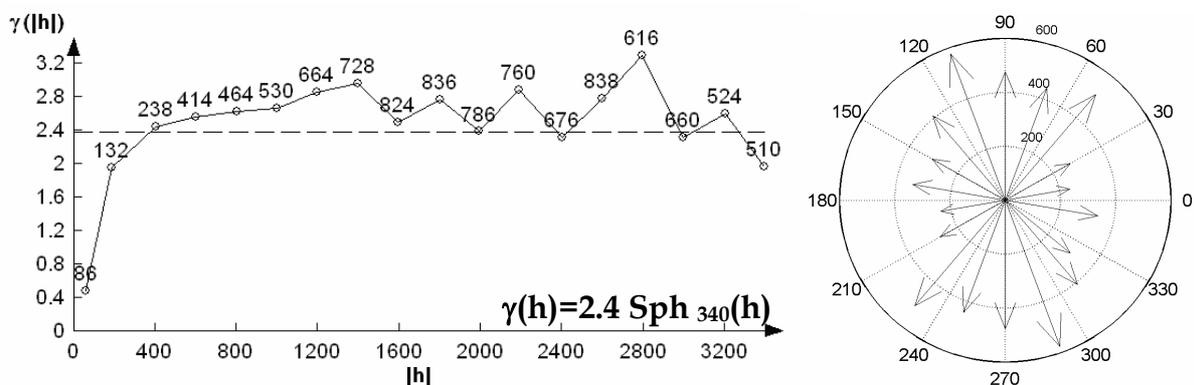
<sup>24</sup> <http://www.gslib.com>

tolerancia angular se fija a 45°. La figura IV.14 muestra los variogramas omnidireccionales (izquierda) y los alcances obtenidos de los variogramas direccionales (derecha) para los conjuntos de datos LAI<sub>LICOR</sub> (a) y LAI<sub>DHP</sub> (b). Se ha representado el variograma experimental, es decir el valor de la función  $\gamma(h)$  para las diferentes distancias de separación elegidas, junto con las parejas de puntos que intervienen en el cálculo.

(a) LAI<sub>LICOR</sub>



(b) LAI<sub>DHP</sub>



**Figura IV.14.** Variogramas omnidireccionales y estudio de la anisotropía para el parámetro LAI obtenido de los conjuntos de datos LAI<sub>LICOR</sub> (a) y LAI<sub>DHP</sub> (b).

En general, se observa un comportamiento del variograma más suave con los datos LAI<sub>LICOR</sub> respecto a los datos LAI<sub>DHP</sub>, el cual muestra una pendiente más acusada para distancias cortas. Por ello, cabe esperar que la estimación del LAI con el conjunto de datos LAI<sub>DHP</sub> presente posteriormente una mayor variabilidad a distancias pequeñas que la que se observaría en el caso de utilizar los datos LAI<sub>LICOR</sub> (Isaacs & Srivastava 1996). Posteriormente, hemos ajustado a los variogramas experimentales modelos esféricos caracterizados por los parámetros, meseta, alcance y efecto pepita. Se observan, alcances del orden de los 1100 m para el caso LAI<sub>LICOR</sub> y de 300 m para el LAI<sub>DHP</sub>.

La figura IV.14 (derecha) muestra los alcances derivados de dichos modelos para los variogramas direccionales. En este caso, se identifican dos direcciones de anisotropía definidas por los ejes máximo y mínimo de la elipse. Para el conjunto de datos LAI<sub>LICOR</sub> (figura IV.14a derecha), se observa una anisotropía muy débil en la dirección 60° NE, mientras que el conjunto de observaciones realizadas con la cámara hemisférica (figura IV.14b derecha) muestra una anisotropía más marcada en la dirección 20° NO. Los valores máximo y mínimo del alcance para los dos conjuntos de datos se han representado en la tabla IV.4 mediante el parámetro  $r$ , el cual indica el grado de anisotropía. En el caso de que no exista anisotropía, el valor de  $r$  es igual a 1, disminuyendo su valor a medida que aumenta la anisotropía en una determinada dirección. La dirección principal es aquella en el que el alcance es máximo. Estos parámetros son los que se introducirán en los modelos para incluir la anisotropía presente en los conjuntos de datos.

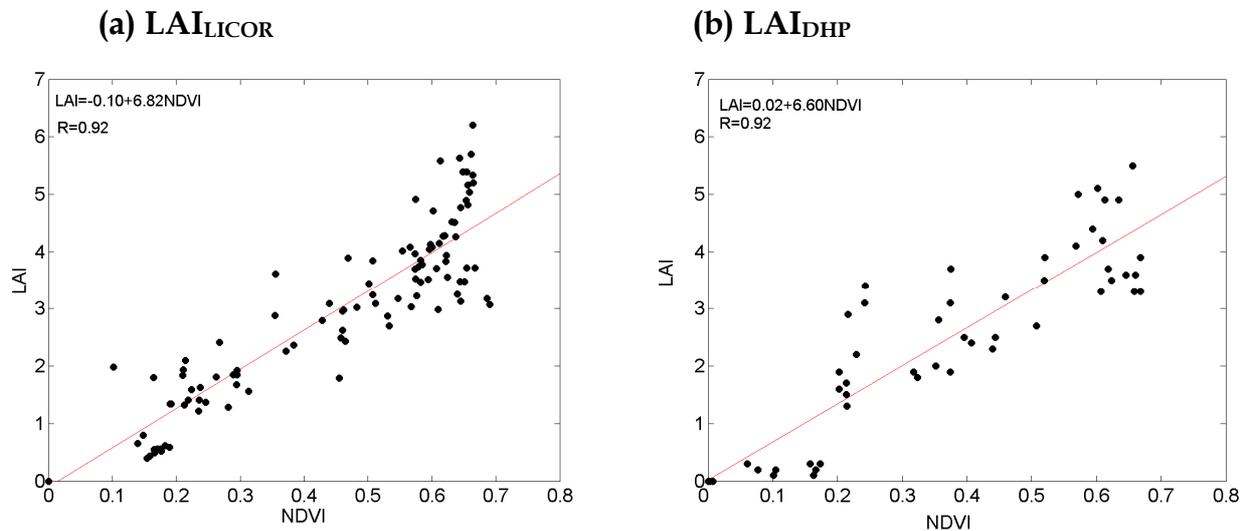
**Tabla IV.4.** Parámetros relacionados con la anisotropía,  $r$  y dirección de máximo alcance.

|                      | $r=a_{\min}/a_{\max}$ | Meseta | Efecto pepita | Dirección principal |
|----------------------|-----------------------|--------|---------------|---------------------|
| LAI <sub>LICOR</sub> | 0.63                  | 3.5    | 0             | 60° NE              |
| LAI <sub>DHP</sub>   | 0.41                  | 2.4    | 0             | 160° NE             |

## IV.2.2 Variable secundaria

Para calcular la correlación entre la variable primaria y secundaria, se extraen los valores de la variable secundaria que coinciden con la posición de las medidas *in-situ* y se calcula el coeficiente de correlación lineal entre los valores colocalizados de ambas variables.

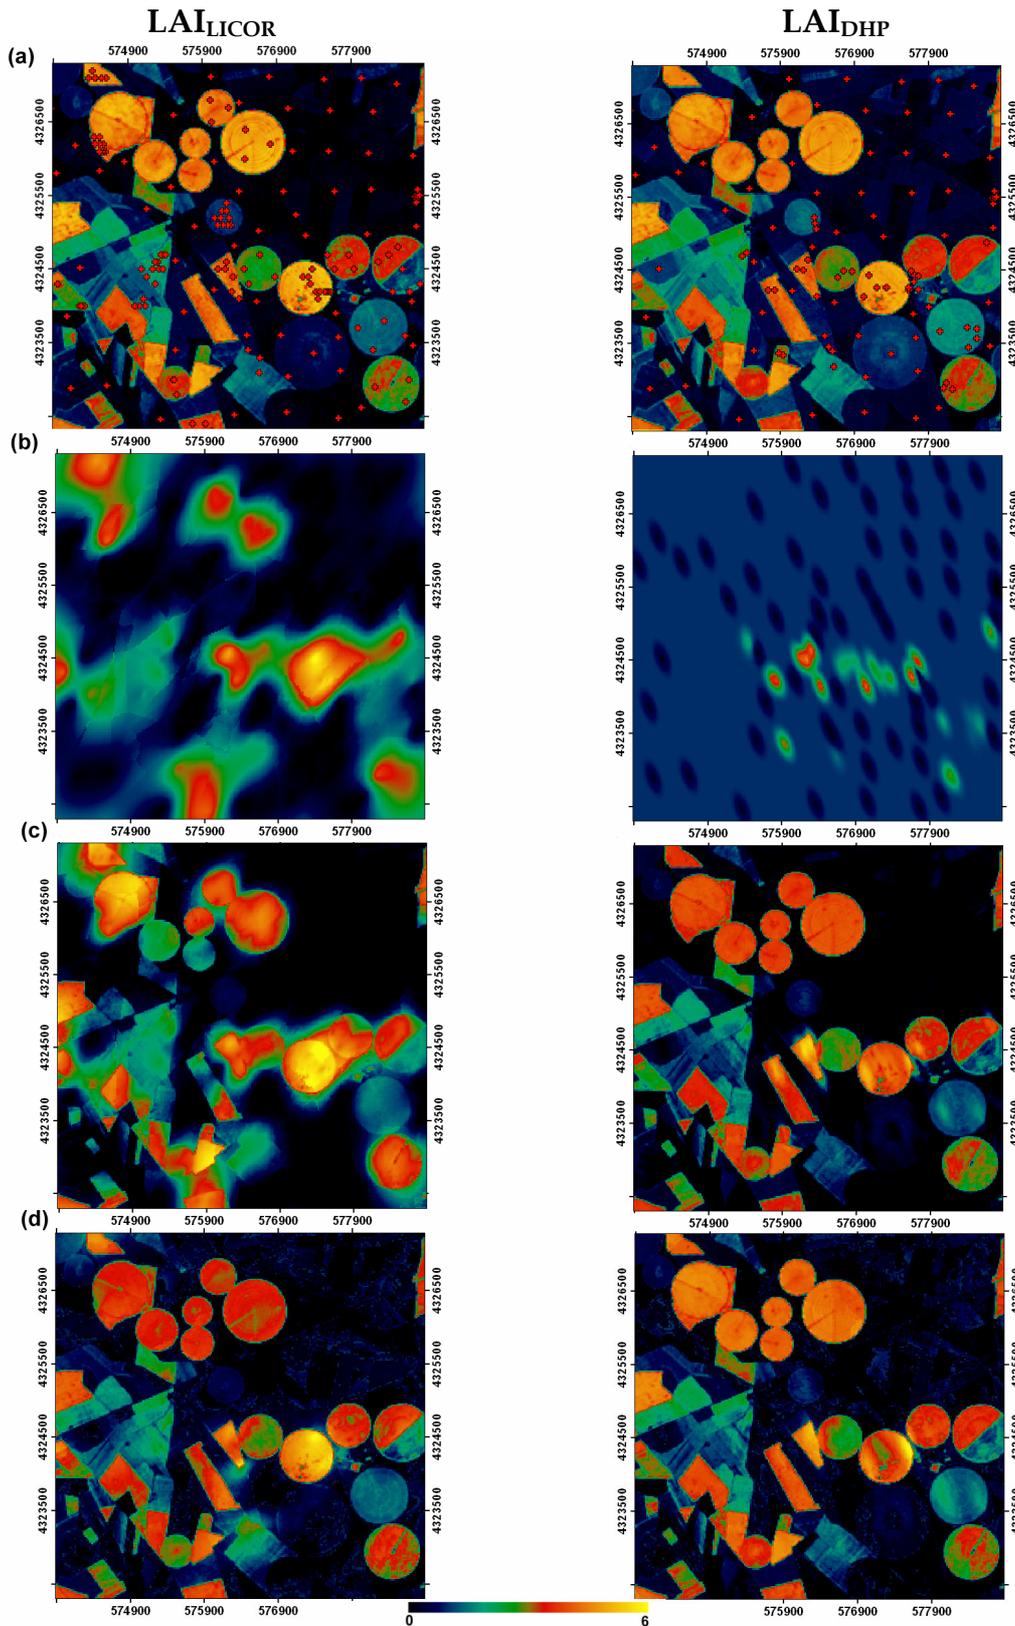
En nuestro caso, se ha escogido el parámetro NDVI como variable secundaria para utilizar en los algoritmos de CKC y KDE por su alta correlación con el parámetro LAI. En general, se ha observado (capítulo I) que la relación entre ambas variables no se comporta de forma lineal para valores altos de LAI. La figura IV.15a y IV.15b muestra las medidas *in-situ* de cada variable primaria respecto al valor colocalizado de NDVI extraído de la imagen. Se observa para el LAI<sub>LICOR</sub> (figura IV.15a) un comportamiento no lineal entre las variables para valores de LAI superior a 4. Sin embargo, se ha asumido una relación lineal en los dos casos con un coeficiente de correlación igual a 0.92, que demuestra que el NDVI describe como mínimo el 84% ( $R^2=0.84$ ) de la variabilidad encontrada en el conjunto de datos de la variable primaria. El comportamiento asintótico para valores de LAI mayores de 4 que se observa para el LAI<sub>LICOR</sub> se deberá considerar como una fuente de error en las estimaciones.



**Figura IV.15.** Variable primaria,  $LAI_{LICOR}$  y  $LAI_{DHP}$  frente al valor colocalizado de NDVI. En cada caso se presenta el coeficiente de correlación que será incluido en los modelos KDE y CKC.

### IV.2.3 Estimación mediante KO, CKC y KDE

Una vez se conoce el patrón de continuidad espacial definido a partir de los conjuntos de datos,  $LAI_{LICOR}$  y  $LAI_{DHP}$ , así como la relación que existe con el NDVI, el siguiente paso consiste en la estimación de los mapas. La figura IV.16a muestra la localización de las ESUs para los datos  $LAI_{LICOR}$  (izquierda) y  $LAI_{DHP}$  (derecha) sobre el mapa de LAI derivado de cada uno de ellos a partir de la FT (puntos rojos). Debido a la falta de representatividad del suelo desnudo observada en el apartado anterior, se han añadido a ambos conjuntos de datos más ESUs con LAI igual a cero. A diferencia de la regresión multivariada, en los métodos geostadísticos no es suficiente con caracterizar el rango de variabilidad mostrado por el parámetro sino que las ESUs deben distribuirse por toda el área para obtener una correcta caracterización de todos los cultivos. La figura IV.16b, IV.16c y IV.16d muestran las estimaciones obtenidas al aplicar los algoritmos de KO, CKC y KDE, respectivamente, sobre cada conjunto de datos.



**Figura IV.16.** Localización de las ESUs para los datos  $LAI_{LICOR}$  ((a) izquierda) y  $LAI_{DHP}$  ((a) derecha) sobre el mapa de LAI derivado a partir de la FT, junto con las estimaciones al aplicar los algoritmos de KO (b), CKC (c) y KDE (d).

En general, se observa al comparar las estimaciones obtenidas por los tres modelos para cada conjunto de datos la alta influencia de la variable secundaria en la obtención del patrón de continuidad de la zona de estudio. Un ejemplo es la estimación del LAI en aquellas posiciones donde no se tiene información de la variable primaria, como es el caso del grupo de seis campos de Alfalfa situado en la esquina superior izquierda de la imagen. Tal como se esperaba, el modelo de KO (figura IV.6b izquierda y derecha) proporciona información de la variable primaria a escalas bajas. Éste modelo está totalmente condicionado por el número de medidas y localización de la variable primaria, de modo que en nuestro caso, sólo identifica los grupos más grandes de cultivos y no proporciona información sobre la variabilidad a escalas finas.

En el caso del CKC (figura IV.6c izquierda y derecha), se obtienen estimaciones de LAI donde es posible identificar el patrón de continuidad definido por la variable primaria. Sin embargo, este modelo no resuelve correctamente el problema asociado a una variable no estacionaria y no consigue reproducir el cambio tan fuerte en el LAI que se observa entre parcelas (figura IV.16c). El estimador por CKC proporciona una zona de transición entre parcelas, la cual desaparece al aplicar el modelo KDE (figura IV.16d), tal como se esperaba.

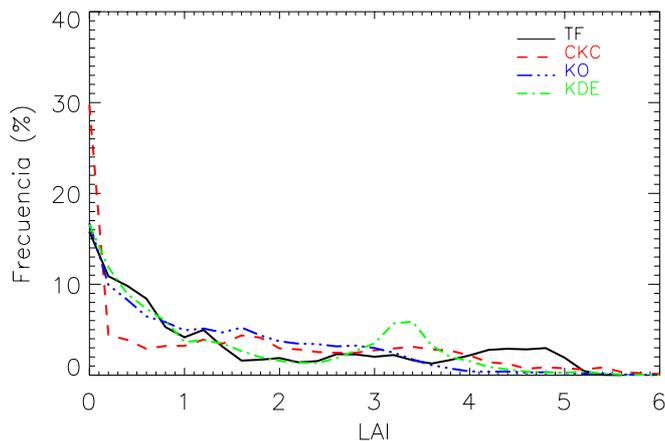
Respecto a las diferencias asociadas al muestreo, se concluyen que:

1. El menor alcance y la mayor pendiente mostrada por el variograma para los datos LAI<sub>DHP</sub>, implica una mayor variabilidad a distancias menores que para las estimaciones derivadas con los datos LAI<sub>DHP</sub> (figura IV.6.b izquierda y derecha).
2. Las diferencias entre las estimaciones por KO para ambos conjuntos de datos, indican que el muestreo del LAI<sub>DHP</sub> no es adecuado para aplicar el KO dado que no cubre toda el área de estudio.
3. Las estimaciones derivadas con el muestreo LAI<sub>DHP</sub> y los algoritmos de CKC y KDE muestran visualmente un comportamiento similar a las obtenidas con el muestreo LAI<sub>LICOR</sub>.
4. La contribución de la variable secundaria en las estimaciones es más importante con el caso LAI<sub>DHP</sub>, dado el menor número de observaciones.

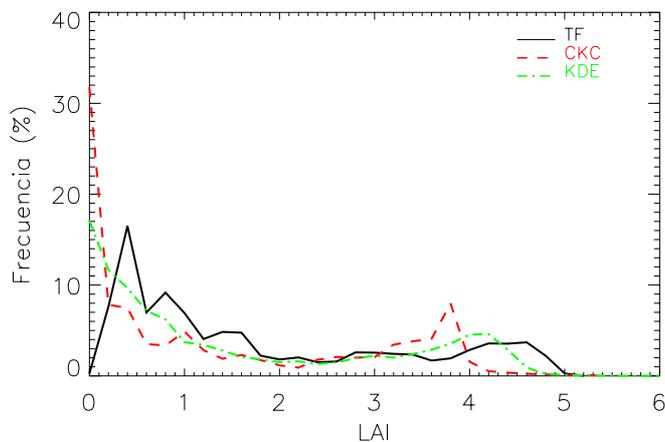
Respecto a la comparación con la FT, la figura IV.17 muestra los histogramas de los mapas derivados con los modelos geostadísticos y con la FT para los dos conjuntos de datos LAI<sub>LICOR</sub> (a) y LAI<sub>DHP</sub> (b). La figura IV.17a pone de manifiesto una mayor similitud en las estimaciones respecto a la FT para los datos LAI<sub>LICOR</sub> que para el LAI<sub>DHP</sub>. Al igual que en la figura IV.16, se observa cómo el KO es el que peor se ajusta a la FT, con un coeficiente de correlación de 0.5 y los valores más altos de RMSE (1.5) y *bias* (-0.3), ver tabla IV.5. Este imagen es la que muestra un menor rango de variabilidad y un alto porcentaje de píxeles con valores entre 1 y 4, que es muy superior al que se obtuvo con la FT. Los modelos CKC y KDE son los que más

se asemejan a la FT, mostrando coeficientes de correlación de Pearson superiores a 0.8, ver tabla IV.5. Sin embargo, el campo estimado por CKC muestra una mayor proporción de valores nulos y una tendencia a estimar valores de LAI más altos que los encontrados en la FT. El modelo KDE, aunque presenta diferencias para valores entre 3 y 4, es el que mejor se ajusta a las estimaciones derivadas con la FT. En el caso del LAI<sub>DHP</sub>, sólo se han representado las estimaciones derivadas por los modelos CKC y KDE. Se observa en la figura IV.17b un mejor ajuste del modelo KDE con la FT a partir de valores de LAI mayores de 1, con un coeficiente de correlación, RMSE y *bias* razonables (e.g. 0.9, 0.4 y -0.3). Aunque el modelo KDE es el que mayor correlación y menor RMSE presenta, el CKC también proporciona valores razonables respecto a las estimaciones realizadas con la FT. Por ejemplo, en el caso del LAI<sub>LICOR</sub> se obtiene un *bias* menor para el CKC (-0.06) a pesar de que el modelo KDE proporciona mayor *r* y menor RMSE.

(a) LAI<sub>LICOR</sub>



(b) LAI<sub>DHP</sub>



**Figura IV.17.** Histogramas de los mapas derivados con cada modelo aplicado a los dos conjuntos de datos LAI<sub>LICOR</sub> (a) y LAI<sub>DHP</sub> (b).

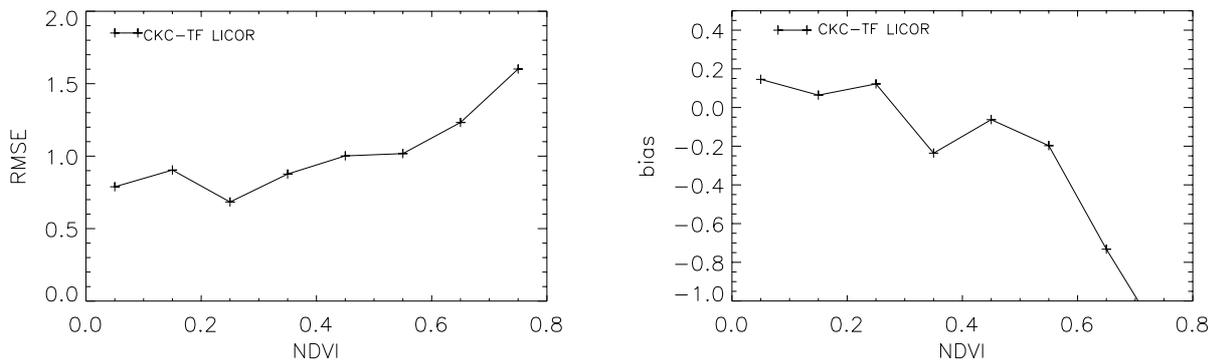
**Tabla IV.5.** Parámetros estadísticos de las estimaciones derivadas de la FT, KO, CKC y KDE a partir de los conjuntos de datos LAI<sub>LICOR</sub> y LAI<sub>DHP</sub>. El *bias*, *r* y RMSE se ha calculado respecto a la FT.

|                            | FT  | KO   | CKC   | KDE   |
|----------------------------|-----|------|-------|-------|
| <b>LAI<sub>LICOR</sub></b> |     |      |       |       |
| Media                      | 1.7 | 1.4  | 1.6   | 1.6   |
| $\sigma$                   | 1.6 | 1.2  | 1.6   | 1.4   |
| <i>bias</i>                | -   | -0.3 | -0.06 | -0.14 |
| <i>r</i>                   | -   | 0.5  | 0.8   | 0.9   |
| RMSE                       | -   | 1.5  | 0.9   | 0.5   |
| <b>LAI<sub>DHP</sub></b>   |     |      |       |       |
| Media                      | 1.9 | 1.0  | 1.4   | 1.6   |
| $\sigma$                   | 1.5 | 0.3  | 1.5   | 1.6   |
| <i>bias</i>                | -   | -0.9 | -0.5  | -0.3  |
| <i>r</i>                   | -   | 0.3  | 0.9   | 0.9   |
| RMSE                       | -   | 1.7  | 0.6   | 0.4   |

La figura IV.18a y IV.18b pone de manifiesto las diferencias entre los algoritmos cuyos resultados han mostrado una mayor correlación con la FT (i.e. CKC y KDE). En el caso del estimador por KDE se obtienen diferencias menores de 0.5 respecto a la FT y valores de *bias* prácticamente nulo, lo que indica que el modelo KDE se comporta prácticamente igual que la FT para niveles de cobertura bajo e intermedio. Las diferencias entre ambos métodos son mayores para niveles de cobertura altos (RMSE $\approx$ 1 y *bias*=-0.9). Respecto al modelo CKC, el estimador por KDE mejora el RMSE y *bias*, sobre todo para niveles de cobertura muy densos, donde el RMSE alcanza valores de 1.5 en el caso del CKC.

Además, se ha evaluado el error de estimación de los algoritmos de KO, CKC y KDE con referencia a datos medidos *in-situ*. Para ello se han comparado las estimaciones geostadísticas de LAI<sub>LICOR</sub>, respecto a las medidas *in-situ* de LAI<sub>DHP</sub>. Se han escogido los mapas estimados con los datos LAI<sub>LICOR</sub> dado que mostraban un RMSE menor que los derivados con los datos LAI<sub>DHP</sub>. La tabla IV.6 muestra el RMSE, coeficiente de correlación, pendiente y ordenada de los valores de LAI coincidentes con las medidas *in-situ* del LAI<sub>DHP</sub> y las estimaciones de los modelos KO, CKC, KDE. También se ha evaluado con los datos LAI<sub>LICOR</sub> las estimaciones derivadas con la FT del LAI<sub>LICOR</sub>.

(a) CKC



(b) KDE

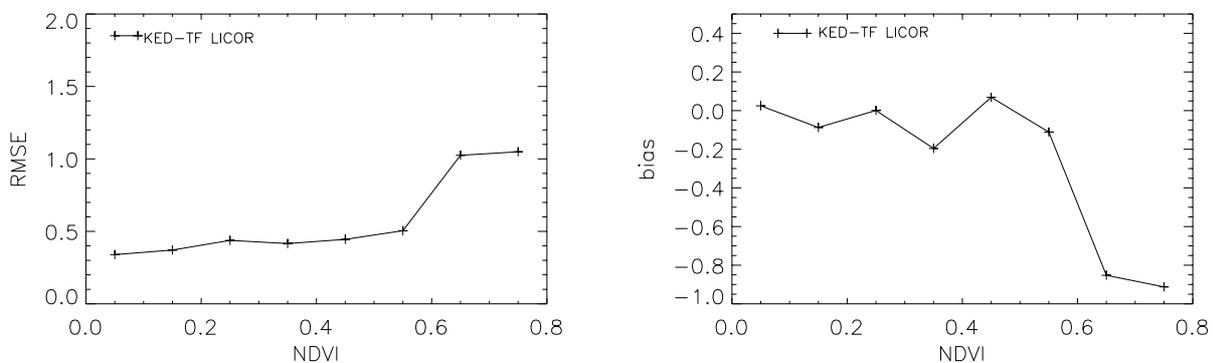


Figura IV.18. RMSE y *bias* en función del NDVI calculado a partir de los mapas derivados con CKC (a) y KDE (b) respecto al mapa derivado con la FT LAI<sub>LICOR</sub>.

Tabla IV.6. Error de estimación proporcionado por los modelos FT, KO, CKC y KDE respecto a los datos *in-situ* LAI<sub>DHP</sub>.

| Modelo | Pendiente | Ordenada | <i>r</i> | RMSE |
|--------|-----------|----------|----------|------|
| FT     | 0.9       | 0.17     | 0.9      | 0.8  |
| KO     | 0.7       | 0.7      | 0.7      | 1.3  |
| CKC    | 0.9       | 0.4      | 0.8      | 1.2  |
| KDE    | 0.9       | 0.5      | 0.9      | 0.8  |

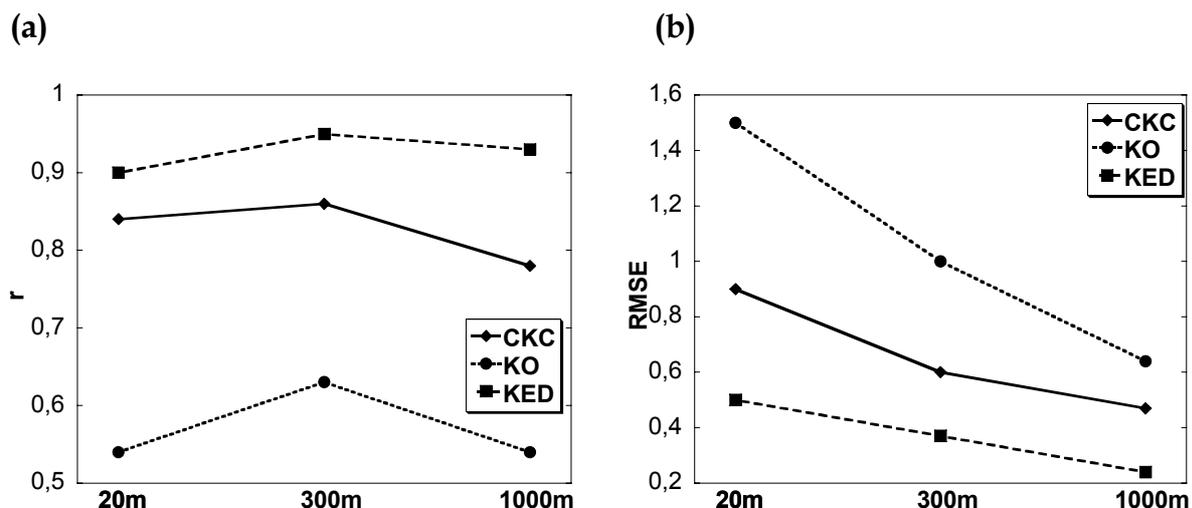
De la tabla IV.6 se observan resultados comparables entre el modelo KDE y la FT, con errores similares (0.8). Además, el RMSE es del mismo orden que el error de validación cruzada obtenido para la función de transferencia (0.6). Los modelos KO y CKC proporcionan un error más alto (1.3 y 1.2, respectivamente) para este conjunto de datos y coeficientes de correlación menores (0.7 y 0.8, respectivamente). En el apartado siguiente (IV.3) se evaluarán las estimaciones de estos modelos con otros muestreos espaciales.

La alta correlación y RMSE razonables entre las estimaciones del CKC y KDE con las medidas *in-situ* ( $r > 0.9$  y  $RMSE < 1.2$ ) y con las estimaciones de la FT ( $r > 0.9$  y

RMSE<0.9), pone de manifiesto la poca influencia que tiene sobre las estimaciones el hecho de que la variable secundaria no se haya corregido atmosféricamente.

Por último, se han analizado las estimaciones de los modelos geostatísticos con respecto a la FT para tres resoluciones espaciales: alta (20 m), media (300 m) y baja (1000 m). El procedimiento ha consistido en degradar los mapas derivados de los modelos KO, CKC y KDE a dichas resoluciones a partir del método de la media aritmética. A continuación, se calcula el coeficiente de correlación y RMSE respecto a las estimaciones derivadas de la FT (ver figura IV.19). El estudio se ha realizado sólo con los mapas estimados a partir del conjunto de datos LAI<sub>LICOR</sub>.

Se observa, de nuevo, cómo el modelo KDE es el que proporciona una mayor correlación ( $r > 0.9$ ) y menores discrepancias (RMSE < 0.5) con las estimaciones de la FT para las tres resoluciones espaciales. En general, se obtiene una disminución del RMSE de hasta el 50% a medida que la resolución aumenta para todos los modelos. El modelo CKC proporciona estimaciones razonables ( $r \approx 0.8$  y RMSE < 1) y el KO se manifiesta como el menos adecuado para la estimación del LAI a partir del conjunto de datos LAI<sub>LICOR</sub>, dado el bajo coeficiente de correlación obtenido (menor de 0.6) y el alto valor en el RMSE (hasta 1.5).



**Figura IV.19.** Coeficiente de correlación (a) y RMSE (b) correspondientes a las estimaciones obtenidas a partir de los modelos KO, CKC y KDE respecto a las estimadas mediante el método FT para las resoluciones espaciales de 20 m, 300 m y 1000 m.

Para finalizar, exponemos a continuación las principales conclusiones derivadas de las técnicas geostatísticas como estimadores del LAI:

1. Se ha observado que cuando el muestreo no cubre toda el área de estudio, como ocurre con el conjunto de datos LAI<sub>DHP</sub>, la técnica del KO presenta limitaciones.

2. El modelo KDE muestra una alta consistencia para la estimación del LAI, dada la alta correlación (0.9) y RMSE razonable (0.8) respecto a las medidas *in-situ* LAI<sub>DHP</sub>.
3. La obtención del mismo error para la FT, indica que el estimador por KDE es comparable al de regresión multivariada. El estimador por KDE proporciona valores de sesgo prácticamente nulos respecto a la FT para niveles de cobertura bajo e intermedio.
4. El modelo KO es el que peor se ajusta a las medidas *in-situ* (pendiente=0.7, RMSE=1.3) y a las estimaciones de la FT.
5. Para las resoluciones de 300 y 1000 m, los modelos KDE y CKC reproducen las estimaciones de la FT con un RMSE inferior a 0.7 y coeficiente de correlación mayor de 0.8. El estimador por KO reproduce muy mal la variabilidad a escalas finas ( $r < 0.6$  y RMSE=1.5).

De los resultados obtenidos hasta el momento surgen cuestiones metodológicas importantes. Hasta ahora se han evaluado las estimaciones obtenidas a partir de un conjunto de datos y determinados modelos suponiendo que los muestreos llevados a cabo eran los más adecuados. Sin embargo, y dado que posteriormente se van a utilizar estos mapas a resoluciones más bajas, es importante plantearse la cuestión de cuál será la configuración más eficaz (muestreo, modelo y resolución) que proporcione estimaciones más fiables y que, a su vez, minimice esfuerzos como por ejemplo, el realizar menor número de medidas en el campo o no depender de información secundaria. Por este motivo, se plantea en el apartado siguiente el estudio de la configuración más eficaz en función de la resolución espacial a partir de cuatro muestreos diferentes. Se han considerado para ello las técnicas de estimación planteadas en este trabajo, el método de regresión multivarida y los métodos geostatísticos.

### IV.3 Evaluación del muestreo, modelo y resolución espacial

El procedimiento para realizar este estudio consiste en encontrar la configuración más apropiada en cuanto al muestro y modelo de estimación para diferentes resoluciones espaciales. Para ello se han aplicado las técnicas de estimación propuestas (i.e. FT, KO, CKC y KDE) con cuatro muestreos espaciales diseñados a partir de los valores de LAI extraídos del mapa LAI<sub>LICOR</sub> derivado con la FT. Se evaluará para diferentes resoluciones espaciales el muestreo y la técnica que mejor reproduzca el mapa de la FT.

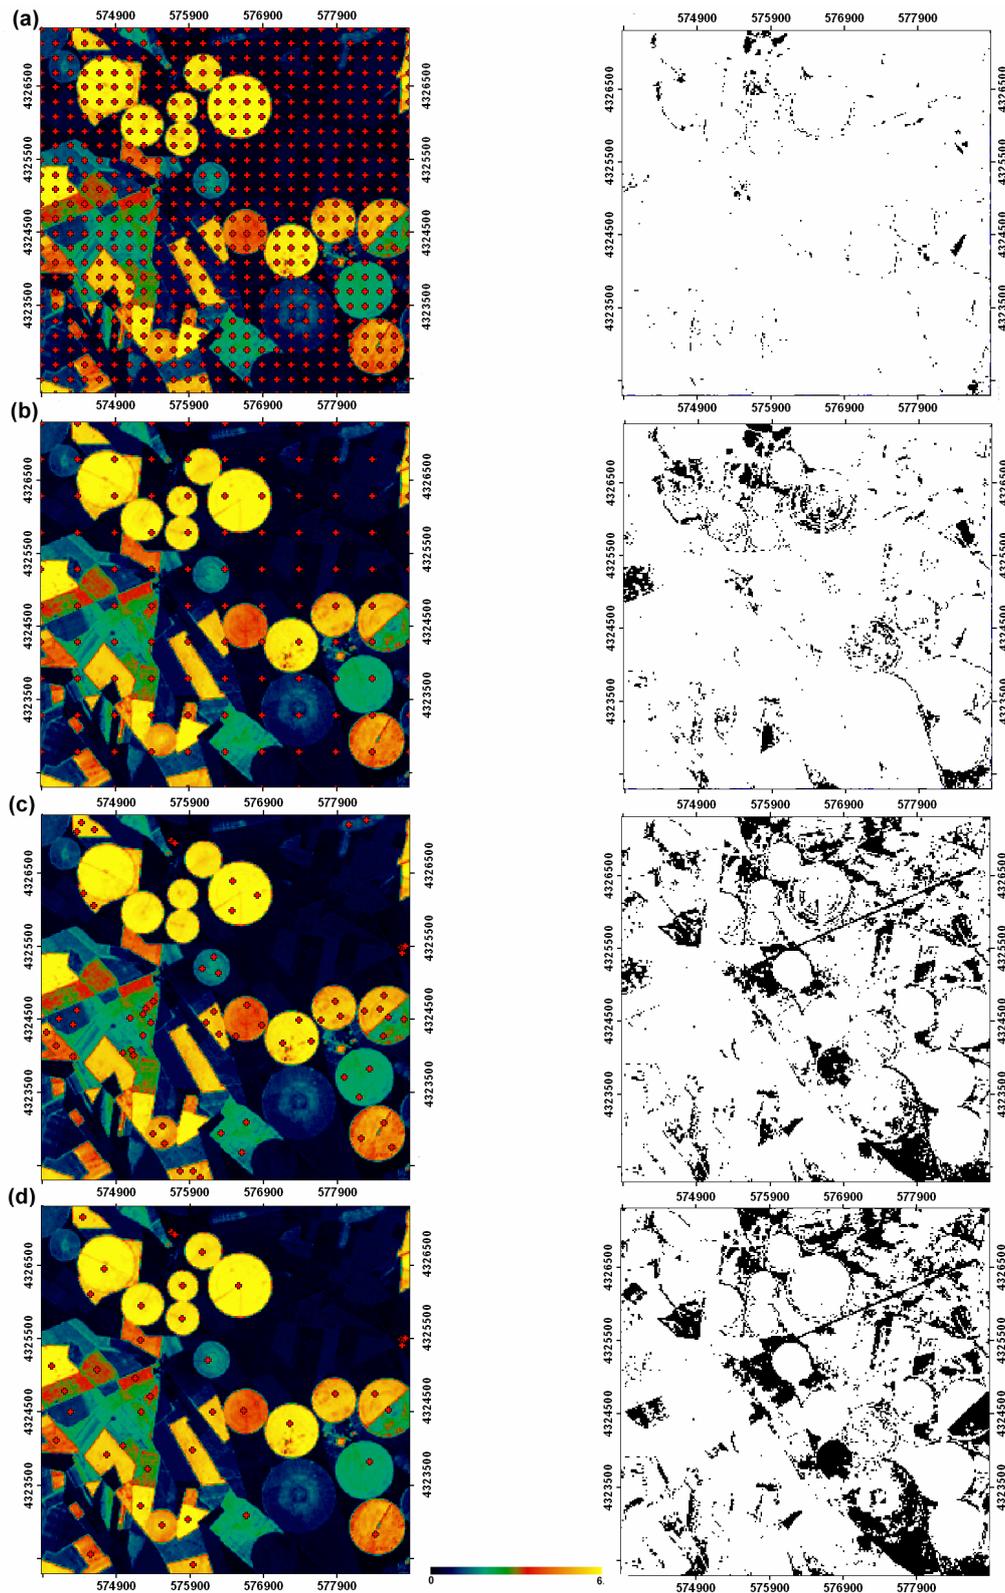
Se han diseñado cuatro muestreos: dos sistemáticos y dos estratificados (ver capítulo I). Tal como se ha comentado en el capítulo I, los patrones sistemáticos definen una malla regular la cual permite muestrear uniformemente toda la población de la zona de estudio. Sin embargo, la principal desventaja es que no se considera la población de cada una de las clases, de modo que algunas de ellas

pueden no estar representadas correctamente por el conjunto de muestras elegidas. Aunque este muestreo resulta más apropiado para zonas no estratificadas como la nuestra, se ha elegido de todas formas para evaluar su aplicación respecto a los muestreos estratificados. La estratificación considerada se ha realizado según el tipo de cubierta y su variabilidad espacial. En nuestro caso, se ha utilizado la imagen de NDVI e información recogida durante la campaña de campo. Se han diseñado dos muestreos sistemáticos con el objetivo de evaluar su eficiencia en obtener la misma variancia pero con menor número de medidas.

En la figura IV.20a y IV.20b se observan los muestreos sistemáticos (e.g. SP1 y SP2) junto con la imagen de NDVI de fondo. Se han elegido dos distancias de separación (200 y 500 m, respectivamente) menores que el alcance definido para el variograma del NDVI. Este parámetro proporciona la distancia a partir de la cual no existe dependencia espacial entre las localizaciones y, en nuestro caso, coincide con el tamaño medio de los campos. De este modo, si elegimos una distancia de separación mayor que el alcance, algunos campos no serán muestreados, y por tanto no estarán incluidos en el cálculo de la función de transferencia. En la figura IV.20a se observa cómo el muestreo SP1 caracteriza un total de 18 campos con 61 ESUs (e.g. 5 Maíz, 4 Alfalfa, 4 Remolacha, 3 Cebolla, 1 Patata y 1 Ajo), mientras que el muestreo SP2 caracteriza el doble de campos, con una ESU en cada uno de ellos.

Los muestreos estratificados se han elegido en base a dos consideraciones derivadas de los apartados anteriores, (i) alrededor de 50 ESUs son suficientes para derivar la función de transferencia y (ii) dichas ESUs deben extenderse en toda el área cuando se utilizan los modelos geostadísticos. La figura IV.20c muestra el primer muestreo estratificado (e.g. SP3), el cual considera la variabilidad espacial y diferentes niveles de cubiertas. La distribución de las ESUs se ha elegido a partir del análisis del NDVI y según dos consideraciones:

1. Cuando el NDVI de un determinado cultivo es relativamente uniforme, se localiza un muestreo regular de tres medidas en un sólo campo, como es el caso de la Patata, el Ajo y la Remolacha.
2. Cuando el NDVI presenta una variabilidad importante entre distintos campos, debido a diferencias de riego, condiciones hídricas del suelo, etc., se muestrean sólo con tres ESUs aquellos campos del cultivo que presenten valores diferentes de NDVI, tal es el caso de la Alfalfa, Cebolla y Maíz.



**Figura IV.20.** Muestras diseñadas a partir del mapa de LAI<sub>LICOR</sub>, SP1 (a), SP2 (b), SP3 (c) y SP4 (d) sobre la imagen de NDVI. Las figuras de la derecha corresponden a la imagen QF obtenida para cada muestreo a partir de la combinación de bandas espectrales (G, R, NIR) de la imagen SPOT.

En nuestro caso, el cultivo que más se ha muestreado es el de Alfalfa, dada su alta variabilidad en la zona de estudio. Este cultivo mostraba tres niveles de cubierta bien diferenciados, un grupo de seis campos (e.g. esquina superior izquierda de la imagen) con valores de NDVI alrededor de 0.6 (tonalidades amarillas) y dos campos con valores de NDVI alrededor de 0.2 y 0.4 (tonalidades verde y roja). En el caso del grupo de seis campos sólo se ha muestreado uno de ellos dada la similitud entre los campos. El segundo muestreo estratificado (e.g. SP4) sólo considera el tipo de cubierta, de modo que se muestrean todos los campos independientemente de que presenten el mismo valor de NDVI, pero sólo se adquiere una ESU por campo.

Para la FT se han considerado también las posiciones donde se localizó suelo desnudo en la campaña de campo, mientras que para los modelos geostadísticos se han considerado las ESUs de suelo añadidas en el apartado anterior. A continuación se presentan dos apartados con los mapas estimados a partir de cada método y la influencia del muestreo en cada uno de ellos.

### **IV.3.1 Técnica de regresión multivariada**

Las funciones para cada muestreo se han obtenido directamente a partir de las bandas del G, R y NIR, puesto que dicha combinación mostró ser apropiada. La influencia del muestreo en las estimaciones se ha evaluado también a partir de la imagen QF derivada con el procedimiento anteriormente descrito del *convex hull*. La figura IV.20 (derecha) muestra las imágenes QF para cada muestreo derivadas del *convex hull*.

Se observa de la figura IV.20a cómo el muestreo SP1 es el que presenta mayor porcentaje de píxeles interpolados (98%), seguido del muestreo SP2 (92%). En el caso de los muestreos estratificados, el porcentaje disminuye para los muestreos SP3 y SP4 en un 82% y 78%, respectivamente. Cabe destacar que en ambos casos el aumento de píxeles no interpolados (e.g. QF=0) corresponde a la clase de suelo desnudo, dado que en ambos esquemas no se ha muestreado tan intensivamente esta clase como en los diseños sistemáticos. Mientras que las diferencias entre cultivos son difíciles de soslayar, las diferencias debidas a la mala caracterización de suelo desnudo son muy poco críticas y fáciles de evitar, dado que es técnicamente simple anotar la posición con un GPS de campos de suelo en la zona. Esto permitirá recoger mejor la variabilidad espectral de los suelos en la zona y reducir así errores en las estimaciones.

En general, las estimaciones derivadas de los cuatro muestreos no muestran importantes diferencias, proporcionando un valor medio (1.3) y desviación estándar (1.6) similar al obtenido con la FT y coeficiente de correlación cercano a la unidad. Sin embargo, en vistas de que el muestreo regular intensivo resulta difícilmente trasladable al campo, se propone uno de los dos muestreos regulares para caracterizar la variabilidad espacial entre cultivos. Aunque las diferencias entre los muestreos SP3 y SP4 no son importantes, una cuestión importante para

elegir uno de ellos sería evaluar la dificultad que requieren al trasladarlo al campo. Considerando la morfología de la zona de estudio y la experiencia adquirida durante las campañas de campo, resulta más óptimo en cuanto a tiempo de adquisición llevar a cabo el muestreo SP3.

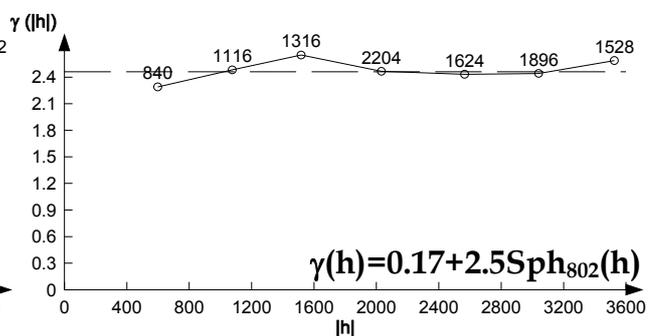
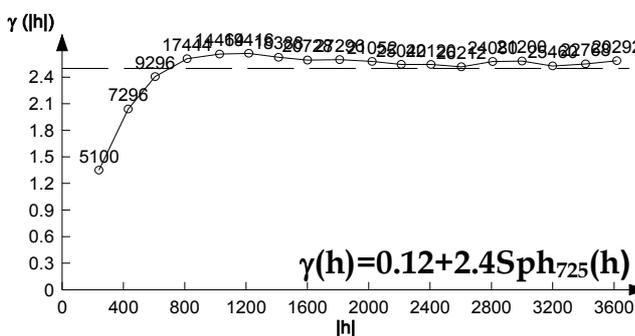
### IV.3.2 Técnicas geoestadísticas

Para evaluar la influencia del muestreo espacial en la estimación del LAI con los modelos KO, CKC y KDE, en primer lugar se deben obtener los patrones de continuidad para cada muestreo. Al igual que en el apartado IV.2, la variable secundaria elegida es el NDVI.

La figura IV.21 muestra los variogramas omnidireccionales junto con los modelos ajustados a cada uno de ellos para los muestreos SP1 (a), SP2 (b), SP3 (c) y SP4 (d), respectivamente. En los cuatro casos se han escogido los modelos esféricos. En este estudio no se ha considerado la anisotropía de los muestreos con la finalidad de simplificar el problema. Se observan alcances entre los 700 y 800 m, así como varianzas alrededor de 2.5 para todos los casos. El muestreo SP3 es el que presenta una mayor varianza (2.7) y alcance (875).

(a) SP1

(b) SP2



(c) SP3

(d) SP4

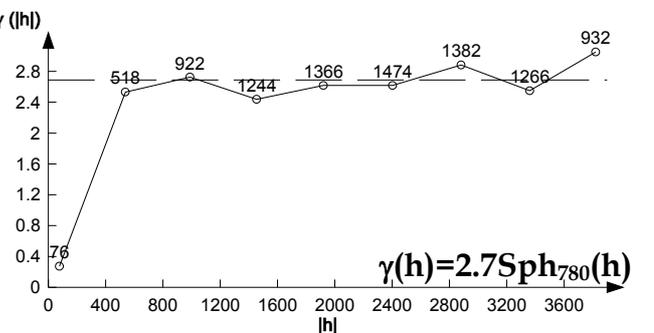
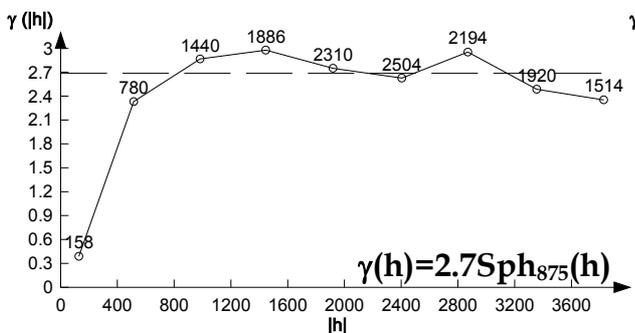
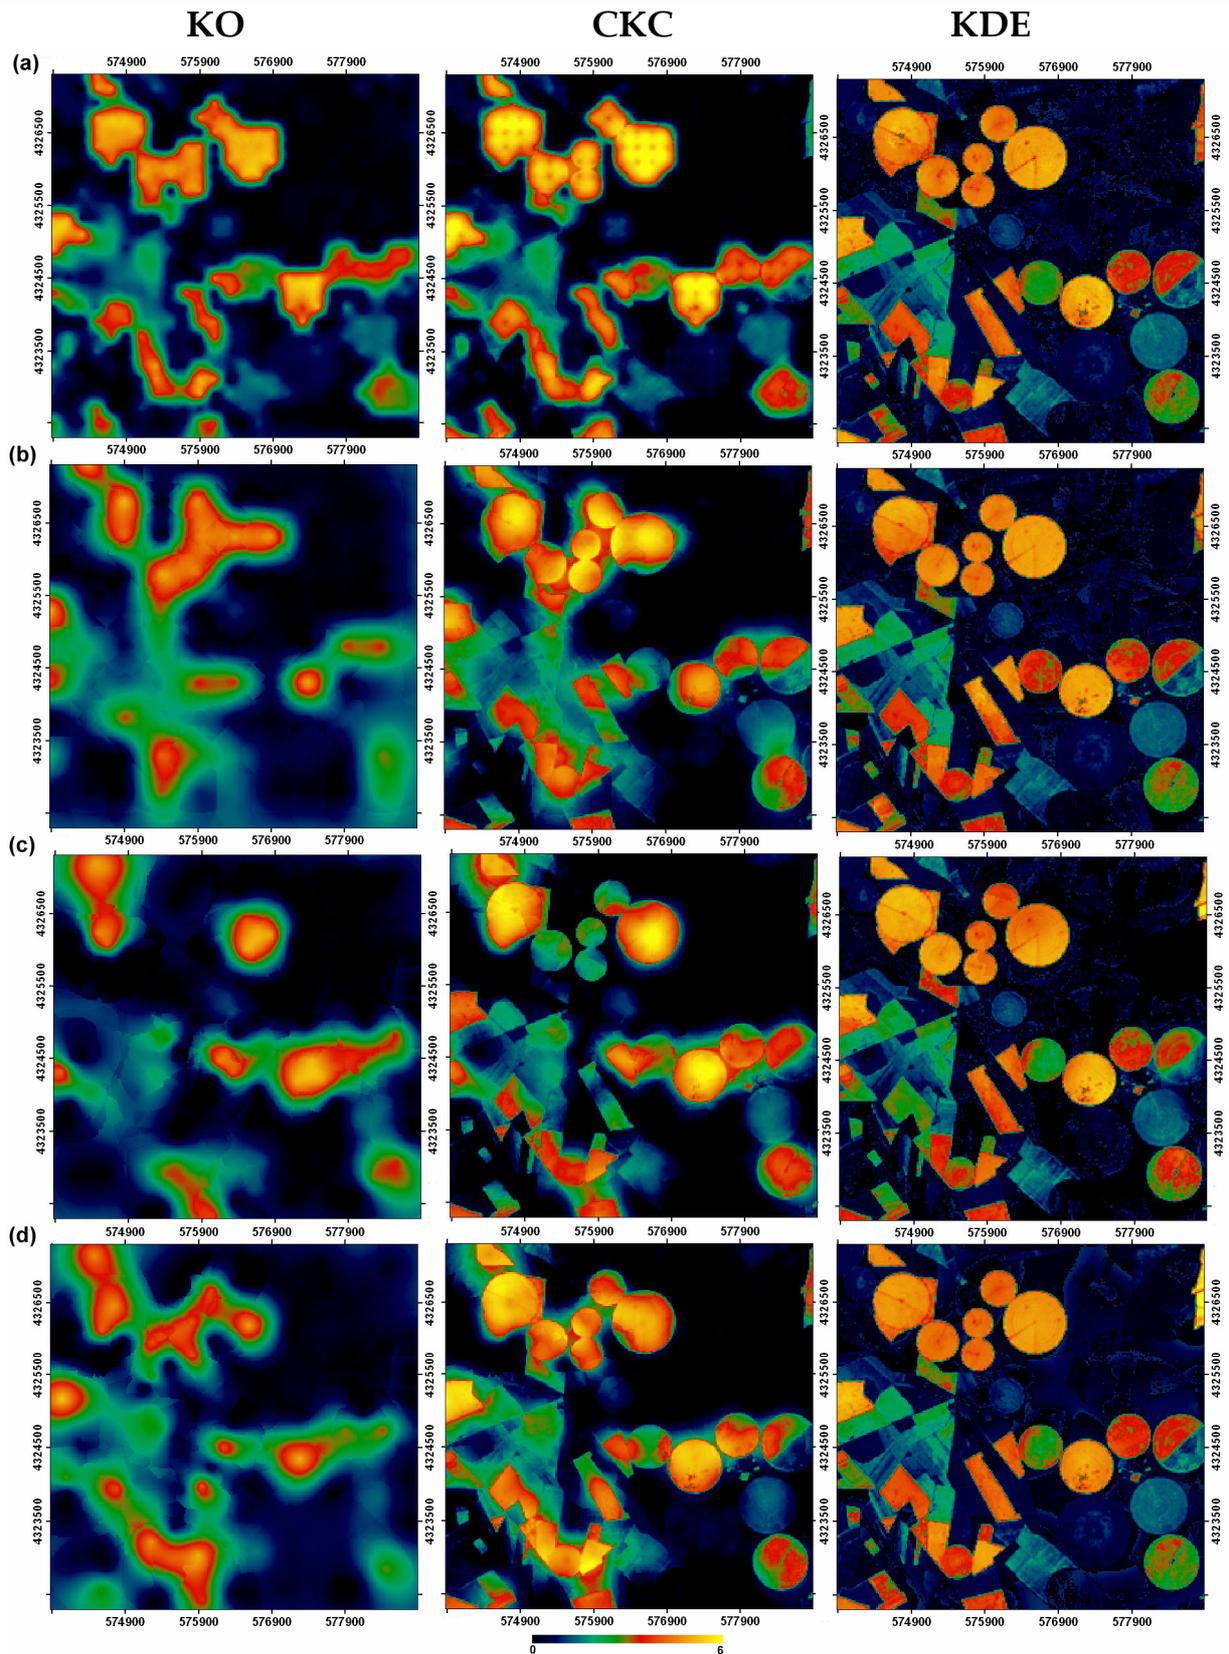


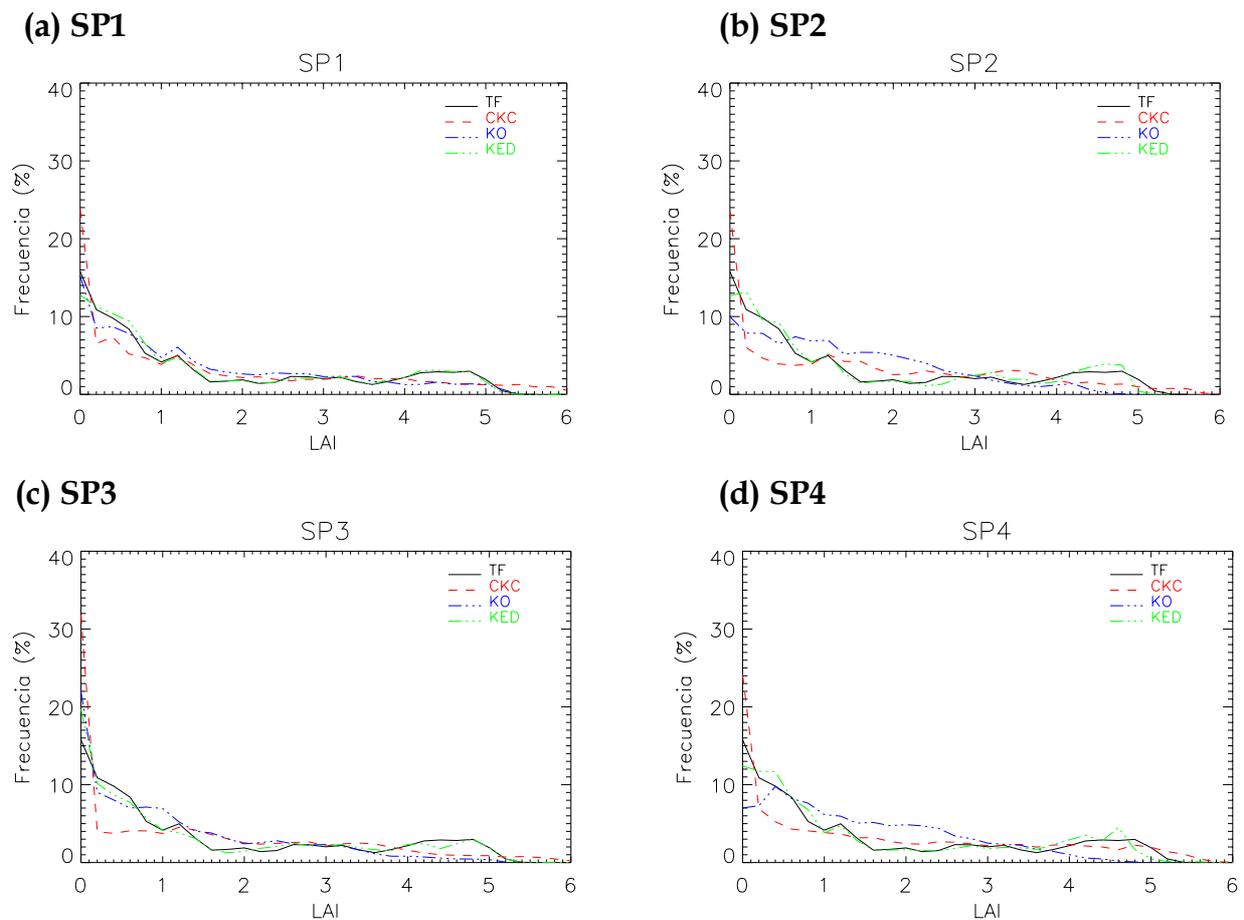
Figura IV.21. Variogramas omnidireccionales obtenidos para los muestreos espaciales SP1 (a), SP2 (b), SP3 (c), SP4 (d).

La figura IV.22 presenta las estimaciones derivadas de los modelos KO (izquierda), CKC (centro) y KDE (derecha) para los cuatro muestreos. A partir de una primera inspección visual, se observa una fuerte influencia de la variable primaria respecto a la secundaria cuando se comparan las estimaciones derivadas de los modelos KO y CKC a partir de un muestreo tan intensivo como es el SP1 (figuras IV.22a). En este caso, el radio de influencia definido por el alcance incluye un alto número de observaciones de la variable primaria lo que provoca un efecto de 'pantalla' sobre la variable secundaria. Este comportamiento es menos acusado cuando el muestreo es menos intensivo, como ocurre con el SP2. En este caso, la variable secundaria contribuye aportando información sobre la estructura de los campos, tal como se puede observar al comparar las estimaciones derivadas de los modelos KO y CKC. Otro aspecto importante a destacar son las estimaciones derivadas del modelo KDE para los cuatro muestreos. Tal como se observa del histograma de valores (figura IV.23), este modelo proporciona resultados comparables a la FT para los cuatro muestreos.

De la figura IV.23a se observa que el muestreo SP1 proporciona una alta correspondencia en las distribuciones de valores con la FT para los tres modelos, dado que es el muestreo que más intensivamente caracteriza la zona de estudio. Después de este muestreo, el SP4 (figura IV.23d) es el que mejor reproduce las estimaciones de la FT para los modelos CKC y KDE ( $RMSE > 0.6$  y  $r > 0.9$ ). Las diferencias más importantes se observan para los muestreos SP2 y SP3 (figura IV.23b y IV.23c). En el caso del KO (línea azul), es el que menor rango de variación presenta con valores de RMSE muy altos (1.1) y correlaciones no mayores de 0.7. Por el contrario, el modelo CKC (línea roja), proporciona el mayor rango de variación y una reproducción del LAI respecto a la FT para valores menores de uno y mayores de cuatro. Este modelo reduce el RMSE (0.7) cuando se utiliza el muestreo SP4. Al igual que sucedía con los datos *in-situ*, el modelo KDE (línea verde) es el que mejor correspondencia presenta con la FT (línea negra) para los cuatro muestreos ( $r > 0.95$  y  $RMSE < 0.3$ ). El modelo KO es el que presenta una correlación menor (0.85) y RMSE mayor (0.9).



**Figura IV.22.** Estimaciones del LAI derivadas de los modelos KO (izquierda), CKC (centro) y KDE (derecha) para los cuatro muestreo espaciales SP1 (a), SP2 (b), SP3 (c) y SP4 (d).



**Figura IV.23.** Histogramas correspondientes a los mapas obtenidos a 20 m con los modelos FT, KO, CKC y KDE para los muestreos SP1 (a), SP2 (b), SP3 (c) y SP4 (d).

Al igual que se hizo con las estimaciones derivadas de los datos  $LAI_{LICOR}$ , se ha evaluado el error de estimación asociado a estos muestreos espaciales con los datos *in-situ*  $LAI_{DHP}$ . La tabla IV.7 muestra la comparación de las estimaciones proporcionadas por los modelos KO, CKC y KDE para los cuatro muestreos. El modelo KDE junto con el muestreo SP4 es el que mejor se ajusta a las estimaciones *in-situ*. Esta combinación proporciona resultados similares a la función de TF (RMSE=0.8,  $r=0.9$ , pendiente=0.9, ordenada=0.17), e incluso disminuye el error respecto a las estimaciones *in-situ* (RMSE=0.7). En general, el modelo KDE proporciona errores similares a los obtenidos con la  $FT_{LICOR}$  para los cuatro muestreos diseñados. Por otra parte, el modelo CKC junto con el muestreo SP4 también muestra un error aceptable (0.9) y pendiente casi uno. El modelo KO es el que mayor diferencia muestra con las estimaciones *in-situ*, siendo el muestreo SP1 el que menor RMSE (1.1) y mayor correlación (0.8) proporciona del resto.

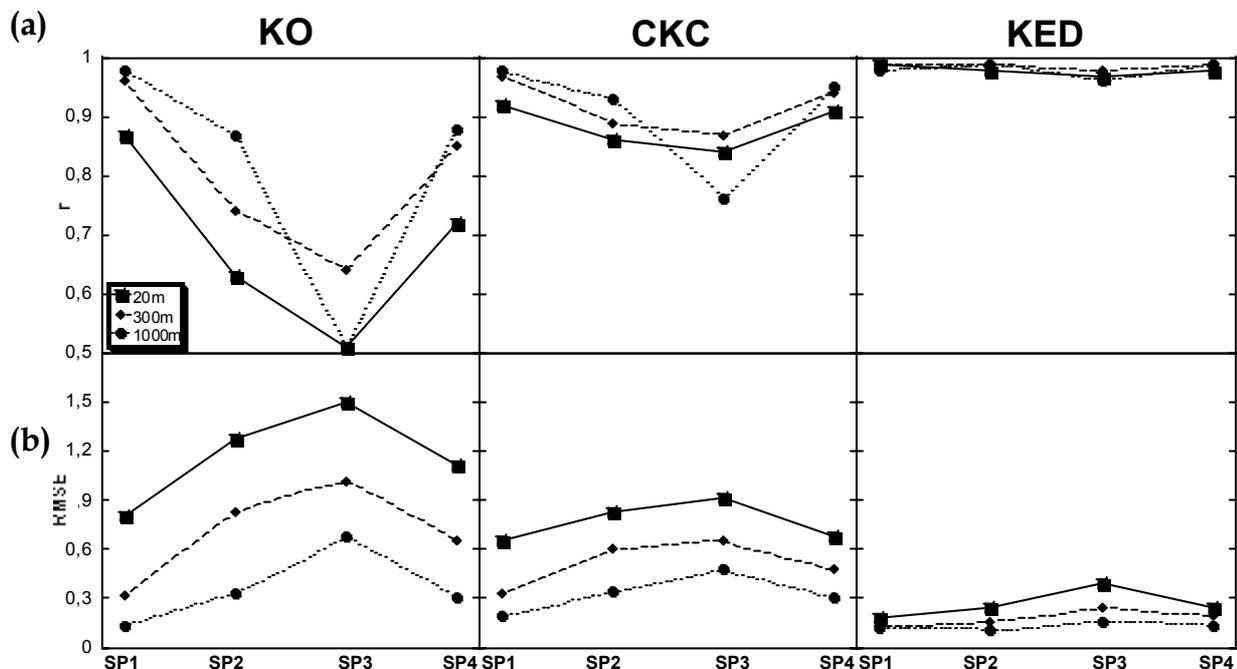
**Tabla IV.7.** Comparación de las estimaciones proporcionadas por los modelos KO, CKC y KDE con las medidas in-situ del LAI<sub>LICOR</sub> para los cuatro muestreos.

| Modelo     | Pendiente | Ordenada | $r$ | RMSE |
|------------|-----------|----------|-----|------|
| <b>KO</b>  |           |          |     |      |
| SP1        | 0.6       | 0.4      | 0.8 | 1.1  |
| SP2        | 0.3       | 0.8      | 0.6 | 1.4  |
| SP3        | 0.6       | 0.5      | 0.7 | 1.4  |
| SP4        | 0.5       | 0.4      | 0.7 | 1.3  |
| <b>CKC</b> |           |          |     |      |
| SP1        | 0.8       | 0.2      | 0.8 | 0.9  |
| SP2        | 0.7       | 0.4      | 0.8 | 0.9  |
| SP3        | 0.8       | 0.4      | 0.8 | 1.2  |
| SP4        | 0.9       | 0.2      | 0.8 | 0.9  |
| <b>KDE</b> |           |          |     |      |
| SP1        | 0.9       | 0.3      | 0.9 | 0.8  |
| SP2        | 1.0       | 0.16     | 0.9 | 0.8  |
| SP3        | 0.9       | 0.2      | 0.9 | 0.8  |
| SP4        | 0.9       | 0.2      | 0.9 | 0.7  |

Por último, la figura IV.24 muestra el coeficiente de correlación y RMSE obtenido a partir de los modelos KO, CKC y KDE respecto a las estimaciones derivadas de la FT para los cuatro muestreos y tres resoluciones espaciales (20 m, 300 m y 1000 m). En general, se observa cómo el modelo KDE es el que mayor coeficiente de correlación y RMSE presenta para todos los muestreos y resoluciones espaciales ( $RMSE < 0.3$  y  $r > 0.95$ ). Es decir, se obtienen resultados similares tanto para el muestreo más intensivo (SP1) como para el menos intensivo (SP4) cuando se aplica el modelo KDE. De este modo, si se dispone de información secundaria el modelo KDE resulta adecuado para estimar mapas a diferentes resoluciones espaciales minimizando los esfuerzos en el campo (i.e. utilizando un muestreo poco intensivo). A pesar que el modelo KDE es el que mejor se correlaciona con las estimaciones derivadas de la FT, caben destacar otras configuraciones (modelo y muestreo) que también muestran ser adecuadas a otras resoluciones espaciales. Tal es el caso del modelo CKC, el cual proporciona un coeficiente de correlación alto (0.8) y RMSE razonable (0.6) respecto a la FT para las resoluciones espaciales media y baja, respectivamente (figura IV.24 centro). Se observa también en este caso, cómo los resultados del muestreo SP4 son comparables a los obtenidos con el muestreo intensivo. Cabe destacar, cómo el muestreo SP3 es el que peor correlación muestra con las estimaciones de la FT y mayor RMSE proporciona para todos los modelos y todas las resoluciones.

Aunque, el modelo KO es el que peor correspondencia muestra con la FT a alta resolución, la configuración formada por el modelo KO y muestreo SP4 (figura

IV.24 izquierda) proporciona resultados comparables a los proporcionados por el muestreo intensivo SP1 ( $r > 0.8$  y  $RMSE < 0.6$ ) para resoluciones media y baja. Este resultado es de gran relevancia dado que permitiría con un muestreo inferior a 50 ESUs y sin necesidad de información secundaria obtener un mapa de LAI sobre el área  $5 \times 5 \text{ km}^2$  para validar productos a media y baja resoluciones.



**Figura IV.24.** (a) Coeficiente de correlación y (b) RMSE obtenido a partir de los modelos KO (izquierda) y CKC (centro) y KDE (derecha) respecto a las estimaciones FT para los cuatro muestreos diseñados y las tres resoluciones espaciales (20 m, 300 m y 1000 m).

## IV. 4 Conclusiones

En este capítulo se han evaluado dos técnicas para obtener mapas de los parámetros LAI, FVC y FAPAR a alta resolución a partir de medidas *in-situ*. A continuación se detallan las principales conclusiones derivadas del estudio.

Respecto a las técnicas utilizadas para la estimación de parámetros biofísicos con datos *in-situ*:

1. El método basado en técnicas de regresión multivariada proporciona un error de validación cruzada para el LAI, FVC y FAPAR de aproximadamente 0.7, 0.19 y 0.18, respectivamente, que puede considerarse un estimador realista del error.
2. El modelo KDE se presenta como una técnica comparable a la FT, dada la alta correspondencia entre sus estimaciones ( $r = 0.9$  y  $RMSE < 0.5$ ) y el bajo error de estimación con las medidas *in-situ*  $LAI_{DHP}$ .

3. El modelo CKC también proporciona una alta correspondencia con la FT ( $r=0.8$  y  $RMSE=0.9$ ).
4. El modelo KO es el que peor se ajusta a las estimaciones de la FT y peor reproduce la variabilidad a escalas finas.

Respecto al muestreo realizado con los dos instrumentos se obtiene que:

1. Para la técnica de regresión multivariada, la alta correlación ( $r=0.98$ ) y bajo error ( $RMSE=0.26$ ) entre los mapas  $LAI_{LICOR}$  y  $LAI_{DHP}$  indica una alta consistencia entre ambos productos derivados a partir de muestreos espaciales diferentes. Se pone de manifiesto que el número de ESUs adquiridas con la cámara hemisférica (50) es adecuado para caracterizar la variabilidad de la zona de estudio.
2. Para la técnica geoestadística, el muestreo del  $LAI_{DHP}$  parece poco adecuado para aplicar esta técnica debido a que las observaciones no cubren toda el área de estudio.

Respecto a la influencia del muestreo:

1. Para la técnica multivariada, los muestreos sistemáticos (i.e. SP1 y SP2) son los que presentan mayor porcentaje de píxeles interpolados (e.g. 98% y 92%), pero, también, son más difíciles de llevar a la práctica debido al elevado número de ESUs y a las limitaciones de acceso en el campo.
2. Para la técnica multivariada, el muestreo SP3 resulta más fácilmente trasladable a nuestra área de estudio.
3. Para las técnica geoestadísticas, el muestreo SP1 es el que mejor reproduce las estimaciones de la FT para los tres modelos a alta resolución. Proporciona coeficientes de correlación mayor que 0.85 y RMSE menores que 0.9 para los tres modelos y presenta poca contribución de la variable secundaria.
4. Para las técnica geoestadísticas, el muestreo SP4 proporciona resultados comparables al muestreo SP1 para los modelos CKC y KDE a alta resolución, con coeficientes de correlación altos ( $r>0.9$ ) y RMSE bajos (menor de 0.65).

Evaluación de la configuración óptima en función de la resolución espacial:

1. El modelo KDE es el que proporciona resultados similares a la FT para todas las resoluciones y muestreos ( $RMSE < 0.3$  y  $r > 0.95$ ). Si se dispone de información secundaria el muestreo SP4 se presenta adecuado para estimar mapas a diferentes resoluciones espaciales minimizando los esfuerzos en el campo.

2. Si no se dispone de información secundaria, el modelo KO y el muestreo SP4 proporcionan resultados comparables al muestreo intensivo SP1 para resoluciones espaciales media y baja. Este resultado es de gran relevancia dado que permitiría con un muestreo inferior a 50 ESUs y sin necesidad de información secundaria obtener un mapa de LAI para validar productos a la resolución espacial de 1000 m.

## CAPÍTULO V

---

---

### VALIDACIÓN DE PRODUCTOS DE BAJA RESOLUCIÓN

---

---

*En este capítulo realizamos una validación de diferentes productos pre- y operacionales de baja resolución sobre el área agrícola de Barrax y la Península Ibérica. Con este capítulo se pretende mostrar la aplicación para validación de los mapas in-situ derivados a partir de la metodología propuesta en este trabajo, a la par que evaluar diferentes productos de baja resolución y, en particular, los productos derivados del prototipo VMESMA desarrollado con datos SEVIRI/MSG en el contexto del proyecto LandSAF. Los productos escogidos para validar corresponden a los parámetros LAI, FVC y FAPAR derivados a partir de datos VEGETATION/SPOT, MODIS/TERRA y SEVIRI/MSG. En particular, se han obtenido los productos de FVC y LAI con datos VEGETATION al aplicar el algoritmo VMSEMA utilizado en LandSAF. De este modo, se pretende evaluar el prototipo VMESMA con otros datos de entrada que presentaban una mejor calidad que los datos SEVIRI/MSG disponibles. Otros productos validados corresponden a los parámetros FVC, LAI y FAPAR derivados en el proyecto CYCLOPES con los mismos datos VEGETATION en los que se ha aplicado el prototipo de LandSAF. Por último, se ha incluido en la discusión los productos LAI y FAPAR derivados a partir de datos MODIS/TERRA. La validación de estos productos ha consistido en aplicar los dos primeros procedimientos descritos en el capítulo I. Por una parte, se ha realizado la validación directa de los productos derivados con datos VEGETATION y MODIS en las dos áreas descritas en el capítulo anterior, 5×5 km<sup>2</sup> y 50×50 km<sup>2</sup> (Sección V.1). Por último, se ha llevado a cabo la validación indirecta de todos los productos para toda la Península Ibérica (Sección V.1.2).*

Los objetivos de este capítulo son,

1. Validar diferentes productos de vegetación y especialmente el prototipo desarrollado para la estimación del LAI y FVC en LandSAF.
2. Mostrar una aplicación concreta de la metodología propuesta para caracterizar a alta resolución los parámetros de la vegetación LAI, FVC y FAPAR.

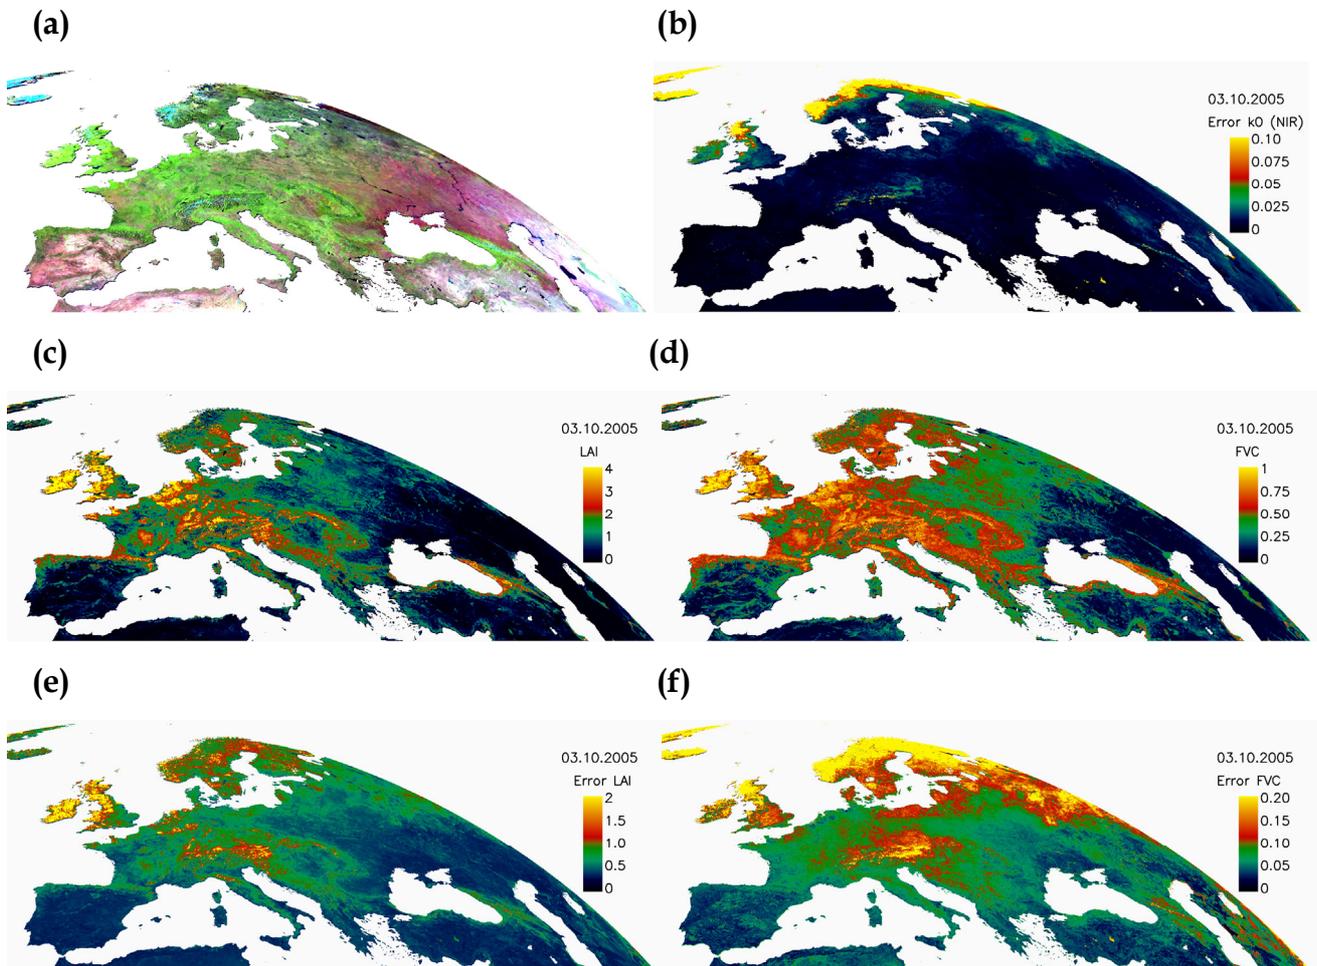
Para ello se han llevado a cabo las dos primeras etapas de la validación descritas en el capítulo I, esto es, (i) la validación directa y (ii) la validación indirecta. La validación directa permitirá evaluar la exactitud del producto a partir de la comparación directa entre las estimaciones derivadas mediante satélite y los mapas verdad-terreno derivados a partir de la metodología propuesta en esta memoria. La validación indirecta proporcionará información sobre el rango de variabilidad de cada producto, su precisión, posibles problemas o mala caracterización en determinadas cubiertas

Los productos utilizados corresponden a productos actualmente en uso o en fase pre-operacional como los derivados en MODLAND (e.g. LAI y FAPAR derivados con datos MODIS/TERRA), en el proyecto CYCLOPES (e.g. LAI, FVC y FAPAR derivados con datos VEGETATION/SPOT) o en el proyecto LandSAF (e.g. LAI y FVC derivados con datos SEVIRI/MSG).

En esta aplicación, se ha mostrado especial interés por evaluar el prototipo y los productos derivados con el algoritmo empleado en el proyecto LandSAF, *Variable Multiple Endmember Spectral Mixture Análisis* (VMESMA). Tal como se ha comentado, el planteamiento de la metodología propuesta en este trabajo surge por el compromiso adquirido por nuestro grupo en la validación de parámetros biofísicos derivados dentro del proyecto LandSAF. Actualmente, todos los algoritmos están siendo integrados en el sistema informático de LandSAF y produciendo los diferentes productos. El paso siguiente consiste en validarlos, asociar un error y demostrar su credibilidad y competitividad con el resto de productos actualmente en uso antes de distribuirlos a los usuarios.

Sin embargo, cuando comenzamos este estudio solamente se disponía de un producto preliminar LandSAF, y un prototipo todavía en desarrollo. El *input* o BRDF de los productos preliminares LandSAF presentaba poca calidad. Por lo tanto, y teniendo en cuenta el impacto de la calidad del *input* en los productos derivados, decidimos aplicar el prototipo LandSAF a los mismos datos con los que se obtenían otros de los productos a validar en este trabajo (i.e. VEGETATION). De este modo, es posible evaluar la consistencia del algoritmo LandSAF frente a otros algoritmos (e.g. CYCLOPES) y productos (e.g. MODIS). Cabe esperar, lógicamente, una mejor consistencia entre productos derivados con distintos algoritmos pero idéntico *input* que entre productos obtenidos al aplicar diferentes algoritmos a datos diferentes.

La figura V.1 muestra un ejemplo de los productos que se obtienen en la cadena de LandSAF actualmente. La figura V.1.a corresponde a la BRDF corregida para el 3 de Octubre de 2005 y la figura V.1.b al error de la banda del NIR. Las figuras V.1.c, V.1.d, V.1.e y V.1.f corresponden a los productos y errores de LAI y FVC derivados de dicha BRDF utilizando el algoritmo diseñado en LandSAF, respectivamente.



**Figura V.1.** Productos de BRDF corregida para el 3 de Octubre de 2005 (a) junto con los productos y errores siguientes derivados del algoritmo diseñado en LandSAF: error asociado a la banda del NIR (b), el producto LAI (c), el producto FVC (d), el error del LAI (e) y el error de la FVC (f).

## V.1 Validación de productos a baja resolución

Los productos utilizados corresponden a Julio de 2003 para que coincidieran con las medidas de referencia obtenidas durante la campaña de SPARC. Éstos han sido proporcionados directamente por los grupos científicos encargados de estimar cada parámetro. En algunos casos, como MODIS o MSG, no ha sido posible adquirir la imagen simultánea a la campaña de medidas, mostrando un desplazamiento temporal entre una y dos semanas. A continuación se describen los diferentes productos utilizados:

1. FVC, LAI y FAPAR producidos en CYCLOPES con datos VEGETATION a partir del algoritmo versión 1 (VGT\_CYC\_v1) descrito en Roujean & Lacaze (2002), el cual se basa en un método semiempírico a partir del índice de vegetación DVI (Roujean & Bréon 1995). El algoritmo se ha aplicado a datos de reflectividad normalizada en el techo de la cubierta (TOC), lo que corresponde al parámetro  $k_0$  derivado del modelo paramétrico de Roujean et al. (1992). Las imágenes de VEGETATION corresponden a la segunda decena del mes de Julio y por tanto coinciden con la campaña de campo de SPARC.
2. FVC y LAI derivados con el algoritmo VMESMA en su versión 1 con los mismos datos VGT de reflectividad TOC, tal y como ha sido implementado en la cadena de producción de LandSAF (VGT\_LandSAF\_v1) descrito en García-Haro et al. (2005a) y Camacho-de Coca (2004).
3. FVC y LAI derivados con el algoritmo VMESMA en su versión 1 con datos MSG (MSG\_LandSAF\_v1). En este caso, el sistema de recepción se encontraba en fase de prueba y no fue posible disponer de una imagen simultánea a la campaña de campo. La imagen disponible fue la del 28 de Julio y presenta algunos fallos en la zona de  $50 \times 50 \text{ km}^2$  que hacen que no sea posible utilizarla para la validación directa. Los productos derivados con datos MSG se incluirán solo en la validación indirecta. Cabe destacar que el producto MSG\_LandSAF\_v1 corresponde a un producto preliminar del prototipo LandSAF aplicado sobre datos de  $K_0$  de poca precisión. Actualmente existen datos de  $K_0$  con mayor confianza, los cuales están siendo utilizados con una nueva versión del prototipo.
4. LAI y FVC oficiales de MODLAND (MODIS\_v4) derivados con datos MODIS/TERRA y obtenidos a partir de la lista de distribución proporcionada por el centro de soporte ORNL DAAC. Los productos consisten en composiciones de ocho días (MOD15A2) a la resolución espacial de 1 km y pertenecen a la colección 4 (V4), los cuales han sido validados e incluyen una imagen QF. Los productos LAI y FAPAR se han estimado a partir de un modelo de transferencia radiativa 3-D descrito en Knyazikhin et al. (1998) y aplicado en Knyazikhin et al. (1999) y Myneni et al (2002). En este caso, los productos MODIS tampoco coinciden exactamente con la adquisición *in-situ* debido a la falta de datos para estas fechas. Los productos corresponden a la decena del 25 de Junio al 4 de Julio los cuales mostraban visualmente un estado de la vegetación similar al encontrado en el campo.

Una vez se han recogido todos los productos a validar, el siguiente paso consiste en registrar todos los productos a un mismo sistema de referencia y posteriormente cortar el área de interés. La proyección elegida ha sido la UTM Mercator con el elipsoide correspondiente a European 1950 coincidente con los mapas de

referencia. La tabla V.1 proporciona las principales características de los datos. Posteriormente, a excepción de la validación directa del área 5×5 km<sup>2</sup>, se han escalado todos los productos a una resolución de 3 km dado que es la resolución más baja de la que disponemos y además se consigue reducir el error debido al registrado ( $\pm 1$  píxel). El método de agregación elegido consiste en la media aritmética de una ventana de 3×3 píxeles dada su fácil aplicación y uso extendido en este tipo de estudios (Liang 2004, Woodcock & Strahler 1987).

**Tabla V.1.** Características de los datos de reflectividad utilizados para derivar los parámetros biofísicos.

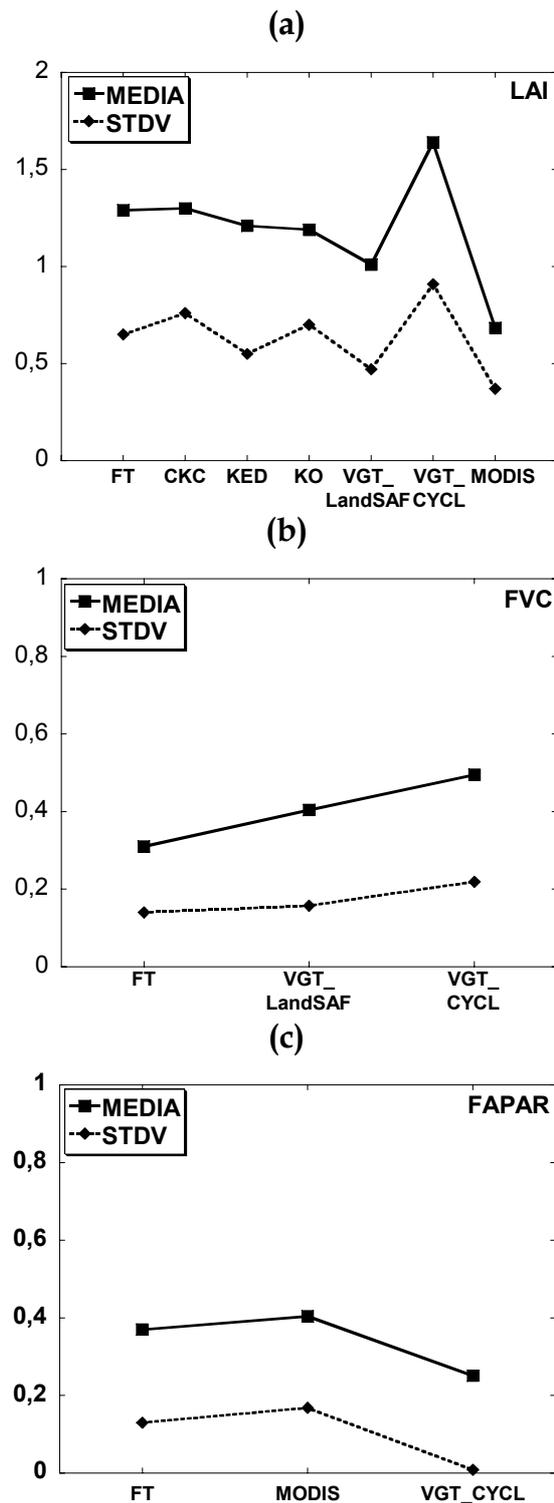
|                            | MODIS             | VGT   | MSG   |
|----------------------------|-------------------|---|---|
| <i>Input</i>               | Reflectividad TOC | Reflectividad TOC normalizada (k0 del modelo paramétrico de Roujean et al (1992)) | Reflectividad TOC normalizada (k0 del modelo paramétrico de Roujean et al (1992)) |
| <b>Resolución Espacial</b> | 1 km              | 1 km  | 3 km  |
| <b>Resolución Temporal</b> | 10 días           | 10 días   | Diaria  |
| <b>Proyección</b>          | ISIN              | Platee Carre  |   |

### V.1.1 Validación directa

La validación directa de los productos LAI, FVC y FAPAR se ha realizado para las áreas de 5×5 km<sup>2</sup> y de 50×50 km<sup>2</sup>, respectivamente. El motivo principal de realizar también la validación directa en el área 50×50 km<sup>2</sup>, se debe a que, de este modo, se tiene mayor significación estadística para realizar la comparación y se puede minimizar el error que se introduce en la validación debido al co-registrado de los productos a la misma proyección. En la validación directa no se han incluido los productos derivados de MSG dado que presentaban una alta proporción de píxeles con error de procesado en el área de 50×50 km<sup>2</sup>.

#### Área 5×5 km<sup>2</sup>

La validación directa en el área de 5×5 km<sup>2</sup> se ha realizado utilizando los mapas verdad-terreno derivados en el capítulo IV con el método de función de transferencia (FT), para el LAI, FVC y FAPAR. También se han incluido las estimaciones derivadas para el LAI a partir de los métodos KO, KDE y CKC. El procedimiento ha consistido en comparar el valor medio, desviación estándar, coeficiente de correlación y RMSE de cada producto respecto al proporcionado por los mapas de referencia. La figura V.2 muestra la comparación del valor medio en esta área para el LAI (a), FVC (b) y FAPAR (c).



**Figura V.2.** Valores medios y desviación estándar de los diferentes productos de LAI, FVC y FAPAR a validar junto con los mapas *in-situ* para cada parámetro y para el área 5×5 km<sup>2</sup>. En el caso del LAI, también se han incluido los mapas derivados con las técnicas geostatísticas.

En general, se observa un buen ajuste de los productos LAI y FVC derivados del algoritmo LandSAF\_v1 respecto a los mapas *in-situ*, con coeficientes de correlación aceptables (0.56 y 0.60, respectivamente) respecto al mapa derivado de la FT y valores de RMSE bajos (0.60 y 0.15, respectivamente), ver tabla V.2. También se observa en la figura V.2a valores medios similares entre los mapas derivados a partir de los modelos geostadísticos y el producto VGT\_LandSAF\_v1. En el caso de los productos derivados del algoritmo CYCLOPES versión 1, se obtienen diferencias mayores en el valor medio respecto al mapa de la FT para los tres parámetros. Sin embargo, se observa un coeficiente de correlación para el LAI y FVC similares a los que muestra el producto VGT\_LandSAF\_v1 pero con RMSE mayores. En el caso de la FAPAR, este algoritmo muestra una correlación con el mapa FT de 0.5, mayor que el producto de MODIS\_v4. Por último, los productos derivados de MODIS\_v4, a pesar de ser los más desarrollados, muestran la peor correlación con los mapas *in-situ* derivados de la FT.

A continuación, se ha incluido en la validación de los productos de LAI la comparación con los mapas *in-situ* derivados a partir de los modelos geostadísticos KO, CKC y KDE, utilizando el muestreo estratificado SP4 que mostraba una mayor correlación con las estimaciones derivadas a partir de la FT. La tabla V.3 muestra los coeficientes de correlación y RMSE obtenidos al comparar los mapas de LAI. En general, se observan para los tres modelos geostadísticos coeficientes y RMSE similares a los obtenidos con las estimaciones de la FT. En este caso, el producto CYCLOPES es el que peor correlación presenta con todos los modelos. Con este análisis se refuerzan las afirmaciones realizadas en el capítulo anterior respecto al modelo más simple KO, el cual mostraba resultados comparables a los modelos FT y KDE para resoluciones espaciales de 1 km sin necesidad de incluir información de la variable secundaria.

**Tabla V.2.** Coeficiente de correlación y RMSE para los diferentes productos LAI, FVC y FAPAR respecto al mapa de referencia en el área de 5×5 km<sup>2</sup>.

|          | LAI      |      | FVC      |      | FAPAR    |      |
|----------|----------|------|----------|------|----------|------|
|          | <i>r</i> | RMSE | <i>r</i> | RMSE | <i>r</i> | RMSE |
| TF_SAF   | 0.6      | 0.6  | 0.6      | 0.15 | -        | -    |
| TF_CYC   | 0.6      | 0.8  | 0.6      | 0.2  | 0.5      | 0.17 |
| TF_MODIS | 0.4      | 0.8  | -        | -    | 0.4      | 0.16 |

**Tabla V.3.** Estadísticos entre el producto LAI derivado con los algoritmos LandSAF\_v1, MODIS\_v4 y CYCLOPES\_v1 y las estimaciones de los modelos KO, CKC y KDE y el muestreo SP4.

|         | LandSAF  |      | MODIS    |      | CYCLOPES |      |
|---------|----------|------|----------|------|----------|------|
|         | <i>r</i> | RMSE | <i>r</i> | RMSE | <i>r</i> | RMSE |
| KO_SP4  | 0.5      | 0.6  | 0.5      | 0.9  | 0.4      | 0.8  |
| CKC_SP4 | 0.6      | 0.8  | 0.6      | 1.0  | 0.4      | 0.8  |
| KDE_SP4 | 0.5      | 0.6  | 0.5      | 0.9  | 0.4      | 0.8  |

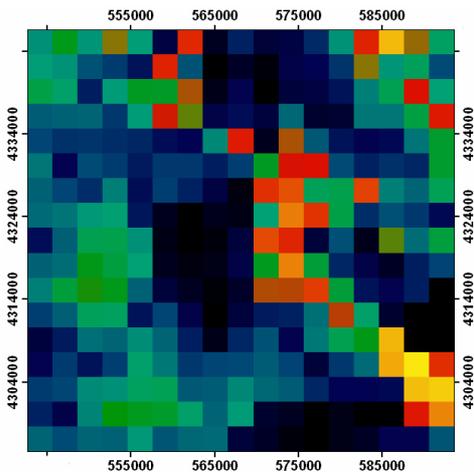
## Área 50×50 km<sup>2</sup>

Tal como se comentó en el capítulo de fundamentos teóricos, la validación es un proceso complicado que puede estar afectado por los errores asociados a cada uno de los pasos que la constituyen. Uno de los errores más difíciles de minimizar se debe al proceso de georeferenciación, sobre todo cuando la zona a validar presenta un cierto grado de heterogeneidad, como es nuestro caso. Este proceso, junto con la poca significación estadística del área de 5×5 km<sup>2</sup>, puede influir en la dispersión que mostraban los productos en el apartado anterior respecto a los mapas de referencia. Por ello y con tal de minimizar los errores asociados a la georeferenciación, se ha realizado la validación directa sobre un área mayor y se han degradado todos los productos a la resolución espacial de 3 km.

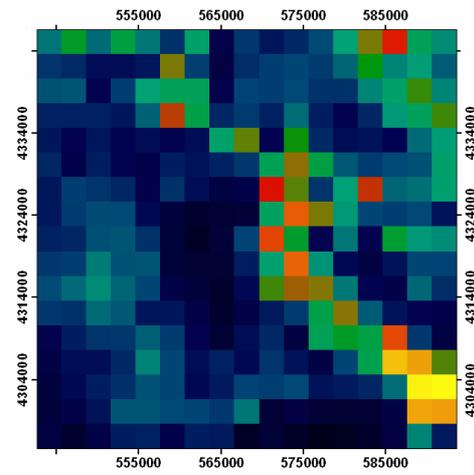
En el caso del LAI, la figura V.3 muestra los diferentes mapas de la zona de estudio a 3 km de resolución. La figura V.3a corresponde al mapa *in-situ* de LAI derivado a partir de la FT, donde es posible apreciar la heterogeneidad de la zona y los 3 principales tipos de superficies, (i) cultivos con un LAI máximo de 2 (píxeles más brillantes en el centro de la imagen), (ii) suelo desnudo (píxeles más oscuros alrededor de los cultivos) y (iii) vegetación natural con valores intermedios de LAI inferior a 1. Una inspección visual con los productos de satélite muestra ligeras diferencias entre los productos. La figura V.3b corresponde al producto de LAI derivado con VGT\_LandSAF\_v1, el cual presenta una mayor similitud en la distribución espacial con relación a los valores *in-situ*. También se observa una muy buena correlación entre los dos mapas derivados a partir de VGT con los algoritmos empleados en LandSAF y CYCLOPES. Finalmente, la figura V.3d pone de manifiesto que el LAI derivado de MODIS\_v4 es el que presenta mayores discrepancias.

Estas diferencias y similitudes se ponen de manifiesto en la figura V.4, donde se representan los histogramas de los productos junto con el mapa *in-situ* para la resolución espacial de 1 km (a) y 3 km (b). En primer lugar, se observan distribuciones similares de todos los productos respecto al mapa *in-situ* cuando se degradan a la resolución de 3 km. Este comportamiento, pone de manifiesto el error introducido por la georeferenciación el cual se puede minimizar disminuyendo la resolución espacial de los productos. Al igual que se observó en la figura V.3a, los productos VGT\_LandSAF\_v1 y VGT\_CYC\_v1 muestran una distribución comparable al mapa de referencia para la resolución de 3 km. El producto MODIS\_v4 es el que presenta mayores diferencias al igual que en la zona de 5×5 km<sup>2</sup>.

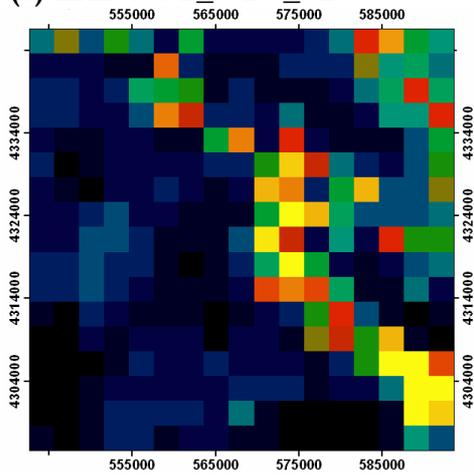
(a) LAI *in-situ*



(b) LAI VGT\_LandSAF\_v1



(c) LAI VGT\_CYC\_v1



(d) LAI MODIS\_v4

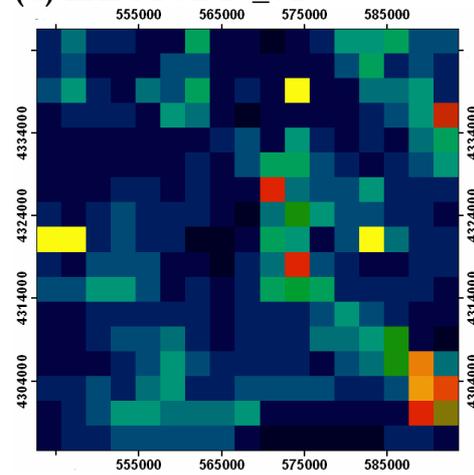
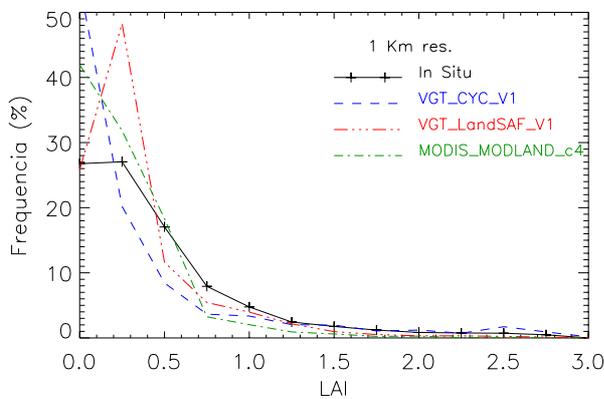


Figura V.3. Mapas de LAI para los productos (a) *in-situ*, (b) VGT\_LandSAF\_v1, (c) VGT\_CYC\_v1 y (d) MODIS\_v4.

(a) 1 km



(b) 3 km

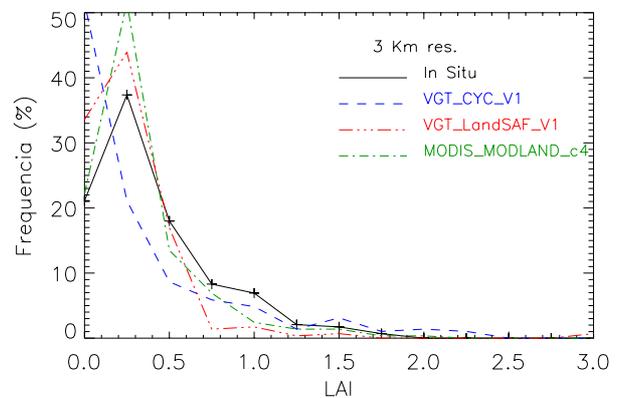
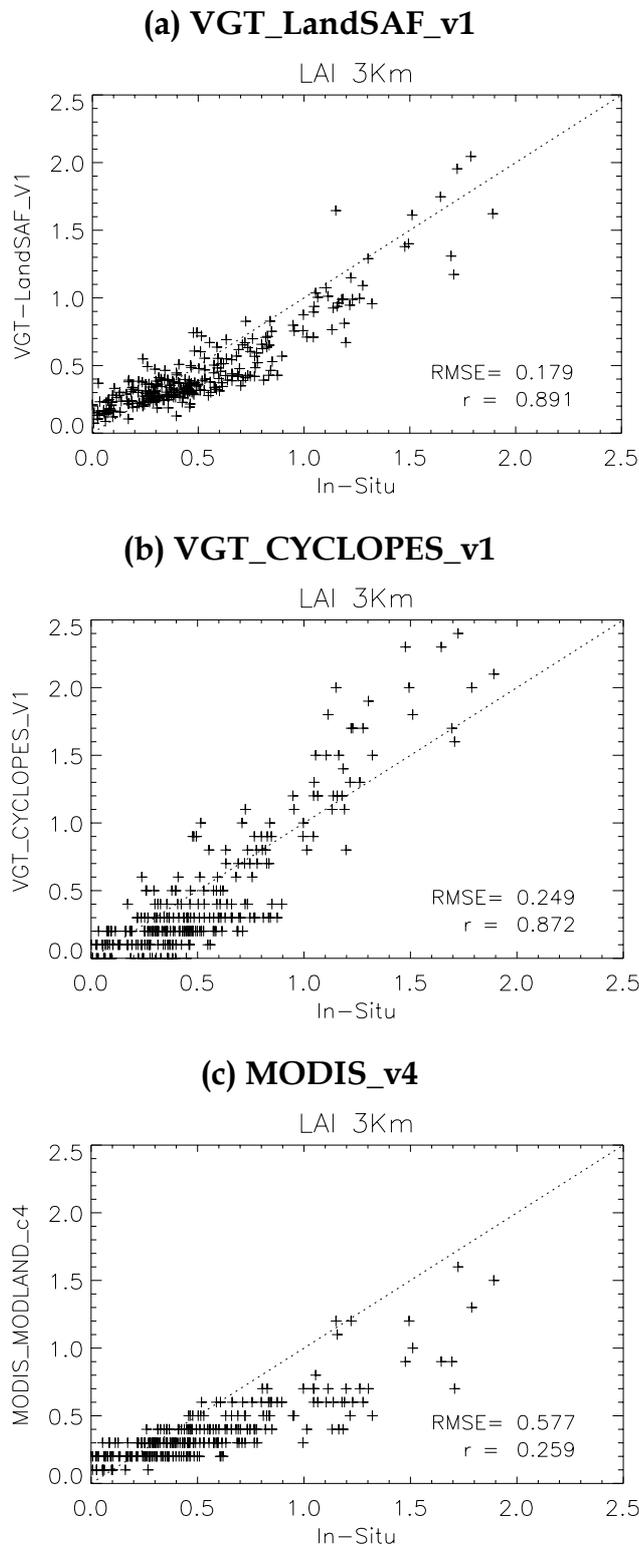


Figura V.4. Histogramas de los productos de LAI a validar junto con el mapa de LAI *in-situ* para la resolución de 1 km (a) y 3 km (b) sobre el área de 50×50 km<sup>2</sup>.

La figura V.5 muestra los diagramas de dispersión de los productos de LAI frente al mapa *in-situ* y la tabla V.3 los valores del coeficiente de dispersión y RMSE.



**Figura V.5.** Diagramas de dispersión, RMSE y coeficiente de Pearson entre los productos LAI de satélite y el mapa LAI *in-situ*.

Se observa de nuevo en la figura V.5 que el producto derivado con el algoritmo empleado en LandSAF es el que presenta una mayor correlación y RMSE con el mapa *in-situ*. La correlación se aproxima a 0.90 con un RMSE inferior a 0.18. En el caso del algoritmo CYCLOPES la correlación de los datos es también muy alta, con un RMSE algo mayor (0.2) pero todavía inferior al error del mapa *in-situ* asociado al muestreo (RMSE<0.3). El producto LAI de MODIS es el que muestra claras discrepancias con la verdad-terreno y, por tanto, también con los otros productos. El producto MODIS subestima el LAI *in-situ* con un RMSE cercano a 0.6 (para un valor medio de LAI de 1), y presenta una correlación muy baja, inferior a 0.3.

**Tabla V.4.** Coeficiente de correlación y RMSE para los diferentes productos LAI, FVC y FAPAR respecto al mapa de referencia en el área de 50×50 km<sup>2</sup>.

|          | LAI      |      | FVC      |      | FAPAR    |      |
|----------|----------|------|----------|------|----------|------|
|          | <i>r</i> | RMSE | <i>r</i> | RMSE | <i>r</i> | RMSE |
| TF_SAF   | 0.9      | 0.17 | 0.7      | 0.09 | -        | -    |
| TF_CYC   | 0.9      | 0.2  | 0.3      | 0.14 | 0.6      | 0.11 |
| TF_MODIS | 0.3      | 0.6  | -        | -    | 0.8      | 0.08 |

En el caso de la FVC, sólo se han incluido los mapas correspondientes a los productos derivados con los algoritmos de LandSAF y CYCLOPES dado que MODLAND no produce FVC. La figura V.6 muestra la presencia de valores más altos de FVC para los productos VGT\_LanSAF\_v1 (b) y VGT\_CYC\_v1 (c) respecto al mapa de referencia (a). Tal como sucedió para el LAI, los productos presentan distribuciones más parecidas a los mapas de referencia cuando la resolución espacial es menor (figura V.7b). De nuevo, el producto FVC derivado con el algoritmo de LandSAF es el que presenta una mayor correlación con el mapa *in-situ*, como se puede observar de la figura V.8 y de la tabla V.4. El producto VGT\_LandSAF\_v1 proporciona el mayor coeficiente de correlación ( $r > 0.7$ ) y menor RMSE (0.09). Se observa de la figura V.8a una tendencia a sobreestimar los valores de FVC (sesgo positivo) aunque con un RMSE inferior a 0.09. A diferencia de los resultados obtenidos para el área de 5×5 km<sup>2</sup>, el producto derivado de CYCLOPES\_v1 presenta una correlación muy baja (0.34) y un mayor RMSE (0.14). Se observa de la figura V.8b como existe una fuerte sobreestimación de la FVC, que oscila entre un factor 2 y 7 para los valores más altos (FVC próxima a 0.8).

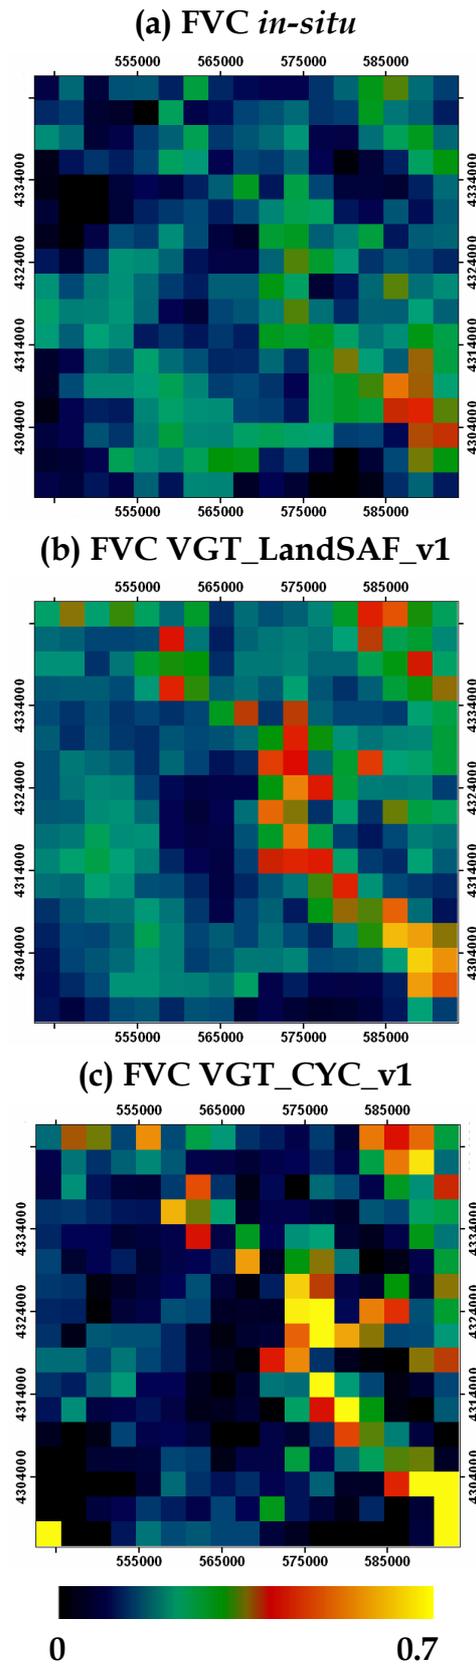
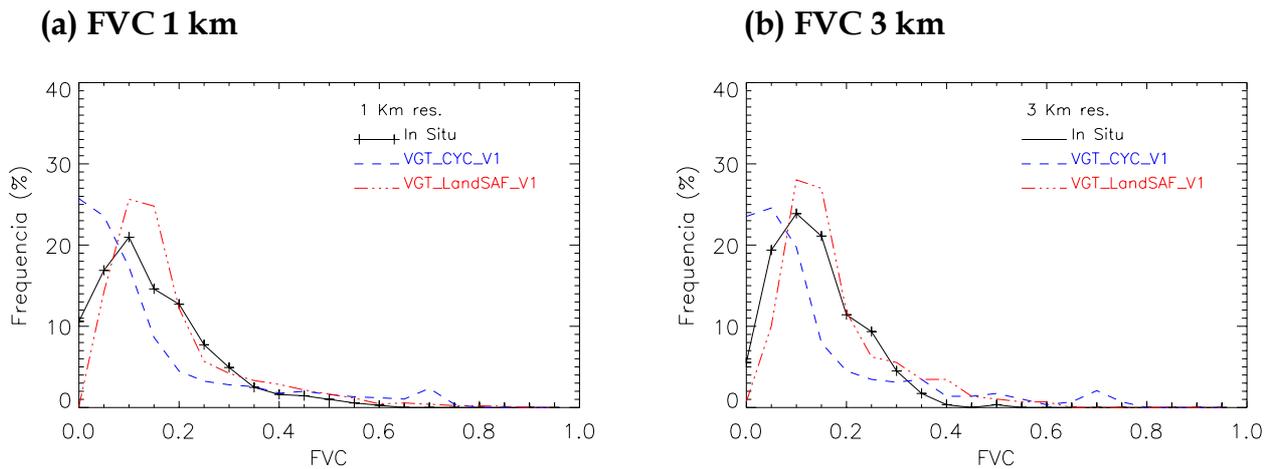
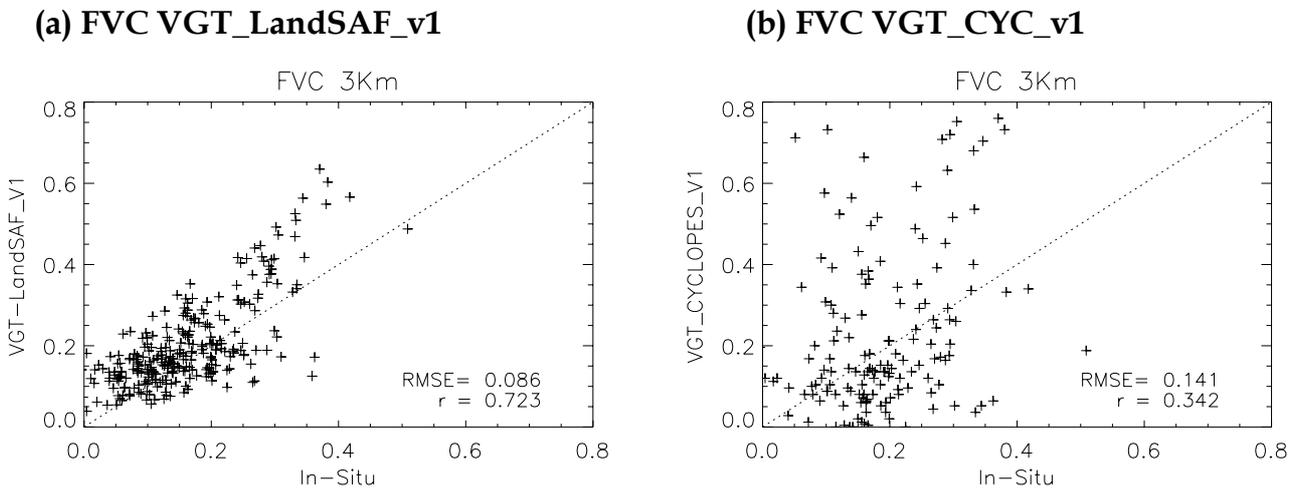


Figura V.6. Mapas de FVC para los productos *in-situ* (a), VGT\_LandSAF\_v1 (b) y VGT\_CYC\_v1 (c).



**Figura V.7.** Histogramas del producto FVC a validar junto con el mapa *in-situ* para la resolución de 1 km (a) y 3 km (b).



**Figura V.8.** Diagramas de dispersión, RMSE y coeficiente  $r$  para los productos de FVC VGT\_LandSAF\_v1 (a) y VGT\_CYC\_v1 (b) respecto a los mapas de referencia.

En el caso de la FAPAR, las figuras V.9a, V.9b y V.9c muestran los mapas para los productos *in-situ*, MODIS\_v4 y VGT\_CYC\_v1, respectivamente. A diferencia de los resultados obtenidos en el área de  $5 \times 5 \text{ km}^2$ , el producto MODIS\_v4 es el que proporciona visualmente una apariencia similar al mapa de referencia, con valores de FAPAR entre 0 y 0.7. Por otra parte, el producto derivado en CYCLOPES muestra valores de FAPAR más bajos, tal como se puede observar también a partir del histograma de frecuencias (figura V.10a y V.10b). El producto derivado en MODLAND es el que presenta una distribución más similar al mapa verdad-terreno para ambas resoluciones espaciales (i.e. 1 km y 3 km). La figura V.11a y V.11b pone de manifiesto la alta correlación del producto MODIS\_v4 (0.79) y el bajo RMSE (0.078), aunque con una tendencia a sobreestimar ligeramente la verdad-terreno. Por el contrario, el producto VGT\_CYC\_v1 pone de manifiesto una subestimación de la FAPAR respecto a los datos verdad-terreno, con una

correlación baja ( $r < 0.6$ ) y un RMSE de 0.12. El producto FAPAR MODIS presenta una mayor credibilidad en la zona y fechas analizadas.

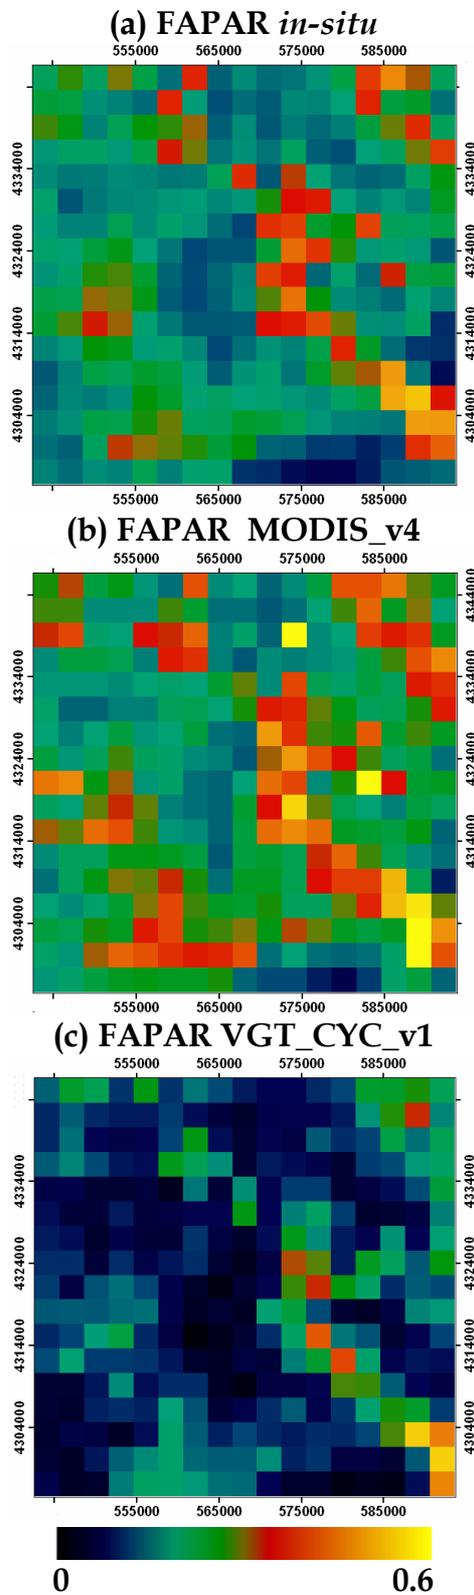
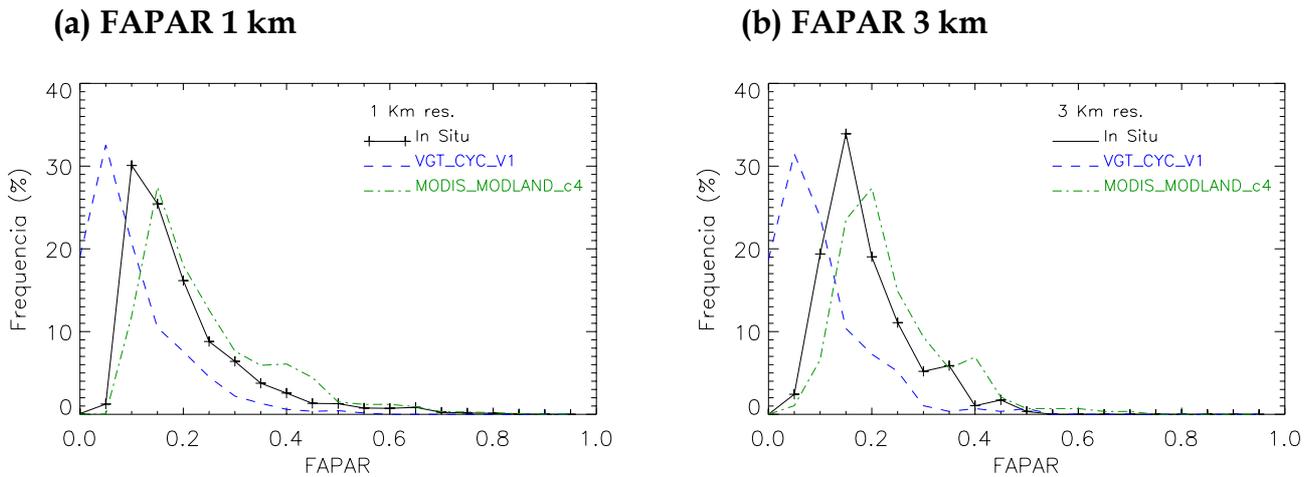
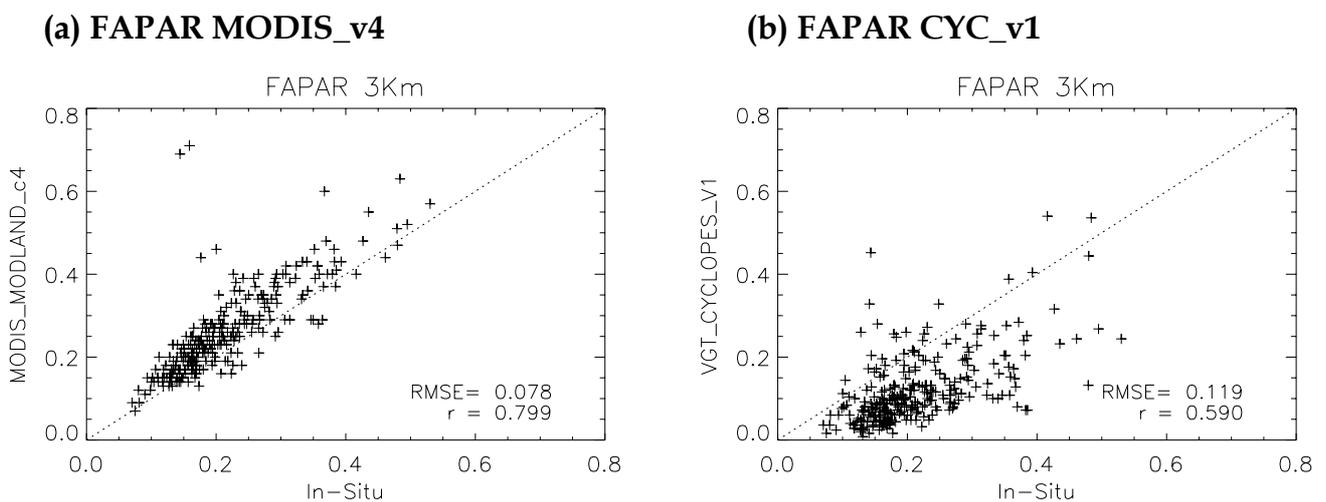


Figura V.9. Mapas de FAPAR para los productos *in-situ* (a), VGT\_MODIS\_v4 (b) y VGT\_CYC\_v1 (c).



**Figura V.10.** Histogramas del producto FAPAR a validar junto con el mapa *in-situ* para la resolución de 1 km (a) y 3 km (b).



**Figura V.11.** Diagramas de dispersión, RMSE y coeficiente de Pearson para el producto FAPAR respecto a los mapas de referencia.

### V.1.2 Validación indirecta

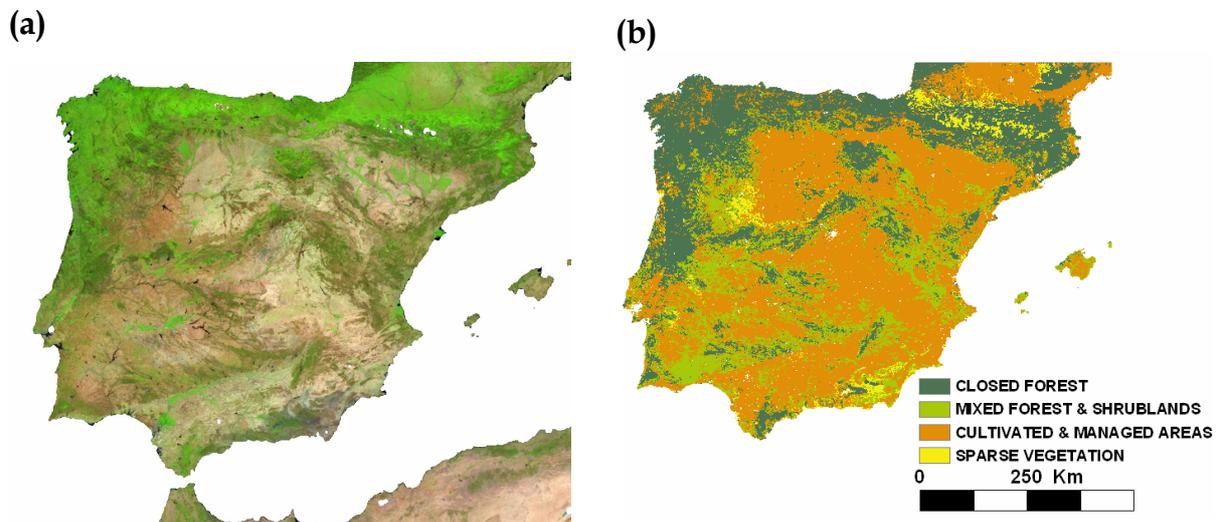
Tal como se ha comentado en el capítulo I, la validación indirecta consiste en la intercomparación entre diferentes productos mediante el análisis de tendencias y parámetros estadísticos, como el RMSE, *bias*, medias, desviación estándar, etc. Al contrario que la validación directa, este proceso no está limitado a la zona de estudio donde se realizan las medidas *in-situ*, por lo que es posible escoger un área mayor y un muestreo más amplio de tipos de cubiertas, tanto para una fecha en particular como para un periodo de tiempo determinado.

La comparación entre productos incluirá las diferencias debidas a un conjunto de factores como la resolución espacial y espectral de cada producto, el algoritmo utilizado para la corrección atmosférica o el prototipo para derivar los productos.

Por otra parte, la comparación entre productos derivados con un mismo prototipo pero diferente *input* reduce los errores debidos a las características del sensor, correcciones y proyecciones, permitiendo evaluar con mayor precisión diferencias asociadas al algoritmo.

Los productos utilizados para realizar la validación indirecta coinciden con los utilizados en el apartado anterior pero incluyendo, para el LAI y FVC, los productos derivados al aplicar el algoritmo LandSAF sobre datos MSG (i.e. MSG\_LandSAF\_v1). La validación indirecta se ha realizado para toda la Península Ibérica considerando cuatro tipos de cubiertas derivadas de la clasificación a 1 km Global Land Cover (GLC).

La figura V.12a muestra la composición de color RGB de la zona de estudio obtenida con las bandas de reflectividad 4, 3, y 2 normalizada a la observación del nadir (i.e. coeficiente K0 derivado de datos VEGETATION). La figura V.12b muestra los cuatro tipos de cubiertas correspondientes a vegetación densa (i.e. Closed Forest), vegetación media y arbustos (i.e. Mixed Forest & Shrublands), áreas cultivadas (i.e. Cultivated & Managed Areas) y vegetación dispersa (i.e. Sparse Vegetation). Aunque la GLC distingue 16 clases, se han agrupado en cuatro grupos las clases más dominantes en la Península Ibérica según el nivel de cobertura con el objetivo de simplificar el proceso de validación.

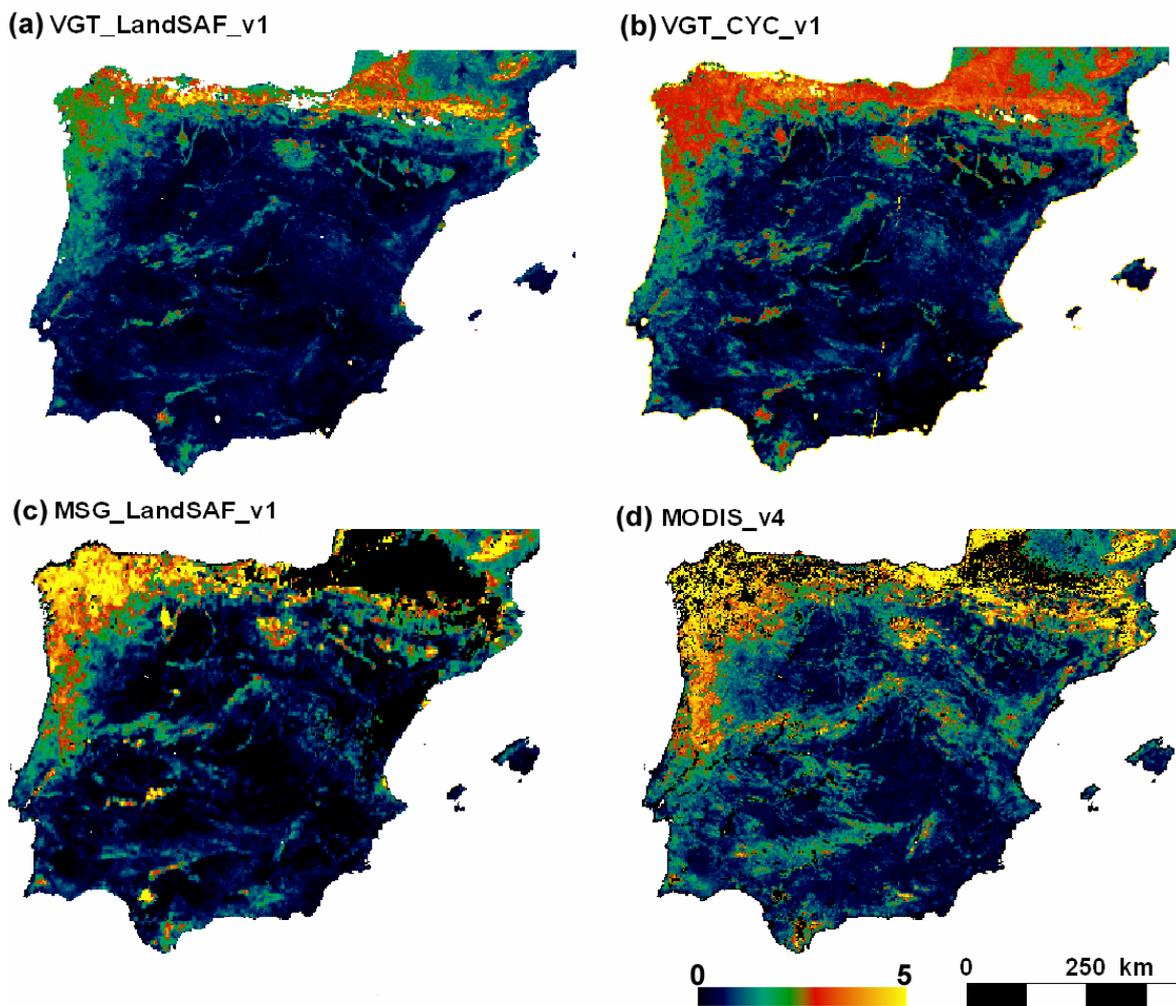


**Figura V.12.** Composición en color RGB (a) de la zona de estudio a partir de las bandas de reflectividad normalizada a la observación nadir 4, 3, y 2 (e.g. coeficiente k0 derivado de datos VGT). La imagen (b) corresponde a la clasificación de vegetación utilizada derivada de la Global Land Cover Classification (GLC).

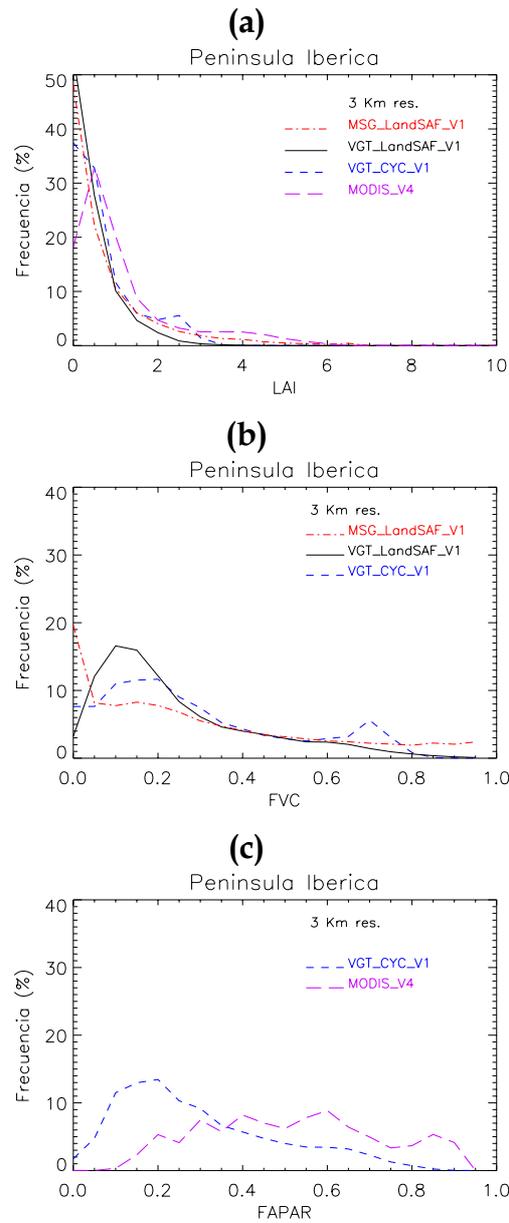
A continuación se presentan los resultados obtenidos en la validación indirecta de los productos LAI, FVC y FAPAR al considerar todas las clases juntas. En el caso del LAI, la figura V.13 muestra los productos de LAI utilizados, VGT\_LandSAF\_v1 (a), VGT\_CYC\_v1 (b), MSG\_LandSAF\_v1 (c) y MODIS\_v4 (d). Una primera

inspección visual pone de manifiesto la peor calidad de los productos MSG\_LandSAF\_v1 y MODIS\_v4 (e.g. zonas en negro al norte de la Península), debido principalmente a errores en el algoritmo o falta de información en la imagen de la que se deriva en producto.

En general, la figura V.13a y V.13b muestra una alta similitud de los productos VGT\_LandSAF\_v1 y VGT\_CYC\_v1, con diferencias más importantes en la zona norte de la Península donde el producto derivado en CYCLOPES proporciona valores más altos. El histograma de valores (figura 14a) muestra una distribución similar a partir de valores mayores de 1. Ambos productos muestran el menor rango de variación (entre 0 y 4), con valores medios igual a 0.7 y 0.9 (tabla V.5). Por otra parte, los productos MODIS\_v4 y MSG\_LandSAF\_v1 son los que presentan valores más altos de LAI, tal como se puede observar en la figura V.13a y V.13b, con una distribución de valores similar a partir de LAI mayores de 1 (figura V.14a). El producto de MODIS\_v4 es el que presenta una distribución de valores más diferente al resto caracterizada por el valor medio y desviación estándar más altos (1.4 y 1.2, respectivamente).



**Figura V.13.** Productos de LAI a 3 km de resolución correspondientes a VGT\_LandSAF\_v1 (a), VGT\_CYC\_v1 (b), MSG\_LandSAF\_v1 (c) y MODIS\_v4 (d).

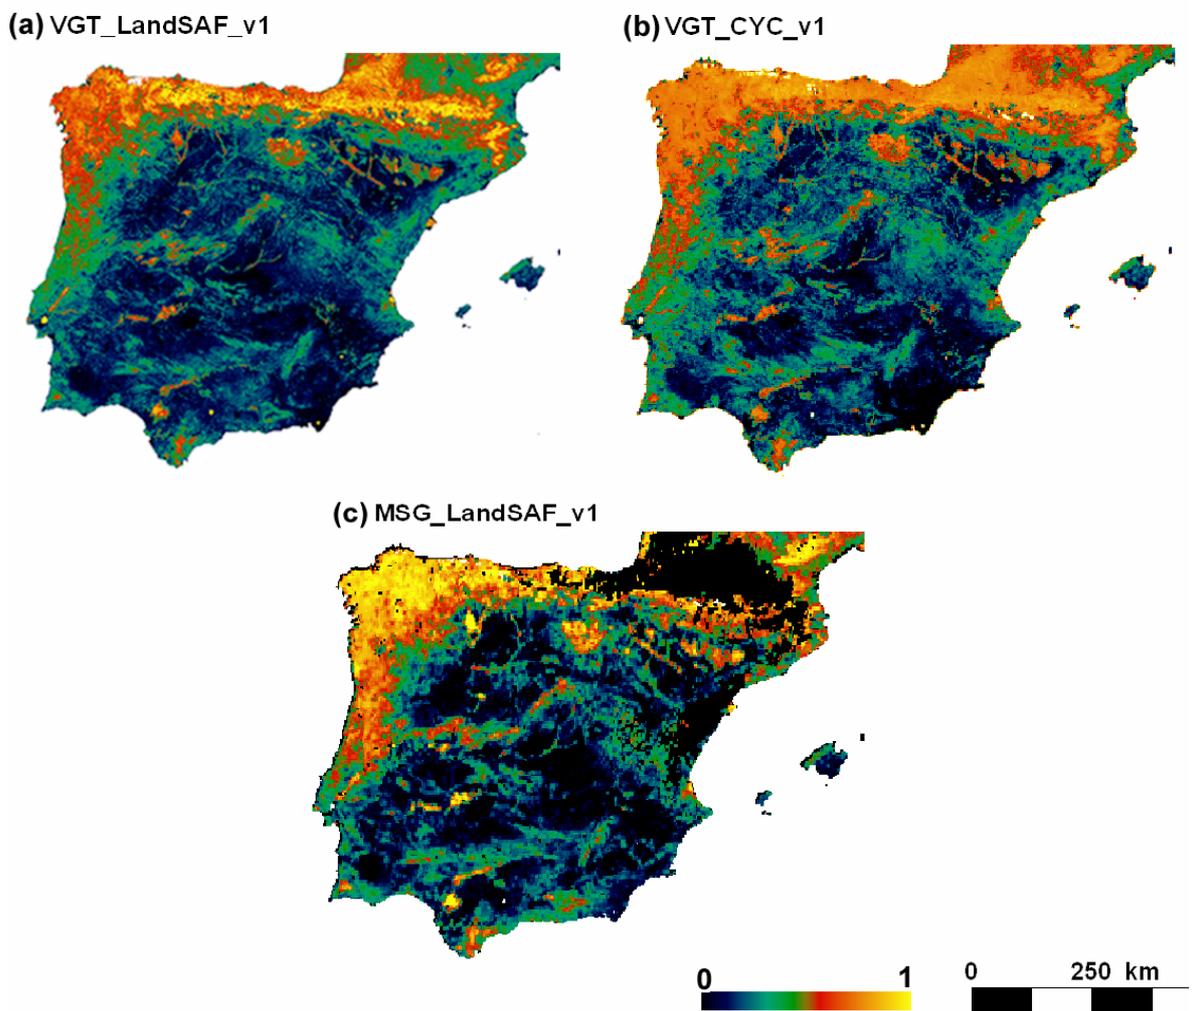


**Figura V.14.** Histogramas de los productos de LAI (a), FVC (b) y FAPAR (c) a la resolución espacial de 3 km.

**Tabla V.5.** Valores medio y desviación estándar ( $\sigma$ ) de los productos de LAI, FVC y FAPAR.

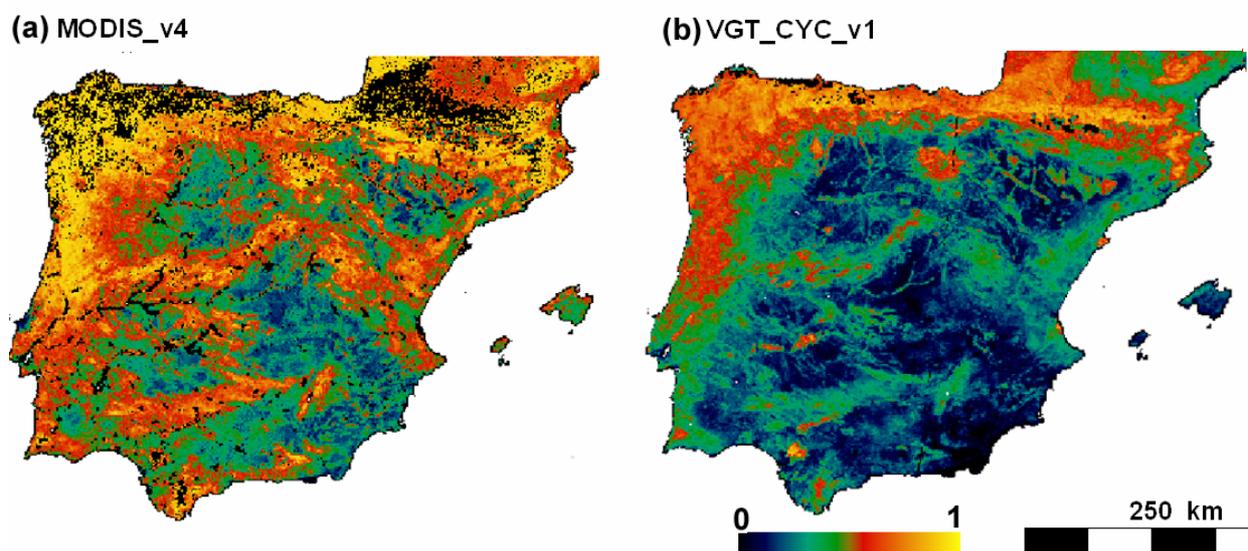
|                | LAI                | FVC                | FAPAR              |
|----------------|--------------------|--------------------|--------------------|
|                | Media ( $\sigma$ ) | Media ( $\sigma$ ) | Media ( $\sigma$ ) |
| MSG_LandSAF_v1 | 0.91 (1.14)        | 0.3 (0.3)          | -                  |
| VGT_LandSAF_v1 | 0.7(0.6)           | 0.26 (0.18)        | -                  |
| VGT_CYC_v1     | 0.9 (0.9)          | 0.3 (0.2)          | 0.30 (0.17)        |
| MODIS_v4       | 1.4 (1.2)          | -                  | 0.5 (0.2)          |

En cuanto al parámetro FVC, la figura V.15 muestra los tres productos utilizados en la validación, VGT\_LandSAF (a), VGT\_CYC\_v1 (b) y MSG\_LandSAF\_v1 sobre datos VGT. Se observa, de nuevo, la mayor similitud entre los productos derivados de CYC\_v1 y LandSAF\_v1. Este comportamiento se pone de manifiesto en el histograma (figura V.14b), donde se observa una mayor proporción de valores con FVC bajos por parte del producto VGT\_LandSAF\_v1, así como un mayor porcentaje de valores de FVC altos para el producto VGT\_CYC\_v1 (entre 0.6 y 0.8). El producto MSG\_LandSAF\_v1 presenta una mayor proporción de valores nulos y saturados en el norte de la Península, que puede atribuirse a la calidad del *input* en base a los resultados cuando se aplica el mismo algoritmo sobre datos VGT.



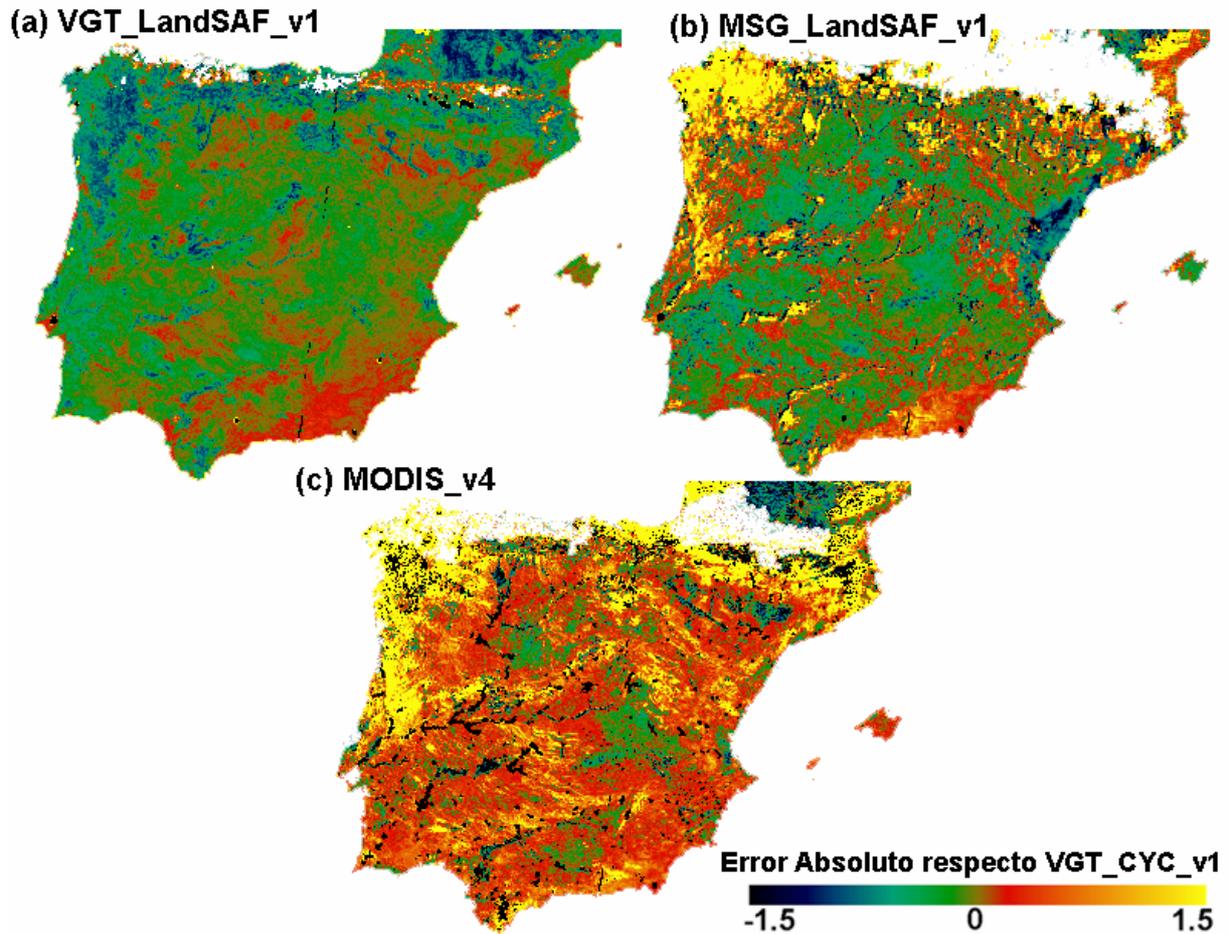
**Figura V.15.** Productos de FVC a 3 km correspondientes a VGT\_LandSAF\_v1 (a), VGT\_CYC\_v1 (b) y MSG\_LandSAF\_v1 (c).

Por último, los productos de FAPAR evaluados son los que presentan mayores diferencias, tal como se puede observar en los histogramas de la figura V.14c y de la figura V.16. El producto MODIS\_v4 presenta valores mucho más altos que el producto VGT\_CYC\_v1, con un valor medio un 100% superior al producto CYCLOPES (tabla V.5) y un máximo de la FAPAR alrededor de 0.6 (figura V.14c). Por el contrario, el algoritmo MODIS\_v4 proporciona una menor proporción de valores bajos de FAPAR (figura V.16a). A partir de los resultados obtenidos en la validación directa para el área de 50×50 km<sup>2</sup>, se obtenía una mayor confianza del producto MODIS\_v4, debido a su alta correlación con el producto verdad-terreno. Sin embargo a nivel peninsular, sería necesario comparar estos productos con más información de referencia para afirmar cuál reproduce mejor o peor dicho parámetro.



**Figura V.16.** Productos de FAPAR correspondientes a MODIS\_v4 (a) y VGT\_CYC\_v1 (b).

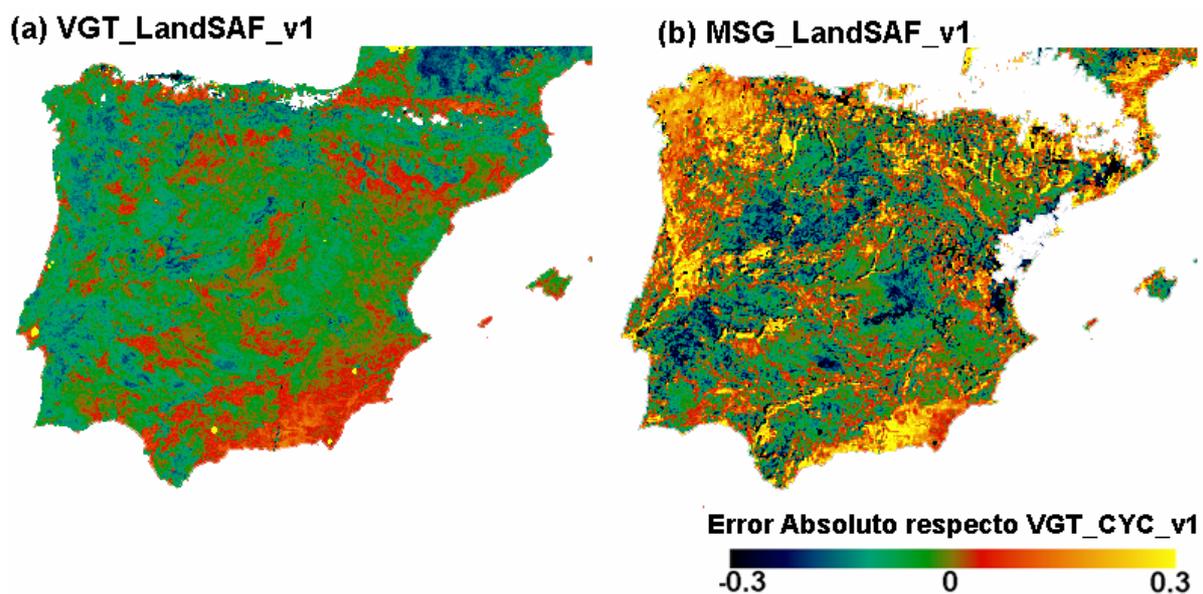
A continuación, se presenta el error absoluto de cada producto respecto al de referencia que hemos elegido. Dado que no se dispone de un mapa verdad-terreno para toda el área de estudio, se ha escogido el producto derivado de CYCLOPES versión 1 como referencia para la validación de todos los parámetros debido, principalmente, a que se ha obtenido a partir de un método sencillo y, a su vez, mostraba correlaciones aceptables en la validación directa para el LAI y FVC. La figura V.17 muestra el error absoluto para el LAI.



**Figura V.17.** Error absoluto de los productos (a) VGT\_LandSAF\_v1, (b) MSG\_LandSAF\_v1 y (c) MODIS\_v1 respecto al VGT\_CYC\_v1 para el LAI.

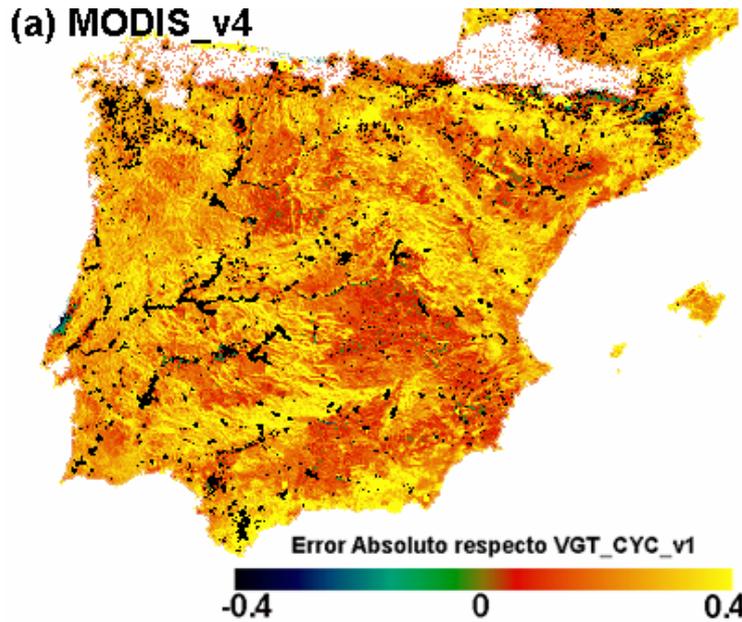
Se observa como el producto VGT\_LandSAF\_v1 (figura V.17a) proporciona resultados similares al producto de referencia, con errores absolutos alrededor de cero. El producto VGT\_LandSAF\_v1 sobreestima el LAI respecto al de referencia en zonas de vegetación dispersa (e.g. región de Murcia y Almería), mientras que subestima en la zona norte norte de la Península, donde se obtienen valores absolutos de hasta -1.5. Por otra parte, los productos MODIS\_v4 y MSG\_LandSAF\_v1 son los que presentan mayores diferencias. En general, sobreestiman respecto al producto VGT\_CYC\_v1 en toda la zona norte y noroeste de la Península, con errores absolutos de hasta 1.5. Para el resto de la Península, el producto MODIS\_v4 presenta un comportamiento opuesto al MSG\_LandSAF\_v1, donde MODIS\_v1 sobreestima (tonos rojos), MSG\_LandSAF\_v1 subestima (tonos verdes) a excepción de la región de Albacete, Murcia y Almería.

Respecto a la FVC, la figura V.18 muestra errores absolutos de hasta el 30%. En el caso del producto VGT\_LandSAF\_v1 (figura V.18a) se observa un comportamiento similar al producto de referencia al igual que para el LAI. Se obtienen errores absolutos alrededor de cero excepto en algunas zonas del norte de la Península y Portugal donde el producto VGT\_LandSAF\_v1 subestima respecto al VGT\_CYC\_v1 en un 30%. El producto MSG\_LandSAF\_v1 presenta errores absolutos muy altos en el norte de la Península, centro de la Península, región de Murcia y Almería debido a una mayor proporción de valores saturados y nulos.



**Figura V.18.** Error absoluto de los productos (a) VGT\_LandSAF\_v1 y (b) MSG\_LandSAF\_v1 respecto al VGT\_CYC\_v1 para la FVC.

Para la FAPAR, la figura V.19 muestra las diferencias entre el producto MODIS\_v4 y VGT\_CYC\_v1. Tal como se observó de la figura V.16, ambos productos muestran importantes diferencias de hasta un 40%. El producto MODIS\_v4 presenta valores más altos de FAPAR para toda la Península, obteniéndose errores de hasta un 40% (tonos amarillos) respecto al producto VGT\_CYC\_v1.

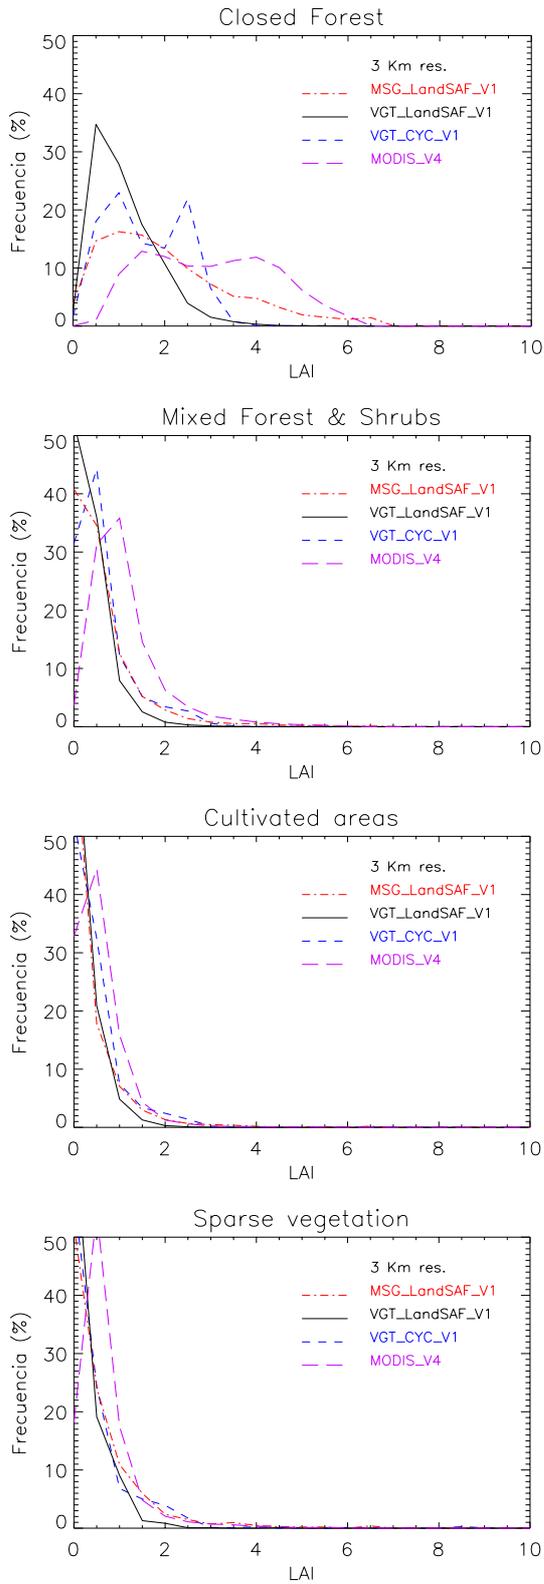


**Figura V.19.** Error absoluto del producto MODIS\_v4 respecto al VGT\_CYC\_v1 para la FAPAR.

A continuación incluimos la comparación entre productos pero distinguiendo por clases. El análisis se ha realizado comparando los histogramas de todos los productos, sus valores medios y desviaciones estándar. La figura V.20 muestra los histogramas por clases para los parámetros LAI (a), FVC (b) y FAPAR (c). Se observa para el LAI, que el producto MODIS\_v4 es el que presenta mayor diferencia con el resto para todas las clases tal y como se observó en la validación directa. En general, proporciona los valores más altos de LAI para todas las clases, lo que se refleja en el valor medio mostrado en la tabla V.5. Por otra parte, los productos VGT\_LandSAF\_v1 y VGT\_CYC\_v1 muestran una distribución similar para todas las clases, excepto para la clase Closed Forest, donde el producto VGT\_CYC\_v1 presenta un comportamiento diferente para valores intermedios de LAI.

En el caso de la FVC, los productos VGT\_LandSAF\_v1 y VGT\_CYC\_v1 presentan un comportamiento similar al obtenido anteriormente, excepto para la clase Closed Forest, donde el producto VGT\_CYC\_v1 presenta un máximo para valores de FVC alrededor de 0.7. Se observa, también, la mayor proporción de valores bajos de FVC (entre 0 y 0.2) para el producto VGT\_LandSAF\_v1, dando lugar a los valores medios más bajos (tabla V.6). Por el contrario, el producto MSG es el que presenta los valores medios más altos. Para la FAPAR, el producto de MODIS\_v4 muestra para todas las clases valores medios un 100% superiores que los mostrados por CYC\_v1 (tabla V.6), al igual que en el análisis anterior.

(a) LAI



(b) FVC

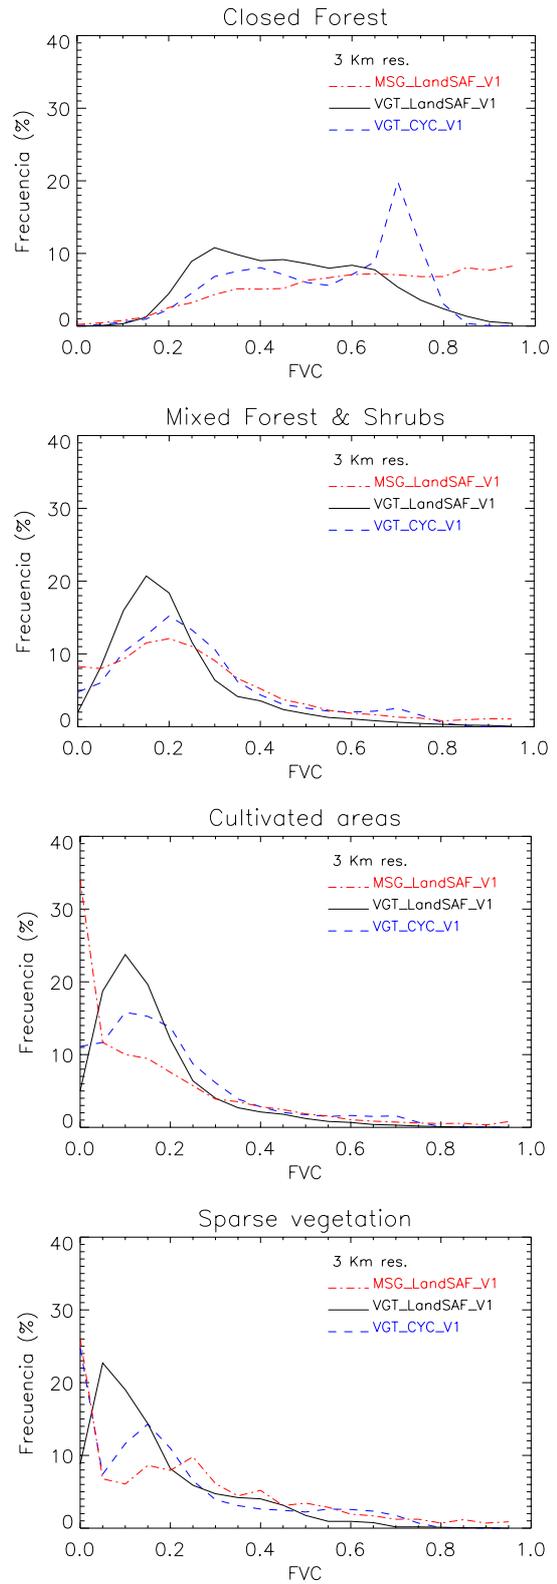


Figura V.20. Histogramas por clases de los diferentes productos LAI (a) y FVC (b).

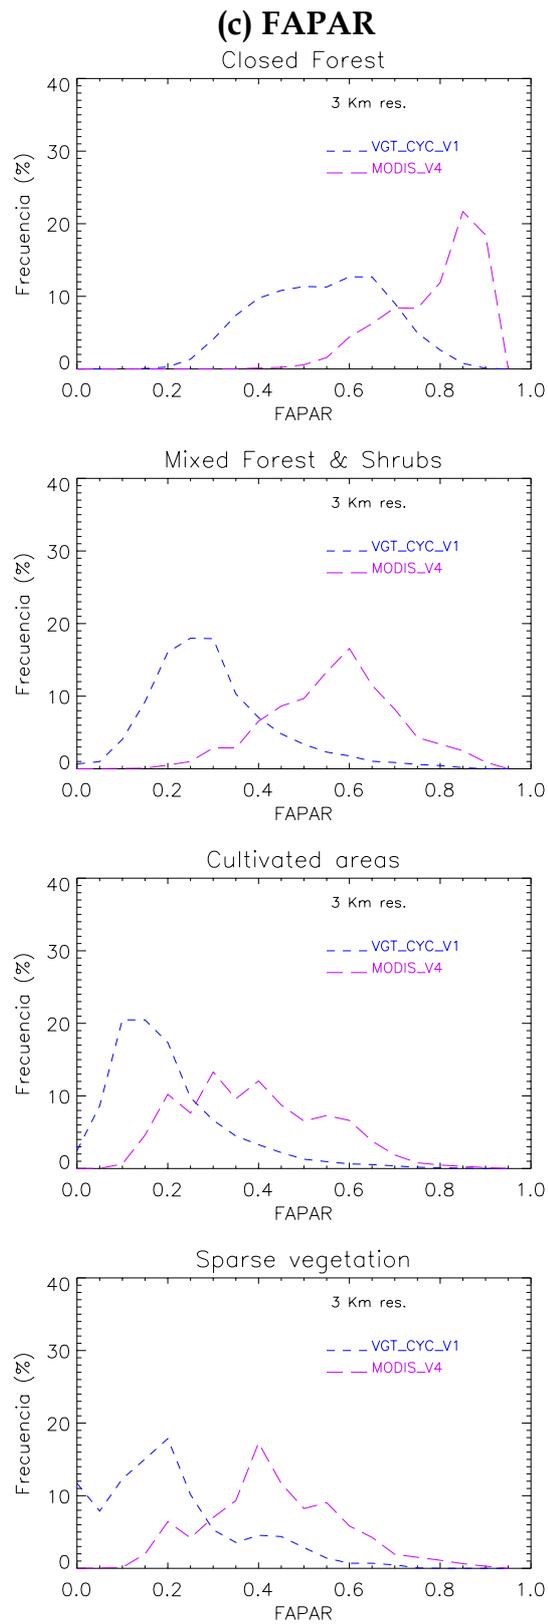


Figura V.20 (continuación). Histogramas por clases de los productos FAPAR (c).

**Tabla V.6.** Valores medios y desviación estándar de los productos a validar distinguiendo las siguientes clases, C1 (Closed Forest), C2 (Mixed Forest & Shrublands), C3 (Cultivated & Managed Areas) y C4 (Sparse Vegetation).

|                       | <b>C1</b>          | <b>C2</b>          | <b>C3</b>          | <b>C4</b>          |
|-----------------------|--------------------|--------------------|--------------------|--------------------|
| <b>LAI</b>            | Media ( $\sigma$ ) |
| <b>MSG_LandSAF_v1</b> | 2.3 (1.4)          | 0.8 (0.8)          | 0.5 (0.7)          | 0.7 (0.9)          |
| <b>VGT_LandSAF_v1</b> | 1.4 (0.7)          | 0.6 (0.4)          | 0.4 (0.3)          | 0.5 (0.4)          |
| <b>VGT_CYC_v1</b>     | 1.8 (1.0)          | 0.8 (0.7)          | 0.6 (0.6)          | 0.6 (0.8)          |
| <b>MODIS_v4</b>       | 3.2 (1.4)          | 1.3 (0.8)          | 0.7 (0.5)          | 0.9 (0.6)          |
| <b>FVC</b>            |                    |                    |                    |                    |
| <b>MSG_LandSAF_v1</b> | 0.6 (0.2)          | 0.3 (0.2)          | 0.18 (0.20)        | 0.3 (0.2)          |
| <b>VGT_LandSAF_v1</b> | 0.49 (0.17)        | 0.24 (0.14)        | 0.18 (0.12)        | 0.19 (0.15)        |
| <b>VGT_CYC_v1</b>     | 0.56 (0.17)        | 0.28 (0.18)        | 0.22 (0.17)        | 0.21 (0.19)        |
| <b>FAPAR</b>          |                    |                    |                    |                    |
| <b>VGT_CYC_v1</b>     | 0.54 (0.12)        | 0.31 (0.12)        | 0.21 (0.11)        | 0.21 (0.14)        |
| <b>MODIS_v4</b>       | 0.81 (0.10)        | 0.59 (0.13)        | 0.41 (0.15)        | 0.46 (0.14)        |

Por último y para terminar con la validación indirecta, se han calculado los coeficientes de correlación y RMSE de los diferentes productos respecto a los productos derivados de CYCLOPES versión 1. Un alto coeficiente de correlación y bajo RMSE indicará que ambos productos son comparables.

La tabla V.7 muestra el coeficiente de correlación y RMSE para los diferentes productos de los parámetros LAI, FVC y FAPAR. La tabla V.7 muestra los resultados considerando todas las clases y, posteriormente, cada una de ellas. El producto VGT\_LandSAF\_v1 es el que presenta una mayor correlación con el producto CYC\_v1 para todas las clases, con coeficientes mayores de 0.7 y 0.9 para los parámetros LAI y FVC, respectivamente. Se observa como la clases de Closed Forest y Sparse Vegetation son las que peor se correlacionan. Por una parte las diferencias en la clase Closed Forest se deben a la tendencia por parte del algoritmo CYCLOPES de proporcionar valores muy altos de LAI y la FVC en cubiertas muy densas, tal como se observó en los histogramas para este clase. En cuanto al tipo de cubierta Sparse Vegetation, las diferencias entre productos se deben a la característica que presenta el algoritmo LandSAF\_v1 de proporcionar valores bajos de FVC para cubiertas poco densas, como se puede observar de los histogramas anteriores.

Por otra parte, los productos MSG\_LandSAF\_v1 y MODIS\_v4 muestran una correlación similar y más débil para el LAI (entre 0.5 y 0.7). Sin embargo, el

producto MODIS\_v4 proporciona RMSE más altos, sobre todo para la clase Closed Forest. En el caso de la FVC, el producto MSG\_LandSAF\_v1 muestra correlaciones razonables con el producto CYC\_v1, aunque proporciona RMSE el doble que el producto VGT\_LandSAF\_v1.

Por último, en el caso de la FAPAR se observa entre los productos MODIS\_v4 y VGT\_CYC\_v1 correlaciones razonables, pero valores de RMSE entre el 20% y 30% correspondiente al rango de variación de la FAPAR (entre 0 y 1).

**Tabla V.7.** Valores medios y desviación estándar de los productos a validar distinguiendo por clases.

|              | Todas       | C1          | C2          | C3          | C4          |
|--------------|-------------|-------------|-------------|-------------|-------------|
| <b>LAI</b>   | $r$ (RMSE)  |
| VGT_LandSAF  | 0.9 (0.5)   | 0.8 (0.8)   | 0.9 (0.5)   | 0.9 (0.3)   | 0.7 (0.6)   |
| MSG_LandSAF  | 0.7 (0.8)   | 0.6 (1.3)   | 0.6(0.7)    | 0.6 (0.6)   | 0.5 (0.9)   |
| MODIS_v4     | 0.7 (0.9)   | 0.5 (1.8)   | 0.6(0.9)    | 0.6 (0.5)   | 0.6 (0.8)   |
| <b>FVC</b>   |             |             |             |             |             |
| VGT_LandSAF  | 0.96 (0.08) | 0.94 (0.09) | 0.95 (0.08) | 0.95 (0.07) | 0.90 (0.09) |
| MSG_LandSAF  | 0.83 (0.15) | 0.74 (0.17) | 0.76 (0.14) | 0.72 (0.14) | 0.61 (0.19) |
| <b>FAPAR</b> |             |             |             |             |             |
| MODIS        | 0.9 (0.3)   | 0.6 (0.3)   | 0.7 (0.3)   | 0.8 (0.2)   | 0.7 (0.3)   |

## V.2 Conclusiones

En este capítulo se ha mostrado una aplicación de los mapas de referencia derivados a partir de la metodología propuesta en este trabajo, la validación directa de productos a baja resolución. Por otra parte, se ha llevado a cabo la validación indirecta de todos los productos para toda la Península Ibérica. Respecto a la validación directa, se han derivado las siguientes conclusiones:

1. En general, podemos decir que los productos son consistentes en cuanto a la distribución espacial obtenida, distinguiéndose claramente los tres tipos de superficie (cultivos, suelos y forestal) presentes en la zona de Barrax. Sin embargo, no todos los productos comparan igualmente con la información *in-situ*.
2. En la validación directa del área de 5×5 km<sup>2</sup>, los mapas derivados con los modelos geostadísticos para el LAI muestran resultados comparables a la validación realizada con los mapas verdad-terreno derivados de la técnica por regresión multivariada.

3. Para las áreas 5×5 km<sup>2</sup> y 50×50 km<sup>2</sup>, los mejores resultados se obtienen con el algoritmo LandSAF\_v1 sobre VGT. La correlación es alta y el RMSE bajo tanto para el LAI como para la FVC. Los resultados obtenidos demuestran la credibilidad de este algoritmo con datos de baja resolución.
4. Para el área de 5×5 km<sup>2</sup>, los productos CYCLOPES\_v1 muestran correlaciones similares al producto LandSAF\_v1, pero con RMSE superiores. Para el área de 50×50 km<sup>2</sup>, los productos CYCLOPES\_v1 muestran un comportamiento desigual, el LAI presenta una alta correlación (0.9), el FAPAR una correlación aceptable (0.6) y la FVC una mala correlación (0.3) con los valores *in-situ*
5. Finalmente, el producto LAI MODIS, a pesar de ser un producto más desarrollado, presenta los peores resultados, y no tiene credibilidad suficiente para ser utilizado en esta zona de estudio. Por el contrario, el producto FAPAR MODIS es de una gran credibilidad.

Por último, respecto a la validación indirecta se han obtenido las siguientes conclusiones:

1. La alta correlación y bajo error absoluto entre los productos LAI y FVC derivados con el algoritmo de CYC\_v1 y LandSAF\_v1 sobre los mismos datos VGT ponen de manifiesto la credibilidad del algoritmo LandSAF\_v1.
2. El producto LAI y FVC derivado con MSG\_LandSAF\_v1 presenta importantes diferencias con el producto derivado de CYC\_v1, alcanzando valores de error absoluto de hasta 1.5 en el norte de la Península. Estas diferencias las atribuimos a la baja calidad del *input* MSG dado los mejores resultados del algoritmo con otros *inputs*.
3. El producto LAI MODIS\_v4 presenta el comportamiento más diferente al resto de productos, mostrando el valor medio y desviación estándar más altos. Cabe destacar también la alta proporción de datos erróneos, sobre todo en la zona norte de la Península.
4. Por último, para el parámetro FAPAR se observan correlaciones razonables entre los productos MODIS\_v4 y VGT\_CYC\_v1, pero valores de RMSE entre el 20% y 30% correspondiente al rango de variación de la FAPAR (entre 0 y 1).

**CONCLUSIONES GENERALES Y  
PERSPECTIVAS**

---

---

A lo largo de esta memoria hemos ido detallando las conclusiones que se derivan de las distintas etapas de este trabajo. No obstante, en este último capítulo recogemos en forma abreviada las principales características de la información utilizada, las conclusiones con una mayor relevancia y las principales perspectivas, permitiendo así que el lector obtenga una visión de conjunto de la investigación llevada cabo en esta tesis doctoral.

El interés por un producto biofísico cada vez más preciso implica considerar diferentes aspectos que no se llevaban a cabo tradicionalmente con el suficiente rigor científico, como por ejemplo la validación científica de los algoritmos y productos (Justice et al 2000). Ello ha motivado por parte de las principales agencias espaciales (e.g. NASA, CNES, EUMETSAT) un esfuerzo en desarrollar metodologías robustas y operacionales para la validación de productos.

La validación de productos consiste en asociar una incertidumbre al mismo que informe al usuario final sobre su precisión y exactitud. También, la de asignar al producto un alto nivel de consistencia espacial y temporal para que pueda ser utilizado en cualquier contexto, momento y con diferentes productos derivados de otros sensores independientemente de sus características espectrales y espaciales. Se trata de un proceso de evaluación que además permite mejorar los algoritmos desarrollados para derivar dichos productos.

La validación se ha entendido desde un principio como la comparación con datos de referencia, normalmente estimaciones *in-situ* del parámetro de interés. Sin embargo para productos de media y baja resolución, este procedimiento es difícil de llevar a cabo debido a que los productos se extienden a escala regional y global. Debido a este problema, la validación de productos ya no se limita actualmente a la comparación directa del producto con medidas de referencia, sino que se entiende actualmente como un conjunto de diferentes actividades entre los que destacan, (i) la validación directa a partir de medidas *in-situ*, (ii) validación indirecta a partir de la intercomparación con otros productos y (iii) el seguimiento temporal del producto.

El objetivo principal de esta tesis doctoral ha sido el desarrollar una metodología que permita la caracterización espacial a alta resolución de los parámetros biofísicos, LAI, FVC y FAPAR a partir del escalado de medidas *in-situ*, para su uso como verdad-terreno en la validación directa de productos biofísicos. Por otra parte, se ha llevado a cabo la validación indirecta de los productos de baja resolución para toda la Península Ibérica.

Dicho objetivo se ha llevado a cabo en el contexto del proyecto europeo LandSAF (*Land Surface Analysis for Satellite Application Facilities*) financiado por EUMETSAT, el cual considera la validación como una de las actividades a realizar para alcanzar sus objetivos. La tarea encomendada a la UIT en el proyecto LandSAF ha consistido en el desarrollo de los algoritmos apropiados para estimar los parámetros LAI y FVC. Actualmente entramos en la fase inicial de dos años (2005-

2007) para que los productos sean operacionales (*Initial Operational Phase, IOP*), que incluirá la aplicación de los algoritmos a datos reales y la validación de los productos.

Por otra parte, el proyecto SPARC (*SPectra bARax Campaign*) ha proporcionado un excelente marco de trabajo en el que desarrollar los objetivos de la tesis. Este proyecto surgió de un conjunto de iniciativas que contaban con la subvención de ESA, CNES, EU y EUMETSAT, cuyo objetivo principal se centraba en la validación de sensores desde alta a baja resolución espacial (CHRIS/PROBA, MERIS/ENVISAT, VEGETATION/SPOT y SEVIRI/MSG) y de los algoritmos a partir de la adquisición *in-situ* de parámetros biofísicos simultáneos al paso de satélite y de aviones con sensores aerotransportados medidas.

El proceso de validación directa se compone de las principales etapas:

1. Caracterización *in-situ* de los parámetros a validar.
2. Caracterización de dichos parámetros a alta resolución a partir de medidas *in-situ*.
3. Ecalado de los mapas a alta resolución hasta la resolución de los productos a validar.

Los principales resultados y conclusiones los expondremos según las diferentes etapas seguidas en la memoria, es decir, (i) la caracterización *in-situ* del LAI, FVC y FAPAR (**Capítulo III**), (ii) la caracterización a alta resolución de dichos parámetros (**Capítulo IV**) y (iii) la validación de diferentes productos de baja resolución (**Capítulo V**).

El primer paso de la metodología para la validación directa de productos de baja resolución espacial propuesta en esta tesis ha supuesto abordar dos aspectos críticos de la **caracterización *in-situ* en el área de estudio**. Estos aspectos se refieren, (i) al diseño de un muestreo espacial apropiado que recoja la variabilidad de los parámetros de interés presente en la zona de estudio y (ii) a la elección de los instrumentos para llevar a cabo dicha caracterización. Estos aspectos se han analizado en el **capítulo III**, de donde se derivan las siguientes conclusiones:

1. **Instrumentos utilizados para la caracterización del LAI, FVC y FAPAR:** En este trabajo hemos utilizado el LICOR LAI2000 y la cámara hemisférica digital. Se ha elegido el LICOR LAI2000 por su uso extendido en la caracterización del LAI y la cámara hemisférica por ser un método novedoso que permite estimar, el LAI, la FVC, la FAPAR y el *clumping* a partir del procesado de las fotografías hemisféricas (*Digital Hemispherical Photographs, DHPs*). En el **capítulo III** se ha dedicado especial interés en comparar las medidas derivadas de ambos instrumentos. De este modo si el error entre estimaciones es bajo será posible combinar ambos instrumentos en futuros muestreos espaciales. En relación a dicha comparación se concluye que:

- 1.1. La comparación entre las estimaciones del LAI con ambos instrumentos pone de manifiesto una buena correlación entre ambas, con un error relativo típicamente inferior al 25%, alcanzando en algunos casos (e.g. G1, A10 y SB1) discrepancias del 50%.
  - 1.2. En el caso de la FVC, los errores relativos en la estimación de la FVC son menores del 20%, con excepción de un cultivo de Alfalfa. El orden de magnitud es igual al que se comete cuando medimos una superficie utilizando dos LICORs.
  - 1.3. Los resultados obtenidos de SPARC'04 muestran que estos errores son del mismo orden de magnitud que los obtenidos al estimar el LAI en una misma ESU con diferentes instrumentos LICORs. Las discrepancias entre estimaciones realizadas con LICORs diferentes muestran un error típico entre el 10% y el 50%, dependiendo del tipo de cubierta.
  - 1.4. En el caso de las DHPs, es recomendable adquirir las fotografías en modo *upward* cuando es posible debido a, (i) una mejor discriminación del cielo y (ii) a una sobreestimación en el LAI en modo *downward* respecto a *upward*, el cual se aproxima más al valor de referencia LICOR.
  - 1.5. En general, las estimaciones obtenidas con las DHPs muestran un LAI efectivo entre el 60% y el 100% del LAI real debido al efecto de agrupamiento. Este efecto ha mostrado ser mayor en las cubiertas de Patata, Maíz y Ajo.
  - 1.6. El procesado de las fotografías requiere invertir mayor tiempo respecto al procesado llevado a cabo con el LICOR, sin embargo pueden utilizarse, posteriormente, como entrada de modelos que permiten estimar un número mayor de parámetros de la cubierta.
2. **Evaluación del programa para el procesado de las DHPs:** El procesado de las DHPs es muy dependiente del criterio que se escoja para separar espectralmente los diferentes elementos que componen la cubierta (i.e. vegetación verde, seca, suelo, píxeles mezcla, etc.). Por ello se ha incluido en el **capítulo III** un análisis de la influencia del operador en las estimaciones. La evaluación se llevó a cabo mediante el procesado del mismo conjunto de imágenes DHP adquirido durante SPARC'03 de forma independiente por los grupos INRA y UV. Las principales conclusiones son:
- 2.1. Las estimaciones de LAI y FVC muestran una alta concordancia, excepto en algunos casos donde la altura de la cubierta era muy baja y la determinación del ALA no era muy fiable.

- 2.2. En el caso de la FAPAR se observan discrepancias altas en aquellas ESUs medidas en condiciones de ángulo solar cenital alto ( $> 60^\circ$ ).
3. **Diseño del muestreo espacial:** El diseño requiere decidir una serie de aspectos importantes para obtener un conjunto de medidas que caractericen correctamente la variabilidad de la zona, como las zonas de estudio, las dimensiones de las unidades elementales de medida (ESU), su localización y número. A continuación se describen las principales características del muestreo realizado con cada instrumento derivadas de este estudio:
  - 3.1. Las dimensiones de la ESU correspondían a un área de  $20 \times 20 \text{ m}^2$ , coincidiendo con el área de un píxel de la imagen de alta resolución utilizada.
  - 3.2. El muestreo a nivel de ESU, fue diferente para cada instrumento. En el caso del LICOR LAI2000, se caracterizó a partir de 24 medidas, 3 sobre la cubierta por 8 debajo de la cubierta, distribuidas de forma aleatoria en la superficie de la ESU. En el caso de la cámara hemisférica, se realizaron 12 DHPs con un esquema *pseudo-regular*, excepto en el caso de cultivos distribuidos por filas muy separadas donde se realizó un muestreo en diagonal.
  - 3.3. Las discrepancias encontradas (menores del 20%) entre las estimaciones del LICOR y la cámara hemisférica incluyen el error debido a las diferencias en el muestreo espacial realizado con cada instrumento.
  - 3.4. El criterio para distribuir las ESUs en el área de estudio y caracterizar la heterogeneidad existente en los diferentes cultivos consistió en obtener un mínimo de 12 ESUs por cultivo con el objetivo de proporcionar valores de la media y desviación estándar estadísticamente fiables. En el caso del LICOR LAI2000 el número de ESUs fue de 100 ESUs correspondientes a 6 cultivos, mientras que con la cámara hemisférica el número de ESUs fue inferior (53), pero mayor el de cultivos muestreados (9).

El segundo paso consiste en evaluar los métodos propuestos para **caracterizar a alta resolución los parámetros biofísicos**, es decir estimar mapas de alta resolución a partir de las medidas *in-situ*. Este proceso resulta complicado debido a la heterogeneidad del área de estudio y se resuelve desde varias perspectivas. En nuestro caso se han propuesto dos técnicas para abordarlo, las cuales se han evaluado en el **capítulo IV**, (i) la técnica de regresión por mínimos cuadrados (OLS) multivariada y (ii) las técnicas geoestadísticas.

El análisis ha incluido la evaluación de ambos métodos para la estimación de los parámetros biofísicos a alta resolución, la comparación entre ellos y la influencia del muestreo espacial en las estimaciones.

4. **Método iterativo de regresión multivariada por mínimos cuadrados multivariada:** El método propuesto, a diferencia de la regresión por mínimos cuadrados simple (OLS), ha permitido, (i) localizar aquellas ESUs con un comportamiento diferente al que se podría esperar, (ii) asociar un factor de ajuste a esas ESUs para que su influencia en las estimaciones sea mínima y (iii) proporcionar estimaciones con un error cuadrático medio menor. En este estudio se ha evaluado cuatro errores, (i) el error cometido por la FT, (ii) el error debido a la elección de la FT, (iii) el error debido al muestreo espacial y (iv) el error asociado a los píxeles no interpolados por la FT. Además, se ha demostrado la utilidad del método *convex hull* para derivar una imagen de calidad (QF) asociada a las estimaciones y evaluar el error asociado a los píxeles no interpolados por la FT.

La técnica de regresión multivariada relaciona las medidas *in-situ* con los valores radiométricos de la imagen a alta resolución seleccionada a partir de relaciones lineales empíricas. Las bandas utilizadas pertenecen al R, G, NIR y MIR, así como también al índice de vegetación NDVI. La estimación de los parámetros LAI, FVC y FAPAR se ha llevado a cabo sobre dos áreas con dimensiones diferentes, (i) la zona donde se han concentrado las medidas *in-situ* (e.g. 5×5 km<sup>2</sup>) y (ii) otra mayor (e.g. 50×50 km<sup>2</sup>) que también será utilizada para realizar la validación directa de productos derivados a baja resolución. A continuación se detallan las principales conclusiones:

- 4.1. El método iterativo de regresión multivariada se ha mostrado como un estimador realista del LAI, FVC y FAPAR con errores de validación cruzada aceptables, 0.7, 0.19 y 0.18, respectivamente.
- 4.2. La elección de la FT introduce un error en el LAI, FVC y FAPAR menor de 0.20, 7% y 3%, respectivamente, para aquellas funciones que incluyen las bandas del NIR o R.
- 4.3. El método de *convex hull* se ha mostrado adecuado para evaluar la influencia del muestreo en las estimaciones.
- 4.4. ESUs localizadas fuera de la región definida por el *convex hull* muestran errores de extrapolación del orden de 0.9. El modelo de regresión muestra ser poco sensible cuando no se consideran ESUs localizadas dentro del *convex hull* con RMSE bajos (0.3).
- 4.5. El error asociado al muestreo se ha evaluado a partir de la comparación entre los mapas estimados de LAI y FVC con ambos instrumentos y muestreos. Se obtiene en general un error aceptable dentro del rango de variación del LAI y de la FVC, menor del 0.3 y del 4%, respectivamente.

- 4.6. La alta consistencia entre los mapas derivados con muestreos diferentes para el LAI y LICOR, pone de manifiesto la validez de ambos instrumentos y muestreos para estimar el LAI y la FVC. Se concluye que el número de ESUs adquiridas con la cámara hemisférica (aprox. 50) es adecuado para caracterizar la variabilidad de la zona de estudio.
5. **Técnicas geoestadísticas:** Estas técnicas se han evaluado sólo en la estimación del LAI. Al igual que con la técnica de regresión multivariada se han obtenido los errores debidos al muestreo y al método a partir de la comparación con medidas *in-situ*. El método por krigado consiste en un estimador lineal que considera información sobre la correlación espacial de las variables y proporciona la estimación de una posición a partir de la combinación lineal de diferentes observaciones (e.g. medidas *in-situ*) incluidas dentro de un radio de influencia. Las técnicas geoestadísticas evaluadas en esta tesis corresponden a tres variantes del krigado, el krigado ordinario (KO), krigado con deriva externa (KDE) y cokrigado colocalizado (CKC). Se han escogido estos tres modelos por los siguientes motivos:
- 5.1. **El Krigado Ordinario (KO):** Es el más sencillo de los tres y no necesita información secundaria, supone un modelo de tendencia constante y no conocido en un cierto radio de vecindad.
- 5.2. **El Krigado con Deriva Externa (KDE):** Asume un modelo de tendencia no estacionario, idóneo para nuestra área de interés, y proporciona información más detallada de la variable a escalas más finas.
- 5.3. **El Cokrigado Colocalizado (CKC):** Permite incluir en las estimaciones información secundaria derivada de teledetección con un muestreo denso.

Aunque los métodos geoestadísticos implican un mayor esfuerzo computacional y una mayor intervención del usuario, se han elegido debido a que presentan la ventaja de considerar la dependencia espacial entre las observaciones de la variable medida y permiten introducir información adicional en las estimaciones. Una de las aportaciones que se ha valorado de este método es la posibilidad de estimar mapas a alta resolución sin necesidad de información auxiliar derivada de teledetección.

Las principales conclusiones derivadas a partir de la evaluación de estas técnicas son:

- 5.4. El modelo KDE muestra una alta consistencia para la estimación del LAI, dada la alta correlación (0.9) y RMSE razonable (0.8) respecto a las medidas *in-situ* LAI<sub>DHP</sub>.
- 5.5. La obtención del mismo error para la FT, indica que el estimador por KDE es comparable al de regresión multivariada. El estimador por KDE

proporciona valores de *bias* prácticamente nulos respecto a la FT para niveles de cobertura bajo e intermedio.

- 5.6. El modelo KO es el que peor se ajusta a las medidas *in-situ* (pendiente=0.7, RMSE=1.3) y a las estimaciones de la FT.

Estos resultados corresponden a las estimaciones obtenidas a partir del conjunto de datos *in-situ* suponiendo que dichos muestreos espaciales eran los adecuados para aplicar los modelos geostadísticos. Sin embargo y dado que los mapas estimados se han utilizado para la validación de productos de baja resolución, hemos planteado la cuestión de cuál será la configuración más eficaz (i.e. muestreo y modelo) en función de la resolución espacial que proporcione estimaciones más fiables y que, a su vez, minimice esfuerzos como por ejemplo, el realizar menor número de medidas en el campo o no depender de información secundaria. Las conclusiones derivadas de este estudio se presentan a continuación.

6. **Evaluación de la configuración muestreo y modelo:** Este análisis se ha llevado a cabo en el **capítulo IV** (Sección IV.3) a partir de cuatro muestreos diseñados, dos sistemáticos y dos estratificados. Para ello se han aplicado las técnicas de estimación propuestas (i.e. FT, KO, CKC y KDE) con los cuatro muestreos espaciales diseñados a partir de los valores de LAI extraídos del mapa LAI<sub>LICOR</sub> derivado con la FT. Las características de los muestreos elegidos son:

- 6.1. **Muestreos sistemáticos, SP1 y SP2:** Definen una malla regular la cual permite muestrear uniformemente toda la población de la zona de estudio. Se han elegido dos distancias de separación (200 y 500 m, respectivamente) menores que el parámetro de alcance definido por el variograma del NDVI.
- 6.2. **Muestreos estratificados, SP3 y SP4:** La estratificación considerada se ha realizado según el tipo de cubierta y su variabilidad espacial. En nuestro caso, se ha utilizado la imagen de NDVI e información de campo recogida durante la campaña de campo. Los muestreos se han elegido en base a dos consideraciones derivadas de los apartados anteriores, (i) alrededor de 50 ESUs son suficientes para derivar la función de transferencia y (ii) dichas ESUs deben extenderse en toda el área cuando se utilizan los modelos geostadísticos.

En el caso de las técnicas geoestadísticas, se ha evaluado la influencia de la variable secundaria y la configuración óptima para la que se minimiza su influencia. Estas técnicas se han evaluado respecto a las estimaciones obtenidas con la FT. Las principales conclusiones derivadas de este estudio son:

- 6.3. Para la técnica multivariada, los muestreos sistemáticos (i.e. SP1 y SP2) son los que presentan mayor porcentaje de píxeles interpolados (e.g. 98% y 92%), pero, también, son más difíciles de llevar a la práctica debido al elevado número de ESUs y a las limitaciones de acceso en el campo.
- 6.4. Para la técnica multivariada, el muestreo SP3 proporciona una mayor cantidad de píxeles interpolados (82%) que el muestreo SP4 y además resulta más fácilmente trasladable a nuestra área de estudio.
- 6.5. Para las técnica geoestadísticas, el muestreo SP1 es el que mejor reproduce las estimaciones de la FT para los tres modelos a alta resolución. Proporciona coeficientes de correlación altos ( $r > 0.85$ ) y RMSE menores que 0.9 para los tres modelos, además de poca contribución de la variable secundaria.
- 6.6. Para las técnica geoestadísticas, el muestreo SP4 proporciona resultados comparables al muestreo SP1 para los modelos CKC y KDE a alta resolución, con coeficientes de correlación altos ( $r > 0.9$ ) y RMSE bajos ( $< 0.65$ ).
7. **Evaluación de la configuración óptima en función de la resolución espacial:** Las resoluciones escogidas para el estudio corresponden a alta (20 m), media (300 m) y baja (1000 m).
  - 7.1. El modelo KDE es el que ha proporcionado resultados similares a la FT para todas las resoluciones y muestreos (RMSE  $< 0.3$  y  $r > 0.95$ ). Si se dispone de información secundaria el muestreo SP4 ha mostrado ser adecuado para estimar mapas a diferentes resoluciones espaciales minimizando los esfuerzos en el campo.
  - 7.2. Si no se dispone de información secundaria, el modelo KO y el muestreo SP4 proporcionan resultados comparables al muestreo intensivo SP1 para resoluciones espaciales media y baja. Este resultado es de gran relevancia dado que permitiría con un muestreo inferior a 50 ESUs y sin necesidad de información secundaria obtener un mapa de LAI para validar productos a la resolución espacial de 1000 m.

Por último, **el capítulo V** ha incluido la validación de diferentes productos pre- y operacionales de baja resolución sobre el área agrícola de Barrax y la Península Ibérica. Con este capítulo se ha querido mostrar la aplicación de los mapas *in-situ* derivados a partir de la metodología propuesta en este trabajo. Los productos utilizados corresponden a productos actualmente en uso o en fase pre-operacional como los derivados en MODLAND (e.g. LAI y FAPAR derivados con datos MODIS/TERRA), en el proyecto CYCLOPES (e.g. LAI, FVC y FAPAR derivados

con datos VEGETATION/SPOT) o en el proyecto LandSAF (e.g. LAI y FVC derivados con datos SEVIRI/MSG).

Los objetivos de este capítulo han sido, (i) Validar diferentes productos de vegetación y especialmente el algoritmo desarrollado en LandSAF para la estimación del LAI y FVC, y (ii) Demostrar una aplicación de la metodología propuesta para caracterizar a alta resolución los parámetros de la vegetación LAI, FVC y FAPAR. A continuación se describen las conclusiones más relevantes de este capítulo distinguiendo según las dos actividades de validación que hemos propuesto.

8. **Validación directa de productos de baja resolución espacial:** En el capítulo V se ha mostrado una aplicación de los mapas de referencia derivados a partir de la metodología propuesta en este trabajo: la validación directa de productos a baja resolución. Por una parte, esta tarea ha permitido evaluar la exactitud del producto a partir de la comparación directa entre las estimaciones derivadas mediante satélite y los mapas verdad-terreno derivados a partir de la metodología desarrollada en esta memoria. Las principales conclusiones obtenidas son:

- 8.1. En general, los productos se han mostrado consistentes en cuanto a la distribución espacial obtenida, distinguiéndose claramente los tres tipos de superficie (cultivos, suelos y forestal) presentes en la zona de Barrax. Sin embargo, no todos los productos se han comparado igualmente con la información *in-situ*.
- 8.2. La validación en el área 5×5 km<sup>2</sup> con los mapas derivados a partir de los modelos geostadísticos para el LAI ha proporcionado resultados comparables a los mapas verdad-terreno obtenidos con la técnica por regresión multivariada.
- 8.3. Para las áreas 5×5 km<sup>2</sup> y 50×50 km<sup>2</sup>, los mejores resultados se han obtenido con el algoritmo LandSAF\_v1 sobre datos VEGETATION. La correlación es alta y el RMSE bajo tanto para el LAI como para la FVC. Los resultados obtenidos han demostrado la credibilidad de este algoritmo con datos de baja resolución.
- 8.4. Los productos CYCLOPES\_v1 muestran correlaciones similares al producto LandSAF\_v1 para el área 5×5 km<sup>2</sup>, pero con RMSE superiores. Para el área de 50×50 km<sup>2</sup>, estos productos han presentado un comportamiento desigual, el LAI presenta una alta correlación (0.9), el FAPAR una correlación aceptable (0.6) y la FVC una mala correlación (0.3) con los valores *in-situ*

- 8.5. El producto LAI MODIS ha mostrado los peores resultados y no tiene credibilidad suficiente para ser utilizado en esta zona de estudio. Por el contrario, el producto FAPAR MODIS es de una gran credibilidad.
9. **Validación indirecta de productos de baja resolución espacial:** Por otra parte, se ha llevado a cabo la validación indirecta de todos los productos para toda la Península Ibérica. La validación indirecta ha proporcionado información sobre el rango de variabilidad de cada producto, su precisión, posibles problemas o mala caracterización en determinadas cubiertas. A continuación se detallan las principales conclusiones:
- 9.1. La alta correlación y bajo error absoluto entre los productos LAI y FVC derivados con el algoritmo de CYC\_v1 y LandSAF\_v1 sobre los mismos datos VGT pone de manifiesto la credibilidad del algoritmo LandSAF\_v1. La correlación entre ambos productos ha sido mayor de 0.8 en todas las clases, con un RMSE máximo de 0.8 en la clase de Closed Forest.
- 9.2. El producto LAI y FVC derivado con MSG\_LandSAF\_v1 presenta importantes diferencias con el producto derivado de CYC\_v1, alcanzando valores de error absoluto de hasta 1.5 en el norte de la Península. Estas diferencias las atribuimos a la baja calidad del *input* MSG dado los mejores resultados del algoritmo con otros *inputs*.
- 9.3. El producto LAI MODIS\_v4 presenta el comportamiento más diferente al resto de productos, mostrando el valor medio y desviación estándar más altos. Cabe destacar también la alta proporción de datos erróneos, sobre todo en la zona norte de la Península.
- 9.4. Por último, para el parámetro FAPAR se observan correlaciones razonables entre los productos MODIS\_v4 y VGT\_CYC\_v1, pero valores de RMSE entre el 20% y 30% correspondiente al rango de variación de la FAPAR (entre 0 y 1).
10. **Perspectivas:** Dado nuestro interés actual por la validación de productos derivados del sensor SEVIRI/MSG en los próximos dos años, es importante para nosotros seguir desarrollando y mejorando aspectos de esta metodología que permitan proporcionar un producto a la comunidad de usuarios fiable y de calidad para su uso en diferentes aplicaciones. En este contexto, las principales perspectivas que se derivan de este trabajo son:
- 10.1. Dada la gran extensión espacial que presentan los productos de baja resolución, sería necesario incluir en la validación otras zonas de estudio que representaran diferentes tipos de cubiertas. Dada la dificultad para realizar experimentos de campo en todas ellas, una opción es utilizar información verdad-terreno derivada de bases de datos disponibles a partir de otros grupos de validación como MODLAND o VALERI.

- 10.2. Referente a la caracterización *in-situ*, ya se están llevando a cabo conclusiones derivadas de este capítulo en experimentos de campo recientes como SEN2FLEX (The SENTinel-2 and FLuorescence EXperiment). Durante esta campaña se ha ensayado el muestreo SP3 para estimar mapas de alta resolución a partir del método de regresión multivariada y se ha dedicado especial atención en medir las mismas ESUs con ambos instrumentos para realizar la intercomparación entre estimaciones.
- 10.3. Respecto a la FT una cuestión importante es su representatividad temporal y espacial. De este modo y aprovechando los tres experimentos de campo que han tenido lugar en Barrax desde el 2003, de donde se dispone de medidas *in-situ* y de imágenes de alta resolución, nos planteamos estudiar la variabilidad de la FT en diferentes fechas y áreas de estudio.
- 10.4. Respecto a las técnicas geoestadísticas una conclusión relevante en la validación de productos de baja resolución ha sido la utilidad del método de KO para la estimación de mapas verdad-terreno. De este modo, un estudio que nos planteamos es el de analizar con mayor profundidad las ventajas de la técnica de KO utilizando datos *in-situ* derivados de las diferentes bases de datos disponibles por los proyectos de validación.
- 10.5. Otra cuestión de gran relevancia en la metodología de validación directa es la de asociar un mapa de error a los productos verdad-terreno estimados. Este es un tema importante y que nos planteamos en un futuro a partir de una exhaustiva investigación de los métodos actuales. Varias técnicas que se proponen actualmente para evaluar la incertidumbre en cada estimación consisten en modelar la función de distribución de probabilidad o en métodos de simulación.
- 10.6. Por último y debido al interés por validar productos de media y baja resolución, nos planteamos en un futuro evaluar diferentes técnicas para el degradado de los mapas verdad-terreno a resoluciones más bajas. Este estudio permitirá analizar la capacidad de cada técnica para mantener la información espacial del mapa verdad-terreno a resoluciones más bajas.

---



---

**ANEXO A**


---



---



---



---

**ESTIMACIÓN DE LA GAP FRACTION**


---



---

El índice de superficie foliar se obtiene a partir de la integración de la densidad de superficie foliar en la cubierta. El LAI a la altura  $H$  de la cubierta se relaciona a partir de la siguiente relación:

$$LAI = \int_0^H l(h) dh \quad [A.1]$$

donde  $l(h)$  es la densidad de superficie foliar. Según Warren-Wilson (1959), el número medio de contactos entre un rayo de luz que penetra dentro de la cubierta y elementos de la vegetación verde  $N(H, \theta_v, \varphi_v)$  se puede escribir para una cubierta de altura  $H$  y dirección  $(\theta_v, \varphi_v)$  como:

$$N(H, \theta_v, \varphi_v) = \int_0^H \frac{G(h, \theta_v, \varphi_v) l(h)}{\cos \theta_v} dh \quad [A.2]$$

donde  $G(h, \theta_v, \varphi_v)$  es la función de proyección, es decir la proyección media de una unidad de superficie foliar en la dirección  $(\theta_v, \varphi_v)$  y a una altura  $h$ . Cuando la densidad de superficie foliar y la función de proyección se consideran independientes de la altura de la cubierta, la ecuación A.2 se simplifica de la siguiente forma:

$$N(L, \theta_v, \varphi_v) = \frac{G(\theta_v, \varphi_v) LAI}{\cos \theta_v} \quad [A.3]$$

Cuando las hojas se consideran infinitamente pequeñas y distribuidas espacialmente de forma aleatoria, la *gap fraction* se relaciona con la frecuencia de contacto a partir del modelo de Poisson (Welles 1990):

$$P_0(\theta_v, \varphi_v) = e^{-N(\theta_v, \varphi_v)} = e^{\frac{-G(\theta_v, \varphi_v)LAI}{\cos \theta_v}} \quad [\text{A.4}]$$

Cabe destacar, la relación lineal entre la frecuencia de contacto y el LAI mientras que la *gap fraction* presenta una relación exponencial. Aunque la frecuencia de contacto es una magnitud adecuada para estimar indirectamente el LAI dado que no se requiere ninguna suposición previa sobre la distribución espacial de las hojas, forma o tamaño, dicha magnitud es muy difícil de medir en la cubierta, por tanto se suele preferir la medida del *gap fraction* aunque haya que hacer varias suposiciones en cuanto a la distribución espacial de las hojas.

Por otra parte, la función de proyección se define como:

$$G(\theta_v, \varphi_v) = \frac{1}{2\pi} \int_0^{2\pi} \int_0^{2\pi} |\cos \psi| g(\theta_1, \varphi_1) \times \sin \theta_1 d\theta_1 d\varphi_1 \quad [\text{A.5}]$$

$$\cos \psi = \cos \theta_v \cos \theta_1 + \sin \theta_v \sin \theta_1 \cos(\varphi_v - \varphi_1) \quad \text{A.6]}$$

donde  $g(\theta_1, \varphi_1)$  es la función de probabilidad que describe la densidad de probabilidad de la normal a la superficie foliar. Normalmente, el LAD se suele considerar acimutalmente simétrico, lo que conlleva a que la función de probabilidad  $g(\theta_1, \varphi_1)$  sólo dependa del ángulo cenital. Esta suposición se ha comprobado en una gran número de cubiertas pero presenta problemas en las plantas heliotrópicas como son los girasoles (Andrieu & Sinoquet 1993). Según los resultados de Goel (1988), la función de probabilidad y la función de proyección toman los valores mostrados en la tabla A.1 para las orientaciones foliares más comunes.

| Tipo de Cubierta      | ALA (°) | $g(\theta_1)$             | $G(\theta_1)$           |
|-----------------------|---------|---------------------------|-------------------------|
| Planófila(horizontal) | 26.8    | $2(1+\cos 2\theta_1)/\pi$ | $\cos \theta_1$         |
| Erectófila (Vertical) | 63.2    | $2(1-\cos 2\theta_1)/\pi$ | $(2/\pi) \sin \theta_1$ |
| Esférica (Uniforme)   | 57.3    | $\sin \theta_1$           | $1/2$                   |

---



---

**ANEXO B**


---



---



---



---

**EJEMPLO KRIGEADO**


---



---

**B.1. Condición de estimador insesgado**

La condición de estimador insesgado da lugar a que la suma de los pesos que intervienen en la ecuación anterior sea igual a 1. A continuación se describe cómo se llega a dicha consecuencia.

Partiendo de la condición de estimador insesgado:

$$m_R = E\{R(\mathbf{u})\} = E\{Z^*(\mathbf{u}) - Z(\mathbf{u})\} = 0 \quad \text{[B.1]}$$

y reemplazando esta expresión en la ecuación del error,  $R(\mathbf{u}) = Z^*(\mathbf{u}) - Z(\mathbf{u})$ , se tiene:

$$R(\mathbf{u}) = \sum_{\alpha=1}^n \lambda_{\alpha} Z(\mathbf{u}_{\alpha}) - Z(\mathbf{u}) \quad \text{[B.2]}$$

El valor esperado del error se puede escribir como:

$$E\{r(\mathbf{u})\} = E\left\{\sum_{\alpha=1}^n \lambda_{\alpha} Z(\mathbf{u}_{\alpha}) - Z(\mathbf{u})\right\} = \sum_{\alpha=1}^n \lambda_{\alpha} E\{Z(\mathbf{u}_{\alpha}) - E\{Z(\mathbf{u})\}\} \quad \text{[B.3]}$$

Si se asume que la función aleatoria es estacionaria, el valor esperado del error se expresa como:

$$E\{R(\mathbf{u})\} = \sum_{\alpha=1}^n \lambda_{\alpha} E\{Z\} - E\{Z\} \quad \text{[B.4]}$$

de donde se deduce que para que  $E\{R(\mathbf{u})\} = 0$ , se debe verificar que:

$$\sum_{\alpha=1}^n \lambda_{\alpha} = 1 \quad [\text{B.5}]$$

## B.2. Minimización de la varianza del error

La condición de varianza mínima supone encontrar una expresión para  $\sigma_R^2$ , así como su valor mínimo.

De forma general, la varianza de una combinación lineal de variables aleatorias se expresa como:

$$\text{Var}\left\{\sum_{\alpha=1}^n \lambda_{\alpha} Z(\mathbf{u}_{\alpha})\right\} = \sum_{\alpha=1}^n \sum_{\beta=1}^n \lambda_{\alpha} \lambda_{\beta} C\{Z(\mathbf{u}_{\alpha})Z(\mathbf{u}_{\beta})\} \quad [\text{B.6}]$$

donde  $C\{Z(\mathbf{u}_{\alpha})Z(\mathbf{u}_{\beta})\}$  es la covarianza entre las variables aleatorias para las localizaciones  $\mathbf{u}_{\alpha}$  y  $\mathbf{u}_{\beta}$ .

La varianza del error cometido en un conjunto de estimaciones es una combinación lineal de dos variables aleatorias, por lo que:

$$\begin{aligned} \text{Var}\{R(\mathbf{u})\} &= C\{Z^*(\mathbf{u})Z^*(\mathbf{u})\} - C\{Z^*(\mathbf{u})Z(\mathbf{u})\} - C\{Z(\mathbf{u})Z^*(\mathbf{u})\} + C\{Z(\mathbf{u})Z(\mathbf{u})\} \\ &= C\{Z^*(\mathbf{u})Z^*(\mathbf{u})\} - 2C\{Z^*(\mathbf{u})Z(\mathbf{u})\} + C\{Z(\mathbf{u})Z(\mathbf{u})\} \end{aligned} \quad [\text{B.7}]$$

donde el primer termino corresponde a la autocovarianza de  $Z^*(\mathbf{u})$ , el tercer termino a la autocovarianza de la variable aleatoria  $Z(\mathbf{u})$ , la cual es igual a  $\sigma^2$ . Reemplazando la ecuación B.1 en la ecuación B.7, tenemos que la varianza del error se puede expresar como:

$$\sigma_R^2 = \sigma^2 + \sum_{\alpha=1}^n \sum_{\beta=1}^n \lambda_{\alpha} \lambda_{\beta} C(\mathbf{u}_{\alpha} - \mathbf{u}_{\beta}) - 2 \sum_{\alpha=1}^n \lambda_{\alpha} C(\mathbf{u}_{\alpha} - \mathbf{u}) + 2\mu \left( \sum_{\alpha=1}^n \lambda_{\alpha} - 1 \right) \quad [\text{B.8}]$$

donde  $\mu$  es el parámetro de Lagrange. El último término de Lagrange se añadió para incluir la condición de estimador insesgado. Dicho término no altera la expresión para la varianza del error ya que es igual a cero.

## B.5. Influencia del parámetro meseta

Los pesos no se ven afectados por el cambio de la meseta pero si la variancia la cual aumenta cuando la meseta también aumenta.

## B.6. Influencia del parámetro pepita

Una sobrestimación del efecto pepita da lugar a que la correlación entre puntos sea menor y que los pesos asociados a cada posición sean similares y la variancia estimada sea alta. Por otra parte, una subestimación del efecto pepita da lugar a que la correlación entre puntos sea mayor y que los pesos asociados a sean mayores y la variancia estimada menor.

### **B.7. Influencia del parámetro alcance**

Los pesos se ven afectados de forma más suave por el cambio del alcance. Cuando el alcance es pequeño existen algunos puntos que presenten una correlación muy baja. La Variancia aumenta cuando el alcance es pequeño y disminuye cuando esta variable aumenta.

### **B.8. Influencia del efecto de la forma**

Si que cambia, en el caso particular del cambio de una función exponencial a gaussiana afecta en que los pesos cercanos a la posición donde se desea estimar presentan valores más altos.

### **B.9. Influencia de la anisotropía**

El efecto de la anisotropía se refleja en el cambio del alcance según la dirección. Se obtienen pesos más altos en la dirección del alcance máximo.



## ANEXO C

### VARIANTES COKRIGEADO

#### C.1 Cokrigado simple (CKS)

Si disponemos de datos de una variable principal  $z_1$  y de una variable secundaria  $z_2$ , el estimador por cokrigado simple de la variable principal viene dado por la siguiente expresión:

$$z_{\text{CKS}}^*(\mathbf{u}) - m_1 = \sum_{\alpha_1=1}^{n_1} \lambda_{\alpha_1} [z_2(\mathbf{u}_{\alpha_1}) - m_2] + \sum_{\alpha_2=2}^{n_2} \lambda_{\alpha_2} [z_2(\mathbf{u}_{\alpha_2}) - m_2] \quad [\text{C.1}]$$

donde  $z_1$  es la variable principal;  $z_2$  es la variable secundaria;  $m_1$  y  $m_2$  son sus medias;  $n_1$ , es el número de datos primarios y  $n_2$  es el número de datos secundarios. Los pesos  $\lambda_\alpha$  se obtienen resolviendo el siguiente sistema de ecuaciones lineales o sistema de cokrigado simple:

$$\begin{cases} \sum_{\beta_1=1}^{n_1} \lambda_{\beta_1} C_1(\mathbf{u}_{\alpha_1} - \mathbf{u}_{\beta_1}) + \sum_{\beta_2=1}^{n_2} \lambda_{\beta_2} C_{12}(\mathbf{u}_{\alpha_1} - \mathbf{u}_{\beta_2}) + \mu_1 = C_1(\mathbf{u}_{\alpha_1} - \mathbf{u}_0), & \alpha_1 = 1, \dots, n_1 \\ \sum_{\beta_1=1}^{n_1} \lambda_{\beta_1} C_{12}(\mathbf{u}_{\alpha_1} - \mathbf{u}_{\beta_1}) + \sum_{\beta_2=1}^{n_2} \lambda_{\beta_2} C_2(\mathbf{u}_{\alpha_1} - \mathbf{u}_{\beta_2}) + \mu_2 = C_{12}(\mathbf{u}_{\alpha_1} - \mathbf{u}_0), & \alpha_2 = 1, \dots, n_2 \end{cases} \quad [\text{C.2}]$$

Donde interviene tanto la covarianza de la variable primaria  $C_1(\mathbf{u}_{\alpha_1} - \mathbf{u}_{\beta_1})$  como la de la secundaria  $C_2(\mathbf{u}_{\alpha_2} - \mathbf{u}_{\beta_2})$  y la covarianza cruzada  $C_{12}(\mathbf{u}_{\alpha_1} - \mathbf{u}_{\beta_2})$ . Como en el krigado simple, el algoritmo de cokrigado simple requiere conocer las medias de las variables consideradas. La expresión para la varianza de los errores por cokrigado simple es la siguiente:

$$\sigma_{\text{CKS}}^2(\mathbf{u}_0) = \sigma_1^2 - \sum_{\alpha_1=1}^{n_1} \lambda_{\alpha_1} C_1(\mathbf{u}_{\alpha_1} - \mathbf{u}_0) - \sum_{\alpha_2=1}^{n_2} \lambda_{\alpha_2} C_{12}(\mathbf{u}_{\alpha_2} - \mathbf{u}_0) \quad [\text{C.3}]$$

## C.2 Cokrigado Ordinario (CKO)

El estimador por cokrigado ordinario considera las variaciones locales en la media limitando la condición de estacionalidad a un área menor,  $W(\mathbf{u})$ , que el área de estudio. El estimador por cokrigado ordinario presenta la forma siguiente:

$$z_{\text{CKO}}^*(\mathbf{u}) = \sum_{\alpha_1=1}^{n_1} \lambda_{\alpha_1}(\mathbf{u}) z_1(\mathbf{u}_{\alpha_1}) + \sum_{\alpha_2=1}^{n_2} \lambda_{\alpha_2}(\mathbf{u}) z_2(\mathbf{u}_{\alpha_2}) \quad [\text{C.4}]$$

y los coeficientes de ponderación resultan de la solución del sistema de cokrigado ordinario:

$$\left\{ \begin{array}{l} \sum_{\beta_1=1}^{n_1} \lambda_{\beta_1} C_1(\mathbf{u}_{\alpha_1} - \mathbf{u}_{\beta_1}) + \sum_{\beta_2=1}^{n_2} \lambda_{\beta_2} C_{12}(\mathbf{u}_{\alpha_1} - \mathbf{u}_{\beta_2}) + \mu_1 = C_1(\mathbf{u}_{\alpha_1} - \mathbf{u}_0), \quad \alpha_1 = 1, \dots, n_1 \\ \sum_{\beta_1=1}^{n_1} \lambda_{\beta_1} C_{12}(\mathbf{u}_{\alpha_1} - \mathbf{u}_{\beta_1}) + \sum_{\beta_2=1}^{n_2} \lambda_{\beta_2} C_2(\mathbf{u}_{\alpha_1} - \mathbf{u}_{\beta_2}) + \mu_2 = C_{12}(\mathbf{u}_{\alpha_1} - \mathbf{u}_0), \quad \alpha_2 = 1, \dots, n_2 \\ \sum_{\beta_1=1}^{n_1} \lambda_{\beta_1} = 1 \\ \sum_{\beta_2=1}^{n_2} \lambda_{\beta_2} = 0 \end{array} \right. \quad [\text{C.5}]$$

donde las dos últimas restricciones son suficientes, aunque no necesarias, para garantizar una estimación insesgada, y  $\mu_1$  y  $\mu_2$  son los parámetros de Lagrange introducidos en la minimización. La expresión para la varianza de los errores por cokrigado ordinario es la siguiente:

$$\sigma_{\text{CKO}}^2(\mathbf{u}_0) = \sigma_1^2 - \mu_1 - \sum_{\alpha_1=1}^{n_1} \lambda_{\alpha_1} C_1(\mathbf{u}_{\alpha_1} - \mathbf{u}_0) - \sum_{\alpha_2=1}^{n_2} \lambda_{\alpha_2} C_{12}(\mathbf{u}_{\alpha_2} - \mathbf{u}_0) \quad [\text{C.6}]$$

## C.3 Cokrigado Colocalizado Ordinario (CKC)

El estimador por cokrigado ordinario considerando sólo una variable secundaria es:

$$z_{\text{CKC}}^*(\mathbf{u}) = \sum_{\alpha=1}^{n_1} \lambda_{\alpha} z_1(\mathbf{u}_{\alpha}) + \lambda_2 [z_2(\mathbf{u}) - m_2 + m_1] \quad [\text{C.7}]$$

En esta variante, las condiciones impuestas a los coeficientes de ponderación en la expresión C.5 no se pueden aplicar porque darían lugar a que el peso colocalizado de la variable secundaria fuera cero. En este caso, estas condiciones se cambian por la condición:

$$\sum_{\alpha_1=1}^{n_1} \lambda_{\alpha_1} + \lambda_{\alpha_2} = 1 \quad [\text{C.8}]$$

El sistema de  $n_1(\mathbf{u})+2$  ecuaciones para el cokrigado colocalizado cuya solución nos da los coeficientes de ponderación es:

$$\left\{ \begin{array}{l} \sum_{\beta_1=1}^{n_1} \lambda_{\beta_1} C_1(\mathbf{u}_{\alpha_1} - \mathbf{u}_{\beta_1}) + \lambda_2(\mathbf{u}) C_{12}(\mathbf{u}_{\alpha_1} - \mathbf{u}_0) + \mu = C_1(\mathbf{u}_{\alpha_1} - \mathbf{u}_0), \quad \alpha_1 = 1, \dots, n_1 \\ \sum_{\beta_1=1}^{n_1} \lambda_{\beta_1} C_{21}(\mathbf{u}_0 - \mathbf{u}_{\beta_1}) + \lambda_2(\mathbf{u}) C_{22}(0) + \mu = C_{21}(0) \\ \sum_{\beta_1=1}^{n_1} \lambda_{\beta_1} + \lambda_2 = 1 \end{array} \right. \quad [\text{C.9}]$$



## REFERENCIAS

---

---

### - A -

- ALLEN, R.G., PEREIRA, L.S., RAES, D. AND SMITH, M. 1998. Crop evapotranspiration. *FAO Irrigation and Drainage Paper*, N° 56.
- ALMEIDA, A. AND JOURNEL, A.G. 1994. Joint simulation of multiple variables with a Markov-type coregionalization model. *Mathematical Geology*, 26: 565-588.
- ANDRIEU, B. AND BARET, F. 1993. Indirect methods of estimating crop structure from optical measurements. In *Crop Structure and Light Microclimate, Characterization and Apcouvert, plications* (C. Varlet-Grancher, R. Bonhomme, and H. Sino-quet, Eds.), INRA, Paris, pp.285-322.
- ATKINSON, P.M., WEBSTER, R. AND CURRAN, P.J. 1996. Cokriging with airborne MSS imagery. *Remote Sensing of the Environment*, 50 (3): 335-345.
- ATKINSON, P. M. AND CURRAN, P. J. 1995. Defining an optimal size of support for remote sensing investigations. *IEEE Transactions on Geoscience and Remote Sensing*, 33: 1- 9.
- ATKINSON, P.M., WEBSTER, R. AND CURRAN, P.J. 1994. Cokriging with airborne MSS imagery. *Remote Sensing Environment*, 50: 335-345.
- ATKINSON, P. M. 1993a. Simulating Landsat TM images with the variogram. *Towards Operational Applications* (Notingham: Remote Sensing Society), pp. 25- 32.
- ATKINSON, P. M. 1993b. The effect of spatial resolution on the experimental variogram of airborne MSS imagery. *International Journal of Remote Sensing*, 14: 1005- 1011.
- ATKINSON, P. M., WEBSTER, R. AND CURRAN, P. J. 1992. Cokriging with ground-based radiometry. *Remote Sensing of Environment*, 41: 45-60.
- ATKINSON, P. M. 1991. Optimal ground-based sampling for remote sensing investigations: estimating the regional mean. *International Journal of Remote Sensing*, 12: 559- 567.
- AUBRY P. AND DEBOUZIE D. 2000. Geostatistical estimation variance for the spatial mean in two-dimensional systematic sampling. *Ecology*, 81: 543-53.

### - B -

- BARCLAY, H. J. 1998. Conversion of total leaf area to projected leaf area in lodgepole pine and Douglas-fir. *Tree Physiology*, 18:185-93.

- BARET, F., ET AL. 2005a. VALERI: a network of sites and a methodology for the validation of land satellite products. *Remote Sensing of Environment*, (en prensa).
- BARET, F., ET AL. 2005b. Evaluation of the representativity of networks of sites for the validation and inter-comparison of global land biophysical products. Proposition of the CEOS-BELMANIP. *IEEE special issue: Validation and accuracy assessment of global products* (enviado).
- BARET, F., BACOUR, C., WEISS, M., PAVAGEAU, K., BÉAL, D., BRUNIQUEL, V., REGNER, P., MORENO, J., GONZALEZ, C. AND CHEN, J. 2003. Canopy biophysical variables estimation from MERIS observations based on neural networks and radiative transfer modelling: principles and validation. *presented at ENVISAT conference, Salzburg* (Austria).
- BARET, F. AND GUYOT, G. 1991. Potentials and Limits of vegetation indices for LAI and APAR assessment. *Remote Sensing of Environment*, 35: 161-173.
- BARET, F., GUYOT, G., BEGUE, A., MAUREL, P. AND PODAIRE, A. 1988. Complementarity of middle infrared with visible and near-infrared reflectance for monitoring wheat canopies. *Remote Sensing of Environment*, 26: 213- 225.
- BARBER, C. B., DOBKIN, D.P. AND HUHDANPAA, H.T. 1996. The Quickhull Algorithm for Convex Hulls. *ACM Transactions on Mathematical Software*, 22(4): 469-483.
- BEADLE, C.L. 1993. Growth analysis. In: Hall, D.O., et al. (Eds.), *Photosynthesis and Production in a Changing Environment: A Field and Laboratory Manual*. Chapman & Hall, London, pp. 36-46.
- BEGUE, A. 1991. Estimation de la production primaire en zone Sahélienne à partir de données radiométriques. PhD thesis, Université Paris VII.
- BELWARD, A. S. 1999. International co-operation in satellite sensor calibration; the role of the CEOS working group on calibration and validation. *Adv. Space Res.* 23: 1443-1448.
- BERTERRETICHE, M., HUDAK, A. T., COHEN, T. W., MAIERSPERGER, T. K., GOWER, S. T. AND DUNGAN, J. 2005. Comparison of regression and geostatistical methods for mapping Leaf Area Index (LAI) with Landsat ETM+ data over a boreal forest. *Remote Sensing of Environment*, 96: 49-61.
- BHATTI, A. U., MULLA, D. J. AND FRAZIER, B. E. 1991. Estimation of soil properties and wheat yields on complex eroded hills using geostatistics and thematic mapper images. *Remote Sensing of Environment*, 37: 181-191.

- BLENNOW, K. 1995. Sky view factors from high resolution scanned fish-eye lens photographic negatives. *Journal of Atmospheric and Oceanic Technology*, 12: 357-1362.
- BOGAERT, P. AND RUSSO, D. 1999. Optimal spatial sampling design for the estimation of the variogram based on a least squares approach. *Water Resources Research*, 35: 1275-89.
- BOLLE, H.J., ET AL. 1993. EFEDA: European field experiment in a desertification-threatened area. *Annales Geophysique*, 11: 173-189.
- BONHOMME, R., VARLET GRANGER, C. AND CHARTIER, P. 1972a. The use of photographs for determining the leaf area index of young crops. *Photosynthesis*, 8: 299-301.
- BONHOMME, R. AND CHARTIER, P. 1972b. The interpretation and automatic measurement of hemispherical photographs to obtain sunlit foliage area and gap frequency. *The Israel Journal of Agricultural Research*, 22: 53-61.
- BROWN, L., CHEN, J. M., LEBLANC, S. G. AND CIHLAR, J. 2000. A shortwave infrared modification to the simple ratio for LAI retrieval in boreal forests: An image and model analysis. *Remote Sensing of Environment*, 71: 16- 25.
- BURGESS, T.M. AND WEBSTER, R. 1980. Optimal interpolation and isarithmic mapping of soil properties I. The semi-variogram and punctual Kriging. *Journal of Soil Science*, 31: 315-331.
- BURROWS, S. N., GOWER, S. T., CLAYTON, M. K., MACKAY, D. S., AHL, D. E., NORMAN, J. M. AND DIAK, G. 2002. Application of geostatistics to characterize leaf area index (LAI) from flux tower to landscape scales using a cyclic sampling design. *Ecosystems*, 5: 667-679.

- C -

- CALERA, A., JOCHUM, A. AND CUESTA, A. 2003. Space-assisted irrigation management: Towards user-friendly products. ICID Workshop on Remote Sensing of Crop Evapotranspiration, Montpellier, 17 Sep 2003.
- CALERA, A., MARTÍNEZ, C. AND MELIÁ, J. 2001. A procedure for obtaining green plant cover: relation to NDVI in a case study for barley. *International Journal of Remote Sensing*, 22: 3357-3362.
- CAMACHO-DE COCA, F. 2004. La anisotropía de la BRDF en la estimación de parámetros de la cubierta vegetal mediante teledetección. Tesis Doctoral. Doctorado Europeo. Universitat de Valencia. 404 pp.
- CAMACHO-DE COCA, F., GARCÍA HARO, F. J., MARTÍNEZ, B. AND MELIÁ, J. 2003. Prototyping algorithm for retrieving vegetation parameters from the MSG

- and EPS Eumetsat platforms. *Remote Sensing for Agriculture, Ecosystem and Hydrology*. SPIE. Vol 5232: 1-10.
- CAMPBELL G.S. AND NORMAN J.M. 1998. An introduction to environmental biophysics. New York: Springer-Verlag New York.
- CAMPBELL, G.S. 1990. Derivation of an angle density function for canopies with ellipsoidal leaf angle distributions. *Agricultural and Forest Meteorology*, 49, 173-176.
- CAMPBELL, G.S. 1986. Extinction coefficients for radiation in plant canopies calculated using an ellipsoidal inclination angle distribution. *Agricultural and Forest Meteorology*, 36: 317-321.
- CARLSON, T. N. AND RIPLEY, D. A. 1998. On the relation between NDVI, fractional vegetation cover, and leaf area index. *Remote Sensing of Environment*, 62: 241-252.
- CARROLL, S. S. AND CRESSIE, N. 1996. A comparison of geostatistical methodologies used to estimate snow-water equivalent. *Water Resources Bulletin*, 32, 267-278.
- CASSIRAGA, E. AND GÓMEZ-HERNÁNDEZ, J. 1997. Improved Rainfall Estimation by Integration of Radar Data: A Geostatistical Approach. In: *GEOENV I - Geostatistics for Environmental Applications*. Ed. A. Soares, J. Gómez-Hernandez, R. Froidevaux. Kluwer Academic Publishers, 363-374.
- CAYLOR, K., SHUGART, P. R. AND SMITH, T. M. 2003. Tree spacing along the Kalahari transect in southern Africa. *Journal of Arid Environments*, 54: 281-296.
- CHASON, J.W., BALDOCCHI, D.D. AND HUSTON, M.A. 1991. Comparison of direct and indirect methods for estimating forest canopy leaf-area. *Agricultural and Forest Meteorology*, 57: 107-128.
- CHEN, J. M., ET AL. 2002. Derivation and validation of Canada wide coarse resolution leaf area index maps using high resolution satellite imagery and ground measurements. *Remote Sensing of Environment*, 80: 165-184.
- CHEN, J. M. 1999. Spatial scaling of a remotely sensed surface parameter by contexture. *Remote Sensing of Environment*, 69: 30-42.
- CHEN, J.M., RICH, P.M., GOWER, S.T., NORMAN, J.M. AND PLUMMER, S. 1997. Leaf area index of boreal forests: theory, techniques, and measurements. *Journal of Geophysical Research Atmosphere*, 102: 29429-29443.
- CHEN, J.M. 1996. Evaluation of vegetation indices and a modified simple ratio for boreal applications. *Canadian Journal of Remote Sensing*, 22: 229-242.
- CHEN, J.M. AND BLACK, T.A. 1992. Defining leaf-area index for non-flat leaves. *Plant Cell. Environ.*, 15: 421-429.

- CHEN, J.M. AND BLACK, T.A. 1991. Measuring leaf-area index of plant canopies with branch architecture. *Agricultural and Forest Meteorology*, 57: 1-12.
- CLEVERS, J. G. P. W. 1989. The application of a weighted infrared-red vegetation index for estimating leaf area index by correcting for soil moisture. *Remote Sensing of Environment*, 29: 25-37.
- COMBAL, B., BARET, F., WEISS, M., TRUBUIL, A., MACÉ, D., PRAGNÈRE, A., MYNENI, R.B., KNYAZIKHIN, Y. AND WANG, L. 2002. Retrieval of canopy biophysical variables from bi-directional reflectance data. Comparison of three algorithms to solve the ill-posed inverse problem. *Remote Sensing of Environment*, 84: 1-15.
- COHEN, W. B., MAIERSPERGER, T. K., YANG, Z., GOWER, S. T., TURNER, D. P., RITTS, W. B., BERTERRETICHE, M. AND RUNNING, S. W. 2003a. Comparisons of land cover and LAI estimates derived from ETM+ and MODIS for four sites in North America: a quality assessment of 2000/2001 provisional MODIS products. *Remote Sensing of Environment*, 88: 233-255.
- COHEN, W. B., MAIERSPERGER, T. K., GOWER, S. T. AND TURNER, D. P. 2003b. An improved strategy for regression of biophysical variables and Landsat ETM+ data. *Remote Sensing of Environment*, 84: 561-571.
- COHEN, W., MAIERSPERGER, T., SPIES, T. AND OETTER, D. 2001. Modelling forest cover attributes as continuous variables in a regional context with Thematic Mapper data. *International Journal of Remote Sensing*, 22: 2279- 2310.
- COHEN, W. B. AND JUSTICE, C. O. 1999. Validating MODIS terrestrial ecology products: linking in situ and satellite measurements. *Remote Sensing of Environment*, 70: 1- 3.
- COLOMBO, R., BELLINGERI, D., FASOLINI, D. AND MARINO, C. M. 2003. Retrieval of leaf area index in different vegetation types using high resolution satellite data. *Remote Sensing of Environment*, 86: 120-131.
- CURRAN, P. J. AND ATKINSON, P. M. 2002. Issues of scale and optimal pixel size. In Gorte B. Stein A., Vander Meer F., editor, *Spatial Statistics of Remote Sensing*, pp: 115-133. Dordrecht: Kluwer.
- CURRAN, P.J. AND HAY, A. M. 1986. The importance of measurement error for certain procedure in remote sensing of optical wavelengths. *Photogrammetric Engineering and Remote Sensing*, 52: 229-241.
- D -**
- DANCY, K. J., WEBSTER, R. AND ABEL, N. O. J. 1986. Estimating and mapping grass cover and biomass from low-level photographic sampling. *International Journal of Remote Sensing*, 7: 1679- 1704.

- DAUGHTRY, C. S. T., GALLO, K. P., GOWARD, S. N., PRINCE, S. D. AND KUSTAS, W. P. 1992. Spectral estimates of absorbed radiation and phytomass production in corn and soybean canopies. *Remote Sensing of Environment*, 39: 141-152.
- DECAGON. 2001. AccuPAR, Linear PAR/LAI ceptometer. Operator's Manual, Version 3.4. Decagon Devices, Inc.
- DEARDORFF, J.W. 1978. Efficient prediction of ground surface temperature and moisture, with inclusion of a layer of vegetation. *Journal of Geophysical Research*, 83: 1889-1903.
- DEBLONDE, G., PENNER, M. AND ROYER, A. 1994. Measuring leaf area index with Li-Cor LAI-2000 in pine stand. *Ecology*, 75: 527-1511.
- DEUTSCH, C. AND JOURNAL, A. 1998. GSLIB, Geostatistical Software Library and User's Guide, Second edition, Oxford University Press, New York.
- DUMOUCHEL, W.H. AND F.L. O'BRIEN. 1989. Integrating a robust option into a multiple regression computing environment. *Computer Science and Statistics: Proceedings of the 21st Symposium on the Interface*, American Statistical Association, Alexandria, VA.
- DUNGAN, J. L., PETERSON, D. L. AND CURRAN, P. J. 1994. Alternative approaches for mapping vegetation quantities using ground and image data. In *Environmental Information Management and Analysis: ecosystem to global scales*, edited by W. Michener, S. Stanford, and J. Brunt (London: Taylor and Francis), pp. 237- 261.
- DUTILLEUL, P. 1993. Spatial heterogeneity and the design of ecological field experiments. *Ecology*, 74: 1646-58.

- E -

- EFRON, B. AND GONG, G. 1983. A leisurely look at the bootstrap the jackknife, and cross-validation. *The American Statistician*, 37: 36-48.
- EPHIPHANIO, J.C. AND HUETE, A. 1994. Dependence of NDVI and SAVI on Sun/Sensor geometry and its effect on fAPAR relationships in alfalfa. *Remote Sensing of Environment*, 51: 351-360.
- EVANS, G.C. 1972. *The quantitative analysis of plant growth*. University of California Press, Berkeley, CA.

- F -

- FASSNACHT, K.S., GOWER, S.T., MACKENZIE, M.D., NORDHEIN, E.V. AND LILLESAND, T.M. 1997. Estimating the leaf area index of north central Wisconsin forests using the Landsat Thematic Mapper. *Remote Sensing of Environment*, 61: 229-245.

- FASSNACHT, K.S., GOWER, S.T., NORMAN, J.M. AND MCMURTRIE, R.E. 1994. A comparison of optical and direct methods for estimating foliage surface area index in forests. *Agricultural and Forest Meteorology*, 71: 183–207.
- FENSHOLT, R., SANDHOLT, I. AND RASMUSSEN, S. 2004. Evaluation of MODIS LAI, fAPAR and the relation between fAPAR and NDVI in a semi-arid environment using in situ measurements. *Remote Sensing of Environment*, 91: 490-507.
- FERNÁNDEZ, G., MORENO, J., GANDÍA, S., MARTÍNEZ, B., VUOLO, F. AND MORALES, F. 2005. Statistical variability of fields measurements of biophysical parameters in SPARC-2003 and SPARC-2004 data campaigns. Final report SPARC, ESA proceedings, (en prensa).
- FERNANDES, R., BUTSON, C., LEBLANC, S. AND LATIFOVIC, R. 2003. Landsat-5 TM and Landsat-7 ETM+ based accuracy assessment of leaf area index products for Canada derived from SPOT-4 VEGETATION data. *Canadian Journal of Remote Sensing*, 29: 241–258.
- FRAZER, G.W., CANHAM, C. D. AND LERTZMAN, K. P. 2000. Gap Light Analyzer (GLA), version 2.0. *Bulletin of the Ecological Society of America*, 81: 191-197.
- FRIEDL, M.A. 1997. Examining the effects of sensor resolution and sub-pixel heterogeneity on spectral vegetation indices: Implications for biophysical modelling. In Quattrochi and Goodchild, editor, *Scale in Remote Sensing and GIS*, pages 113-140. Lewis Publisher.

- G -

- GALLO, K. P., DAUGHTRY, C. S. T. AND WIEGAND, C. L. 1993. Errors in measuring absorbed radiation and computing crop radiation use efficiency. *Agronomie Journal*, 85: 1222–1228.
- GALLO, K. P. AND DAUGHTRY, C. S. T. 1986. Techniques for measuring intercepted and absorbed photosynthetic active radiation in corn canopies. *Agronomie Journal*, 78: 752–756.
- GARCÍA-HARO, F.J., CAMACHO-DE COCA, F. AND MELIÁ, J. 2005a. A Directional Spectral Mixture Analysis method. Application to multiangular airborne measurements. *Transactions on Geoscience and Remote Sensing*, (en prensa).
- GARCÍA-HARO, F.J., SOMMER, S. AND KEMPER, T. 2005b. Variable multiple endmember spectral mixture analysis (VMESMA). *International Journal of Remote Sensing*, 26: 2135-2162.
- GARCÍA-HARO, F.J., CAMACHO-DE COCA, F., AND MELIÁ, J. 2003. Metodología para derivar productos de vegetación con datos SEVIRI/MSG: Inversión del modelo DISMA, en “Teledetección y desarrollo regional”, ISBN: 84-607-8649-8, pp. 373-376.

- GARRIGUES, S. 2004. Hétérogénéité spatiale des surfaces terrestres en télédétection : caractérisation et influence sur l'estimation des variables biophysiques. Tesis Doctoral ([http://www.avignon.inra.fr/valeri/fic\\_htm/documents](http://www.avignon.inra.fr/valeri/fic_htm/documents)).
- GATES, D.M., KEEGAN, H. J., SCHLETER, J. C. AND WEIDNER, V. R. 1965. Spectral properties of plants. *Applied Optics*, 4: 11-20.
- GOBRON, N., PINTY, B., VERSTRAETE, M. M., GOVAERTS, Y. M., MARTONCHIK, J. V., KNYAZIKHIN, Y. AND DINER, D. J. 2000a. Potential of multiangular spectral measurements to characterize land surfaces: Conceptual approach and exploratory application. *Journal of Geophysical Research*, 105: 17539-17549.
- GOBRON, N., PINTY, B., VERSTRAETE, M. AND WIDLowski, J. L. 2000b. Advanced vegetation indices optimized for up-coming sensors: design, performances and applications. *IEEE Transactions on Geoscience and Remote Sensing*, 38: 2489-2505.
- GOHIN, F. AND LANGLOIS, G. 1993. Using geostatistics to merge in situ measurements and remotely sensed observations of sea surface temperature. *International Journal of Remote Sensing*, 14: 9-19.
- GOOVAERTS, P. 2000. Geostatistical approaches for incorporating elevation into the spatial interpolation of rainfall. *Journal of Hydrology*, 228: 113-129.
- GOOVAERTS, Y.M., Verstraete, M.M., Pinty, B. and Gobron, N. 1999. Designing Optimal Spectral Indices: a feasibility and proof of concept study. *International Journal of Remote Sensing*, 20 (9): 1853-1873.
- GOOVAERTS, P. 1997. Geostatistics for Natural Resources Evaluation, Oxford University Press, New York.
- GOWER, S.T., KUCCHARIK, C.J. AND NORMAN, J.M. 1999. Direct and indirect estimation of leaf area index, fAPAR, and net primary production of terrestrial ecosystems. *Remote Sensing of Environment*, 70: 29-51.
- GOWER, S.T. AND NORMAN, J.M. 1991. Rapid estimation of leaf-area index in conifer and broad-leaf plantations. *Ecology*, 72: 1896-1900.
- GUTMAN, G. AND IGNATOV, A. 1998. The derivation of the green vegetation fraction from NOAA/AVHRR data for use in numerical weather prediction models, *International Journal of Remote Sensing*, 19 (8), 1533-1543.
- H -**
- HALL, F. G., HUENNRICH, K. F. AND GOWARD, S. N. 1990. Use of narrow-band spectra to estimate the fraction of absorbed photosynthetically active radiation. *Remote Sensing of Environment*, 33: 47-54.
- HERBERT, T. J. 1986. Calibration of fish-eye lenses by inversion of area projections. *Applied Optics*, 25: 1875-1876.

HILL, R. 1924. A lens for whole sky photographs. *Quarterly Journal of the Royal Meteorological Society*, 50: 227-235.

HOLBEN, B. N. AND JUSTICE, C. O. 1980. The topographic effect on spectral response from nadir-pointings sensors. *Photogrammetry Engineering of Remote Sensing*, 46: 1180-1191.

HU, J., TAN, B., SHABANOV, N., CREAN, K. A., MARTONCHIK, J. V., DINER, D. J., KNYAZIKHIN, Y. AND MYNENI, R. B. 2003. Performance of the MISR LAI and FPAR algorithm: a case study in Africa. *Remote Sensing of Environment*, 88: 324-340.

HUBER, P. J. *Robust Statistics*, Wiley, 1981.

HUDAK, A. T., LEFSKY, M. A., COHEN, W. B. AND BERTERRETICHE, M. 2002. Integration of lidar and Landsat ETM+ data for estimation and mapping forest canopy height. *Remote Sensing of Environment*, 82: 397-416.

HUETE, A., DIDAN, K., MIURA, T., RODRÍGUEZ, E. P., GAO, X. AND FERREIRA, L.G. 2002. Overview of the radiometric and biophysical performance of the MODIS vegetation indices. *Remote Sensing of Environment*, 83: 195-213.

**- I -**

IACHAN, R. 1982. Systematic-sampling: a critical-review. *International Statistics Review*, 50: 293-303.

ISAACS, E. AND SRIVASTAVA, R. 1989. *An Introduction to Applied Geostatistics*, Oxford University Press, New York.

**- J -**

JANSEN, F.E. 1998. Upscaling of reservoir properties using wavelets. SPE India Oil and Gas Conference and Exhibition held in New Delhi, India, 17-19 February 1998. 23-37.

JONCKHEERE, I., FLECK, S., NACKAERTS, K., MUYS, B., COPPIN, P., WEISS, M. AND BARET, F. 2004. Methods for leaf area index determination. Part I: Theories, techniques and instruments. *Agricultural and Forest Meteorology*, 121: 19-35.

JOURNEL, A. G. AND HUIJBREGTS, C. J. 1978, *Mining Geostatistics*. Academic Press, New York, 600 p.

JUSTICE, C.O., BELWARD, A., MORISSETTE, J., LEWIS, P., PRIVETTE, J. AND BARET, F. 2000. Developments in the 'validation' of satellite sensor products for the study of the land surface. *International Journal of Remote Sensing*, 21 (17): 3383-3390.

JUSTICE, C. O., MARKHAM, B. L., TOWNSHEND, J. R. G. AND KENNARD, R. L. 1989. Spatial degradation of satellite data. *International Journal of Remote Sensing*, 10 (9): 1539-1561.

JUPP, D. L. B., STRAHLER, A. H. AND WOODCOCK, C. E. 1989, Autocorrelation and regularization in digital images II. Simple image models. *IEEE Transactions on Geoscience and Remote Sensing*, 27: 247- 258.

JUPP, D. L. B., STRAHLER, A. H. AND WOODCOCK, C. E. 1988. Autocorrelation and regularization in digital images I. Basic theory. *IEEE Transactions on Geoscience and Remote Sensing*, 26: 463- 473.

**- K -**

KAUFMAN, Y. J. 1989. The atmospheric effect on remote sensing and its correction, in *Theory and Applications of Optical Remote Sensing*, G. Asrar, ed., Wiley, pp. 336-428.

KIMES, D.S., KNYAZIKHIN, Y., PRIVETTE, J.L., ABUELGASIM, A.A. AND GAO, F. 2000. Inversion methods for physically-based models. *Remote Sensing Reviews*, 18: 381-439.

KITANIDIS, P.K. 1997. Introduction to Geostatistics, Applications in Hydrogeology. ISBN 0-521-58747-6, Cambridge University Press.

KLEINBAUM, D. G., KUPPER, L. L., MULLER, K. E. AND NIZAM, A. 1998. Applied regression analysis and other multivariable methods (3rd ed.). 736 pp. Pacific Grove, CA: Duxbury Press.

KNYAZIKHIN, Y., ET AL. 1999. MODIS Leaf Area Index (LAI) and Fraction of Photosynthetically Active Radiation Absorbed by Vegetation (FPAR) Product (MOD15) Algorithm, Theoretical Basis Document, NASA Goddard Space Flight Center, Greenbelt, MD 20771, USA.

KNYAZIKHIN, Y., MARTONCHIK, J.V., MYNENI, R.B., DINER, D.J. AND 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.

KOLASA, J. AND ROLLO, C.D. 1991. Introduction: the Heterogeneity of Heterogeneity: a Glossary. Pp. 1-23. En: *Ecological Heterogeneity* . J. Kolasa y S. T. A. Pickett (eds). Springer-Verlag.

KRIGE, D. 1951. A statistical problem to some basic minimum valuation problems on the Witwatersrand. *Journal of the Chemical, Metallurgical and Mining Society of the South Africa*, 52: 119-139.

KUSSNER, R. AND MOSANDL, R. 2000. Comparison of direct and indirect estimation of leaf area index in mature Norway spruce stands of eastern Germany. *Canadian Journal of Forest Research*, 30: 440-447.

KYRIAKIDIS, P. C., MILLER N.L. AND KIM, J. 2004. A spatial time series framework for simulating daily precipitation at regional scales. *Journal of Hydrology*, 297: 236-255.

- L -

LANG, A.R.G., MCMURTRIE, R.E. AND BENSON, M.L. 1991. Validity of surface area indices of *Pinus radiata* estimated from transmittance of the sun's beam. *Agricultural and Forest Meteorology*, 57: 157-170.

LANG, A.R.G., XIANG, Y. AND NORMAN, J.M. 1985. Crop structure and the penetration of direct sunlight. *Agricultural and Forest Meteorology*, 35: 83-101.

LAW, B.E., TUYL, S.V., CESCATTI, A. AND BALDOCCHI, D.D. 2001. Estimation of leaf area index in open-canopy ponderosa pine forests at different successional stages and management regimes in Oregon. *Agricultural and Forest Meteorology*, 108, 1-14.

LEBLANC, S.G., FERNANDES, R., AND CHEN, J.M. 2002. Recent advancements in optical field leaf area index, foliage heterogeneity, and foliage angular distribution measurements. In: Proceedings of IGARSS 2002, Toronto, Canada, 24-28 June.

LEGENDRE, P. 1993. Spatial autocorrelation: trouble or new paradigm?. *Ecology*, 74:1659-73.

LEVY, P. S. AND LEMESHOW, S. 1999. Sampling of populations: Methods and Applications, 3rd ed., Wiley.

LI, X. AND STRAHLER, A. H. 1995. A hybrid geometrical optical-radiative transfer approach for modelling albedo and directional reflectance of discontinuous canopies. *IEEE Transactions on Geoscience and Remote Sensing*, 33 (2): 466-480.

LIANG, S. 2004. Quantitative remote sensing of land surfaces. New York: John Wiley & Sons, Inc.

LIANG, X. 2002. The role of multi-scale land surface heterogeneity in precipitation recycling and land-atmosphere interactions. *Annual Report*, NASA Hydrology Program.

LI-COR. 1992. LAI-2000 Plant Canopy Analyser. Instruction Manual. LICOR, Lincoln, NE, USA.

LOVELAND, T. R., REED, B. C., BROWN, J. F., OHEN, D. O., ZHU, Z., YANG, L. AND MERCHANT, J. W. 2000. Development of a global land cover characteristics database and IGBP DISCover from 1km AVHRR data. *International Journal of Remote Sensing*, 21: 1303-1330.

- M -

- MARTÍNEZ, B., CAMACHO-DE COCA, F Y GARCÍA-HARO, F.J. 2005a. Estimación de parámetros biofísicos de vegetación utilizando el método de la cámara hemisférica. *Revista de Teledetección*, 23: 13-26.
- MARTÍNEZ, B., CAMACHO-DE COCA, F., GARCÍA-HARO, F. J., VERGER, A. AND MELIÁ, J. 2005b. A methodology for direct validation of LAI/FVC/FAPAR coarse satellite derived products. Final Report SPARC. ESA Proceedings, (en prensa).
- MARTÍNEZ, B., BARET, F., CAMACHO-DE COCA, F., GARCÍA-HARO, F. J., VERGER, A. AND MELIÁ, J. 2004b. Methodology to validate MSG vegetation products. Part I: Field retrieval of LAI and FVC from hemispherical photographs. *Remote Sensing for Agriculture, Ecosystem and Hydrology*. SPIE. Gran Canarias. Vol5232, pp:57-68.
- MARTÍNEZ, B., GARCÍA-HARO, F. J., WEISS, M. AND MELIÁ, J. 2004a. Methodology to validate MSG vegetation products. Part II: Geostatistical approaches for upscaling field data to high-resolution satellite scales. *Remote Sensing for Agriculture, Ecosystem and Hydrology*. SPIE. Gran Canarias. Vol5232, pp: 123-133.
- MATHERON, G. 1971. The Theory of Regionalized Variables and Its Applications, Les Cahiers du CMM, Fasc. No. 5, ENSMP, Paris, 211 pp.
- MATHERON, G. 1963a. Traite de Geoestatistique Appliquee. Tome 2: Le Krigeage. *Memoires du Bureau de Recherches Geologiques et Minieres*. Ed. Technip, París.
- MATHERON, G. 1963b. Principles of Geostatistics. *Economic Geology*, 58: 1246-1266.
- MATHERON, G. 1962. Traite de Geoestatistique Appliquee. Tome 1. *Memoires du Bureau de Recherches Geologiques et Minieres*. Ed. Technip, París.
- MASSON, V., CHAMPEAUX, J. L., CHAUVIN, F., MERIGUER, C. AND LACAZE, R. 2004. A global database of land surface parameters at 1km resolution in meteorological and climate models, *Journal of Climate*, (en prensa).
- MILLER, J.B. 1967. A formula for average foliage density. *Australian Journal of Botany*, 15: 141-144.
- MILNE, B.T. AND. COHEN, W.B. 1999. Multiscale assessment of binary and continuous landcover variables for MODIS validation, mapping, and modeling applications. *Remote Sensing of Environment*, 70:82-98.
- MORENO, J., CALERA, A., CASELLES, V., CISNEROS, J. M., MARTÍNEZ-LOZANO, J. A., MELIÁ, J., MONTERO, F. AND SOBRINO, J. 2001. The measurements programme at Barrax. ESA-DAISEX proceedings, ESA SP-499, 43-52.

- MORISSETTE, J. T., ET AL. 2005. Validation of global moderate resolution LAI Products: a framework proposed within the CEOS Land Product Validation subgroup. LAI Intercomparison Overview Submission , LPV special issue, (en prensa).
- MORISSETTE, J. T., ET AL. 2003. High spatial resolution satellite observations for validation of MODIS land products: IKONOS observations acquired under the NASA Scientific Data Purchase. *Remote Sensing of Environment*, 88: 100–110.
- MORISSETTE, J., PRIVETTE, J. AND JUSTICE, C. 2002. A framework for the validation of MODIS Land products. *Remote Sensing of Environment*, 83: 77– 96.
- MÜLLER, W. G. AND ZIMMERMAN, D. L. 1999. Optimal designs for variogram estimation. *Environmetrics*, 10:23–37.
- MYNENI, R.B., ET AL. 2002. Global products of vegetation leaf area and fraction absorbed PAR from year one of MODIS data. *Remote Sensing of Environment*, 83: 214-231.
- MYNENI, R. B., HALL, F. G., SELLERS, P. J. AND MARSHAK, A. L. 1995. The meaning of spectral vegetation indices. *IEEE Transactions on Geoscience and Remote Sensing*, 33: 481– 486.
- MYNENI, R. B. AND WILLIAMS, D. L. 1994. On the relationship between fAPAR and NDVI. *Remote Sensing of Environment*, 49: 200-211.
- MYERS, D. E. 1991. Pseudo-cross variograms, positive-definiteness, and cokriging. *Mathematical Geology*, 23(6): 805-816.
- MYERS, D.E. 1982. Matrix formulation of co-kriging. *Mathematical Geology*, 14: 249–257.

- N -

- NACKAERTS, K., COPPIN, P., MUYS, B. AND HERMY, M. 2000. Sampling methodology for LAI measurements with LAI-2000 in small forest stands. *Agricultural and Forest Meteorology*, 101: 247–250.
- NEMANI, R., PIERCE, L., RUNNING, S. W. AND BAND, L. 1993. Forest ecosystem processes at the watershed scale: Sensitivity to remotely sensed leaf area index estimates. *International Journal of Remote Sensing*, 14 (13): 2519–2534.
- NEUMANN, H. H., DEN HARTOG, G. D. AND SHAW, R. H. 1989. Leaf-area measurements based on hemispheric photographs and leaf-litter collection in a deciduous forest during autumn leaf-fall. *Agricultural and Forest Meteorology*, 45: 325–345.
- NILSON, T. 1971. A theoretical analysis of the frequency of gaps in plant stands. *Agricultural and Forest Meteorology*, 8: 25–38.

NOILHAN, J. AND PLANTON, S. 1989, A simple parameterization of land surface processes for meteorological models. *Monthly Weather Review*, 117: 536-549.

- O -

OPENSHAW, S. 1984. The Modifiable Areal Unit Problem in Concepts and Techniques in Modern Geography Number 38. GeoBooks, Norwich.

- P -

PANNATIER, Y. 1996. VARIOWIN: Software for Spatial Data Analysis in 2D. Springer-Verlag, New York, NY. ISBN 0-387-94679-9.

PENNEBAKER, W. B., AND MITCHELL, J. L. 1993. JPEG Still Image Data Compression Standard. Van Nostrand Reinhold, New York.

PEARCE, R.B., BROWN, R.H. AND BLASER, R.E. 1965. Relationships between leaf area index, light interception and net photosynthesis in orchardgrass. *Crop Science*, 5: 553-556.

PERRY, S. G., FRASER, A. B., THOMSON, D.W. AND NORMAN, J. M. 1988. Indirect sensing of plant canopy structure with simple radiation measurements. *Agricultural and Forest Meteorology*, 42: 255-278.

PIERCE, L. L. AND RUNNING, S.W. 1995. The effects of aggregating sub-grid land surface variation on large-scale estimates of net primary production. *Landscape Ecology*, 10: 239-253.

PRIVETTE, J. L., ET AL. 2000. The Prototype Validation Exercise (PROVE) at Jornada: overview and lessons learned. *Remote Sensing of Environment*, 74 (1): 1- 12.

PRINCE, S. D. 1991. A model of regional primary production for use with coarse resolution satellite data. *International Journal of Remote Sensing*, 12: 1313-1330.

PRUDHOMME, C. 1999. Mapping extreme rainfall in a mountainous region using geostatistical techniques: a case study in Scotland. *International Journal of Hydrology*, 19: 1337-1356.

- Q -

QUINN, G. P. AND KEOUGH, M. J. 2002. Experimental design and data analysis for biologists. 537 pp. Cambridge University Press, UK.

- R -

RAFFY M. 1994. The role of spatial resolution in quantification problems. Spatialization method. *International Journal of Remote Sensing*, 15 (12): 2381-2392.

- REICH, P. B., TURNER, D. P. AND BOLSTAD, P. 1999. An approach to spatially distributed modelling of Net Primary Production (NPP) at the landscape scale and its application in validation of EOS NPP products. *Remote Sensing of Environment*, 70 (1): 69– 81.
- RICH, P.M., CLARK, D.B., CLARK, D.A. AND OBERBAUER, S.F. 1993. Long-term study of solar radiation regimes in a tropical wet forest using quantum sensors and hemispherical photography. *Agricultural and Forest Meteorology*, 65: 107-127.
- RICH, P.M. 1990. Characterizing plant canopies with hemispherical photographs. *Remote Sensing Reviews*, 5: 13–29.
- RICHARDS, J.A. 1999. *Remote Sensing Digital Image Analysis*, Springer-Verlag, Berlin, p. 240.
- ROSS, J. 1981. *The radiation regime and architecture of plant stands*, The Hague, 391 pp.
- ROUJEAN, J.L. AND LACAZE, R. 2002. Global mapping of vegetation parameters from POLDER multiangular measurements for studies of surface-atmosphere interactions: A pragmatic method and its validation. *Journal of Geophysical Research*, 107D: 10129-10145.
- ROUJEAN, J.L. AND BRÉON, F. M. 1995. Estimating PAR absorbed by vegetation from bidirectional reflectance measurements. *Remote Sensing of Environment*, 51: 373-384.
- ROUJEAN, J.L., LEROY, M. AND DECHAMPS, P.Y. 1992. A bidirectional reflectance model of the earth's surface for the correction of remote sensing data. *Journal of Geophysical Research*, 97 (D18): 20455-20468.
- RUNNING, S., BALDOCCHI, D., TURNER, D., GOWER, S., BAKWIN, P. AND HIBBARD, K. 1999. A global terrestrial monitoring network integrating tower fluxes, flask sampling, ecosystem modeling and EOS data. *Remote Sensing of Environment*, 70: 108–127.

**- S -**

- SANDMEIER, S. AND ITTEN, K. I. 1997. A physically-based model to correct atmospheric and illumination effects in optical satellite data rugged terrain. *IEEE Transactions on Geosciences and Remote Sensing*, 35: 708-717.
- SELLERS, P. J., ET AL. 1997a. Modelling the exchanges of energy, water, and carbon between the continents and the atmosphere. *Science*, 275: 502–509.
- SELLERS, P.J., ET AL. 1997b. Boreas in 1997 : Experiment overview, scientific results and future directions. *Journal of Geophysical Research*, 102 (D24): 28731-28770.

- SELLERS, P., LOS, S., JUSTICE, C., DAZLICH, D., COLLATZ, G. AND RANDALL, D. 1996, A revised land surface parameterization (SiB-2) for atmospheric GCMs. Part 2: The generation of global fields of terrestrial biophysical parameters from satellite data. *Journal of Climate*, 9: 706-737.
- SICHEL, H.S. 1949. *Mine valuation and maximum likelihood*. Unpublished Master of Science Thesis, Univ. Witwatersrand, Johannesburg.
- SICHEL, H.S. 1947, An experimental and theoretical investigation of bias error in mine sampling with special reference to narrow gold reefs. *Transactions, Institution of Mining and Metallurgy, London*, 56, P. 403-473.
- SMITH, F.W., SAMPSON, D.A. AND LONG, J.N. 1991. Comparison of leaf area index estimates from tree allometrics and measured light interception. *Forest Science.*, 37: 1682-1688.
- STEEL, R. AND TORRIE, J. Principles and Procedures of Statistics. A Biometrical Approach. (2nd ed.). *New York: McGraw-Hill.*, 1980.
- STENBERG, P., LINDER, S., SMOLANDER, H. AND FLOWERELLIS, J. 1994. Performance of the Lai-2000 Plant Canopy Analyzer in Estimating Leaf-Area Index of Some Scots Pine Stands. *Tree Physiology*, 14: 981-995.
- SWAP, R. J. AND ANNEGARN, H. (EDS.). 1999. Southern African Regional Science Initiative: SAFARI 2000: Science Plan, Available at <http://safari.gecp.virginia.edu>

- T -

- TIAN, Y., ET AL. 2002a. Multiscale analysis and validation of MODIS LAI product over Maun, Botswana. I: Uncertainty assessment. *Remote Sensing of Environment*, 83: 414-430.
- TIAN, Y., ET AL. 2002b. Multiscale analysis and validation of the MODIS LAI product. II: Sampling strategy. *Remote Sensing of Environment*, 83: 431-441.
- TOWNSHEND, R. G. AND JUSTICE, C. O. 1988. Selecting the spatial resolution of satellite sensors required for global monitoring of land transformations. *International Journal of Remote Sensing*, 9: 187-236.
- TUCKER, C.J. 1980. Remote Sensing of Leaf Water Content in Near Infrared, *Remote Sensing of Environment*, 10: 23-32.
- TUCKER, C. 1979. Red and infrared linear combinations for monitoring vegetation. *Remote Sensing of Environment*, 8, 127-150.
- TURNER, D. P., GOWER, S.T., COHEN, W. B., GREGORY, M. AND MAIERSPERGER, T. K. 2002. Effects of spatial variability in light use efficiency on satellite-based NPP monitoring. *Remote Sensing of Environment*, 80: 397-405.

TURNER, D. P., COHEN, W. B., KENNEDY, R. E., FASSNACHT, K. S. AND BRIGGS, J. M. 1999. Relationship between leaf area index and Landsat TM Spectral Vegetation Indices across three temperate zone sites. *Remote Sensing of Environment*, 70: 52-68.

- V -

VERSTRATE, M.M., PINTY, B. AND MYNENI, R.B. 1996. Potential and limitations of information extraction on the terrestrial biosphere from satellite remote sensing. *Remote Sensing of Environment*, 58: 201- 214.

- W -

WACKERNAGEL, H. 1995. *Multivariate Geostatistics: An Introduction with Applications*. Springer-Verlag, Berlin, 256 p.

WALTER, J. M. N. AND TORQUEBAU, F. H. 2000. The computation of forest leaf area index on slopes using fish-eye sensors. *Comptes Rendus de l'Académie des Sciences de Paris, Sciences de la Vie* 323: 801-813.

WANG, Y. S., ET AL. 2004. Evaluation of the MODIS LAI algorithm at a coniferous forest site in Finland. *Remote Sensing of Environment*, 91: 11-127.

WANG, Y.P. AND JARVIS, P.G. 1988. Mean leaf angles for the ellipsoidal inclination angle distribution. *Agricultural and Forest Meteorology*, 43: 319-321.

WANG, Y.S. AND MILLER, D.R. 1987. Calibration of the hemispherical photographic technique to measure leaf area index distributions in hardwood forests. *Forest Science*, 33: 210-226.

WARDLEY, N.W. AND CURRAN, P.J. 1984. The estimation of green leaf area index from remotely sensed airborne multispectral scanner data. *International Journal of Remote Sensing*, 5(4): 671-679.

WARREN-WILSON, J. 1963. Estimation of foliage denseness and foliage angle by inclined point quadrats. *Australian Journal of Botany*, 11: 95-105.

WARREN-WILSON, J. 1960. Inclined point quadrats. *New. Phytol.*, 59: 1-8.

WATSON, D.J. 1947. Comparative physiological studies in the growth of field crops. I. Variation in net assimilation rate and leaf area between species and varieties, and within and between years. *Annals of Botany*, 11: 41-76.

WEBSTER, R. AND OLIVER, M.A. 1989. Optimal interpolation and isarithmic mapping of soil properties: VI. Disjunctive kriging and mapping the conditional probability. *Journal of Soil Science*, 40: 497-512.

WEISS, M., BARET, F., SMITH, G.J., JONCKHEERE, I AND COPPIN, P. 2004a. Review of methods for in situ leaf area index (LAI) determination: Part II. Estimation of LAI, errors and samplings. *Agricultural and Forest Meteorology*, 121: 37-53.

- WEISS, M. 2004b. Valeri 2003: Barrax site (cropland). Ground data processing & Production of the level 1 high resolution maps. INRA-CSE, Avignon, <http://www.avignon.inra.fr/valeri>.
- WEISS, M., BARET, F., MYNENI, R.B., PRAGNÈRE, A. AND KNYAZIKHIN, Y. 2000. Investigation of a model inversion technique to estimate canopy biophysical variables from spectral and directional reflectance data. *Agronomie*, 20: 3-22.
- WEISS, M. AND BARET, F. 1999. Evaluation of Canopy Biophysical Variable Retrieval Performances from the Accumulation of Large Swath Satellite Data. *Remote Sensing of Environment*, 70: 293-306.
- WELLES, J.M. 1990. Some indirect methods of estimating canopy structure. *Remote Sensing Reviews*, 5: 31-43.
- WELLES, J.M. AND NORMAN, J.M. 1991. Instrument for indirect measurement of canopy architecture. *Agronomy Journal*, 83 (5): 818-825.
- WILSON, J.W. 1963. Estimation of foliage denseness and foliage angle by inclined point quadrats. *Australian Journal of Botany*, 11: 95-105.
- WILSON, J.W. 1960. Inclined point quadrats. *New Phytologist*, 59:1-8.
- WHITFORD, K.R., COLQUHOUN, I.J., LANG, A.R.G. AND HARPER, B.M. 1995. Measuring leaf area index in a sparse eucalypt forest: a comparison of estimates from direct measurement, hemispherical photography, sunlight transmittance and allometric regression. *Agricultural and Forest Meteorology*, 74: 237-249.
- WIEGAND, C.L. 1979. Leaf area index estimates of wheat from Landsat and their implications for evapotranspiration and crop modelling. *Agronomy Journal*, 71 (2): 336-342
- WHITE, M. A., ASNER, G. P., NEMANI, R. R. AND PRIVETTE, J. L., AND RUNNING, S. W. 2000. Measuring fractional cover and leaf area index in arid ecosystems: Digital camera, radiation transmittance, and laser altimetry methods. *Remote Sensing of Environment*, 74: 45-57.
- WYLIE, B. K., MEYER, D. J., TIESZEN, L. L. AND MANNEL, S. 2002. Satellite mapping of surface biophysical parameters at the biome scale over the North American grasslands. A case study. *Remote Sensing of Environment*, 79: 266-278.
- WOODCOCK, C.E. AND V.J. HARWARD. 1992. Nested-Hierarchical Scene Models and Image Segmentation. *International Journal of Remote Sensing*, 13(16): 3167-3187.
- WOODCOCK, C. E. AND STRAHLER, A. H. 1988a. The use of variograms in remote sensing: scene models and simulated images. *Remote Sensing of Environment*, 25: 323-379.

WOODCOCK, C. E. AND STRAHLER, A. H. 1988b. The use of variograms in remote sensing: real digital images. *Remote Sensing of Environment*, 25: 323-379.

WOODCOCK, C. E. AND STRAHLER, A. H. 1987. The factor of scale in remote sensing. *Remote Sensing of Environment*, 21: 311-332.

**-X-**

XU, W., TRAN, T.T., SRIVASTAVA, R.M. AND JOURNEL, A.G. 1992. Integrating seismic data in reservoir modeling: the collocated cokriging alternative, Society of Petroleum Engineers, paper no. 24, 742.

**- Z -**

ZHANG, Y., TIAN, Y., KNYAZIKHIN, Y., MARTONCHIK, J.V., DINNER, D.J., LEROY, M. AND MYNENI, R.B. 2000. Prototyping of MISR LAI and FPAR algorithm with POLDER data over Africa. *IEEE Transactions on Geoscience and Remote Sensing*, 38 (5): 2402-2418.

ZHOU, J., CIVCO, D. L. AND SILANDER, J. A. 1998. A wavelet transform to merge Landsat TM and SPOT panchromatic data. *International Journal of Remote Sensing*, 19: 743-757.



Actualmente, la teledetección se presenta como una herramienta muy potente en el uso de parámetros que describen el estado de la cubierta vegetal, ya que permite modelar y monitorizar a escala global y regional la superficie terrestre, constituyendo, a su vez, un instrumento indispensable para hacer frente a los desafíos del Cambio Global.

El continuo desarrollo tecnológico de los programas actuales de observación de la Tierra y de metodologías ha dado lugar a una amplia aplicación para comprender los procesos que ocurren en la biosfera. Lo que ha derivado en una fuerte demanda por un producto preciso, consistente y de alta calidad. Sin embargo, esta demanda requiere definir estrategias de validación y de intercomparación de los productos para garantizar su consistencia espacial y temporal respecto a valores de referencia y productos actuales. La validación de productos consiste en asociar una incertidumbre al mismo que informe al usuario final sobre su precisión y exactitud. Se trata de un proceso de evaluación que además permite mejorar los algoritmos desarrollados para derivar dichos productos.

El objetivo principal de esta tesis doctoral ha sido el desarrollar una metodología que permita la caracterización espacial a alta resolución de los parámetros biofísicos, LAI, FVC y FAPAR a partir de medidas *in-situ*, para su uso como verdad-terreno en la validación directa de productos biofísicos. Por otra parte, se ha llevado a cabo la validación indirecta de los productos de baja resolución para toda la Península Ibérica.