



Universidad de Oviedo

Programa de Doctorado en Biogeociencias

Identificación y seguimiento de sumideros de carbono orgánico en  
suelos afectados por incendios forestales en el suroccidente de Asturias  
usando imágenes de satélite y de sensores aerotransportados, datos de  
campo y laboratorio

TESIS DOCTORAL

Juan José Peón García

Directoras:

Dra. María del Carmen Recondo González

Dra. Susana del Carmen Fernández Menéndez

2019



## RESUMEN DEL CONTENIDO DE TESIS DOCTORAL

1.- Título de la Tesis	
Español/Otro Idioma: Identificación y seguimiento de sumideros de carbono orgánico en suelos afectados por incendios forestales en el Suroccidente de Asturias usando imágenes de satélite y de sensores aerotransportados, datos de campo y laboratorio	Inglés: Identification and monitoring of organic carbon stocks in soils affected by wildfires in southwestern Asturias using satellite imagery and airborne sensors, field and laboratory data
2.- Autor	
Nombre: Juan José Peón García	DNI/Pasaporte/NIE: -Q
Programa de Doctorado: Biogeociencias	
Órgano responsable: Centro Internacional de Postgrado	

### RESUMEN (en español)

El carbono orgánico es un componente esencial de la materia orgánica del suelo. La medida de las reservas del carbono a distintas escalas es todavía un reto en la actualidad, debido principalmente a su elevada variabilidad espacial y temporal. La aplicación de los métodos tradicionales para cartografiar las reservas de carbono, basados en el análisis de muestras puntuales de suelo, es cara y requiere mucho tiempo, debido al gran número de muestras necesarias para capturar la gran variabilidad del carbono. Surge por lo tanto la necesidad de desarrollar métodos para cuantificar las reservas de carbono de forma rápida, precisa y con un coste inferior al de los métodos tradicionales. En esta tesis se evalúa la posibilidad de la espectroscopía y la teledetección en la región espectral del óptico (400–2500 nm) para estimar el carbono orgánico del suelo en zonas forestales quemadas del suroccidente de Asturias.

En los últimos años se ha utilizado de forma creciente la espectroscopía para estimar en el laboratorio el carbono de muestras puntuales de suelo, con una precisión a menudo comparable a la obtenida con los métodos convencionales de análisis químico. En la tesis se ha utilizado la espectroscopía para estimar el carbono orgánico en muestras puntuales de suelo en el laboratorio y se ha demostrado el gran potencial de esta técnica. El uso de la espectroscopía en la tesis ha sido fundamental, dado que ha permitido establecer un puente entre los datos de laboratorio y los de teledetección.

El uso de técnicas de teledetección (con imágenes de satélite o de sensores aerotransportados) puede resultar muy útil para estimar la distribución espacial y temporal de las reservas de carbono a una escala regional. Sin embargo, la teledetección ha sido escasamente utilizada para estimar el carbono orgánico del suelo debido a múltiples limitaciones, entre las que se encuentran la absorción y dispersión atmosférica, la mezcla espectral y la relativamente baja relación señal-ruido de los sensores. Debido a estas limitaciones, los trabajos de teledetección para estimar el carbono del suelo se han restringido principalmente a zonas agrícolas y se han basado generalmente en el uso de sensores hiperespectrales (con decenas o cientos de bandas), que son los sensores de teledetección más afines a los utilizados en espectroscopía. En esta tesis se ha investigado el uso de distintos sensores y técnicas estadísticas para estimar el carbono del suelo en zonas forestales



quemadas, que reúnen unas condiciones mucho más desfavorables (orografía, presencia de vegetación, etc.) que las de las zonas agrícolas en las que se han realizado la gran mayoría de los trabajos previos de otros autores.

Una de las principales contribuciones de esta tesis ha sido la evaluación de las características espectrales de cinco sensores aeroportados o desde satélite para la estimación del carbono orgánico del suelo, tres de estos sensores hiperespectrales (CASI, AHS e Hyperion) y dos multispectrales (Landsat-TM5 y MODIS). Los resultados mostraron que el sensor con mayor potencial para estimar este carbono del suelo fue el AHS. Otra contribución de la tesis ha sido el análisis de la posibilidad de transferir los modelos de predicción de carbono del suelo obtenidos en el laboratorio a imágenes del sensor AHS, para obtener estimaciones de carbono del suelo del área de estudio. La principal aportación de la tesis ha sido el desarrollo de algoritmos para estimar el carbono orgánico del suelo a escala de teledetección usando índices espectrales y técnicas estadísticas más sencillas que las utilizadas habitualmente. Estos algoritmos se probaron en imágenes AHS e Hyperion de zonas forestales quemadas y se obtuvo una precisión comparable o incluso mejor que la obtenida con los métodos utilizados habitualmente. Los algoritmos desarrollados en la tesis son por lo tanto más sencillos que los utilizados previamente, y también más precisos, incluso en zonas con unas condiciones más desfavorables.

### **RESUMEN (en inglés)**

Organic carbon is an essential component of soil organic matter. Currently, the measurement of soil carbon stocks at different scales still remains a challenge, mainly due to its high spatial and temporal variability. The application of traditional methods for estimating soil carbon stocks, based on the analysis of point soil samples, is expensive and time-consuming because of the large number of samples required to capture the high variability of soil carbon. Hence, the need arises to develop methods to quantify carbon stocks quickly, accurately and cheaper than using traditional methods. In this thesis, it has been evaluated the possibility of using spectroscopy and optical remote sensing (400–2500 nm) to estimate soil organic carbon in burned forest areas located in southwestern Asturias.

In recent years, spectroscopy has been increasingly used to estimate the carbon content of point soil samples in the laboratory, with an accuracy often similar to conventional methods of chemical analysis. In this thesis, spectroscopy has been used to estimate the organic carbon content of point soil samples in the laboratory and the great potential of this technique has been proven. Spectroscopy has been essential in this thesis, as it has allowed us to build a bridge between laboratory and remote sensing data.

Remote sensing techniques (with airborne or satellite images) may be very useful to estimate the carbon stocks spatially and temporally, at a regional scale. However, remote sensing has rarely been used to estimate soil organic carbon due to several limitations, including atmospheric absorption and scattering, spectral mixing, and the relatively low signal-to-noise ratio of the sensors. Because of these limitations, remote sensing studies for estimating soil carbon have been restricted mainly to agricultural areas and have been usually based on hyperspectral sensors (with tens or hundreds of spectral bands), which are the remote sensing sensors most similar to those used in spectroscopy. This thesis has investigated the use of different sensors and statistical techniques to estimate soil carbon in burned forest areas, which have much more unfavourable conditions (orography, presence of vegetation, etc.) than agricultural areas where most of the previous studies have been carried out.

One of the main contributions of this thesis has been the evaluation of the spectral



Universidad de Oviedo  
*Universidá d'Uviéu*  
*University of Oviedo*

characteristics of five airborne or satellite sensors for estimating soil organic carbon, three of them were hyperspectral (CASI, AHS and Hyperion) and two multispectral (Landsat- TM5 and MODIS). AHS showed the greatest potential to estimate soil organic carbon. Another contribution of this thesis has been the analysis of the possibility of transferring the soil carbon prediction models obtained in the laboratory to images of the AHS sensor, in order to obtain soil carbon estimates of the study area. The main contribution of this thesis has been the development of algorithms to estimate soil organic carbon at a remote sensing scale using spectral indices and simpler statistical techniques than those commonly used. These algorithms were tested on AHS and Hyperion images of burned forest areas and obtained similar or even better accuracy than commonly used methods. The algorithms developed in this thesis are therefore simpler than previously used algorithms and more accurate too, even in areas with more unfavourable conditions.

**SR. PRESIDENTE DE LA COMISIÓN ACADÉMICA DEL PROGRAMA DE DOCTORADO EN BIOGEOCIENCIAS**



## FORMULARIO RESUMEN DE TESIS POR COMPENDIO

1.- Datos personales solicitante	
Apellidos: Peón García	Nombre: Juan José

Curso de inicio de los estudios de doctorado en <b>Biogeociencias</b>	2017- 2018
---	---------------

	SI	NO
Acompaña acreditación por el Director de la Tesis de la aportación significativa del doctorando	X	

**Acompaña memoria que incluye**

Introducción justificativa de la unidad temática y objetivos	X	
Copia completa de los trabajos *	X	
Resultados/discusión y conclusiones	X	
Informe con el factor de impacto de la publicaciones	X	

Se acompaña aceptación de todos y cada uno de los coautores a presentar el trabajo como tesis por compendio	X	
Se acompaña renuncia de todos y cada uno de los coautores a presentar el trabajo como parte de otra tesis de compendio	X	

\* Ha de constar el nombre y adscripción del autor y de todos los coautores así como la referencia completa de la revista o editorial en la que los trabajos hayan sido publicados o aceptados en cuyo caso se aportará justificante de la aceptación por parte de la revista o editorial

FOR-MAT-VOA-033

### Artículos, Capítulos, Trabajos

#### Trabajo, Artículo 1

Título (o título abreviado)
Fecha de publicación
Fecha de aceptación
Inclusión en Science Citation Index o bases relacionadas por la CNEAI (indíquese)
Factor de impacto

Evaluation of the spectral characteristics of five hyperspectral and multispectral sensors for soil organic carbon estimation in burned areas
28 de febrero de 2017
31 de enero de 2017
SCI
2.445

Coautor2 ■ Doctor □ No doctor . Indique nombre y apellidos
Coautor3 ■ Doctor □ No doctor . Indique nombre y apellidos
Coautor4 ■ Doctor □ No doctor . Indique nombre y apellidos
Coautor5 □ Doctor □ No doctor . Indique nombre y apellidos

Susana Fernández Menéndez
Carmen Recondo González
Javier Fernández Calleja



Coautor6  Doctor  No doctor . Indique nombre y apellidos  
 Coautor7  Doctor  No doctor . Indique nombre y apellidos

Título (o título abreviado)
Fecha de publicación
Fecha de aceptación
Inclusión en Science Citation Index o bases relacionadas por la CNEAI (indíquese)
Factor de impacto

Coautor2  Doctor  No doctor . Indique nombre y apellidos  
 Coautor3  Doctor  No doctor . Indique nombre y apellidos  
 Coautor4  Doctor  No doctor . Indique nombre y apellidos  
 Coautor5  Doctor  No doctor . Indique nombre y apellidos  
 Coautor6  Doctor  No doctor . Indique nombre y apellidos  
 Coautor7  Doctor  No doctor . Indique nombre y apellidos

Título (o título abreviado)
Fecha de publicación
Fecha de aceptación
Inclusión en Science Citation Index o bases relacionadas por la CNEAI (indíquese)
Factor de impacto

Coautor2  Doctor  No doctor . Indique nombre y apellidos  
 Coautor3  Doctor  No doctor . Indique nombre y apellidos  
 Coautor4  Doctor  No doctor . Indique nombre y apellidos  
 Coautor5  Doctor  No doctor . Indique nombre y apellidos  
 Coautor6  Doctor  No doctor . Indique nombre y apellidos  
 Coautor7  Doctor  No doctor . Indique nombre y apellidos

Título (o título abreviado)
Fecha de publicación
Fecha de aceptación


**Trabajo, Artículo 2**

Spatial modelling of organic carbon in burned mountain soils using hyperspectral images, field datasets, and NIR spectroscopy (Cantabrian Range; NW Spain)
3 de julio de 2016
7 de septiembre de 2015
SCI
9.787

Susana Fernández Menéndez  
 Carmen Recondo González  
 Javier Fernández Calleja  
 César Guerrero Maestre

**Trabajo, Artículo 3**

Prediction of topsoil organic carbon using airborne and satellite hyperspectral imagery
24 de noviembre de 2017
21 de noviembre de 2017
SCI
3.406

Carmen Recondo González  
 Susana Fernández Menéndez  
 Javier Fernández Calleja  
 Eduardo De Miguel Llanes  
 Laura Carretero Medina

**Trabajo, Artículo 4**




Inclusión en Science Citation Index o bases relacionadas por la CNEAI (indíquese)
---

Factor de impacto
-------------------

Coautor2 <input type="checkbox"/> Doctor <input type="checkbox"/> No doctor . Indique nombre y apellidos
--

Coautor3 <input type="checkbox"/> Doctor <input type="checkbox"/> No doctor . Indique nombre y apellidos
--

Coautor4 <input type="checkbox"/> Doctor <input type="checkbox"/> No doctor . Indique nombre y apellidos
--

Coautor5 <input type="checkbox"/> Doctor <input type="checkbox"/> No doctor . Indique nombre y apellidos
--

Coautor6 <input type="checkbox"/> Doctor <input type="checkbox"/> No doctor . Indique nombre y apellidos
--

Coautor7 <input type="checkbox"/> Doctor <input type="checkbox"/> No doctor . Indique nombre y apellidos
--

Título (o título abreviado)
-----------------------------

Fecha de publicación
----------------------

Fecha de aceptación
---------------------

Inclusión en Science Citation Index o bases relacionadas por la CNEAI (indíquese)
---

Factor de impacto
-------------------

Coautor2 <input type="checkbox"/> Doctor <input type="checkbox"/> No doctor . Indique nombre y apellidos
--

Coautor3 <input type="checkbox"/> Doctor <input type="checkbox"/> No doctor . Indique nombre y apellidos
--

Coautor4 <input type="checkbox"/> Doctor <input type="checkbox"/> No doctor . Indique nombre y apellidos
--

Coautor5 <input type="checkbox"/> Doctor <input type="checkbox"/> No doctor . Indique nombre y apellidos
--

Coautor6 <input type="checkbox"/> Doctor <input type="checkbox"/> No doctor . Indique nombre y apellidos
--

Coautor7 <input type="checkbox"/> Doctor <input type="checkbox"/> No doctor . Indique nombre y apellidos
--

Título (o título abreviado)
-----------------------------

Fecha de publicación
----------------------

Fecha de aceptación
---------------------

Inclusión en Science Citation Index o bases relacionadas por la CNEAI (indíquese)
---

Factor de impacto
-------------------

Coautor2 <input type="checkbox"/> Doctor <input type="checkbox"/> No doctor . Indique nombre y apellidos
--

Coautor3 <input type="checkbox"/> Doctor <input type="checkbox"/> No doctor . Indique nombre y apellidos
--

Coautor4 <input type="checkbox"/> Doctor <input type="checkbox"/> No doctor . Indique nombre y apellidos
--

Coautor5 <input type="checkbox"/> Doctor <input type="checkbox"/> No doctor . Indique nombre y apellidos
--

Coautor6 <input type="checkbox"/> Doctor <input type="checkbox"/> No doctor . Indique nombre y apellidos
--

Coautor7 <input type="checkbox"/> Doctor <input type="checkbox"/> No doctor . Indique nombre y apellidos
--

**Trabajo, Artículo 5**

**Trabajo, Artículo 6**





## Agradecimientos

En estas líneas me gustaría transmitir mi más profundo y sincero agradecimiento a todas aquellas personas que me han ayudado y acompañado a lo largo de estos años y que, de una forma u otra, han sido de gran importancia para la culminación de este trabajo.

En primer lugar, me gustaría dar las gracias a mis directoras de tesis. A Carmen, por su dedicación durante todos estos años, por su ayuda y por haberme descubierto el mundo de la teledetección que tanto me ha dado. A Susana, por su apoyo y sus consejos, por darme libertad e independencia para crecer y evolucionar, por ser una fuente inagotable de inspiración y por su pasión por la ciencia.

A Javi, por creer en mí y ayudarme siempre que lo he necesitado. Por la autenticidad, frescura y claridad de sus ideas, por animarme y darme fuerzas con su humor y alegría.

A los compañeros del grupo de investigación Remote Sensing Applications, de la Escuela Politécnica de Mieres y del INDUROT, por su apoyo y por haber generado un ambiente de trabajo muy agradable.

A Daniel, Stephanie y toda la gente de VITO y de Boeretang, por su hospitalidad y por haberme hecho sentir como en casa. Por haber hecho posible una estancia tan enriquecedora.

A Eduardo y a Laura del INTA, por acogerme en su laboratorio y ayudarme con el procesamiento de las imágenes hiperespectrales.

A César de la Universidad Miguel Hernández, por su ayuda con la espectroscopía.

Al equipo de ESA-ESRIN, por la formación recibida en la escuela de verano y por darme la oportunidad de aprender con tan buena compañía. Y a los compañeros de la escuela de verano, por todos los momentos que compartimos en Frascati.

Gracias a mi familia y mis amigos, que han sido un pilar fundamental durante todo este tiempo y sin los que nada de esto habría sido posible.

A mis padres y a mi hermano, por el apoyo incondicional y por haber creído siempre en mí. Por tantísimas cosas.

A Ana, por acompañarme en tantas etapas de mi vida, por animarme permanentemente y apoyarme hasta el final.

A todos mis amigos y compañeros de viajes, por devolverme el buen humor y por todas las aventuras y buenos momentos que hemos vivido. A Alexis, Ástor y todos los topógrafos de Malta, por recibirme siempre con los brazos abiertos. A Cecilia, por su fuerza y por recordarme desde la distancia lo que es importante de verdad.

A Ángel, por estar siempre ahí, por compartir sueños e ilusiones y por ser un apoyo fundamental durante estos años. Por hacerme sentir que Santander y Zaragoza son mi segunda casa. Por su forma de ver la vida, con los pies en la tierra y la mente en Marte.

A todos los que me han dado impulso y ánimo y han hecho que este camino haya sido más fácil. A todos, gracias.

# Índice

Resumen.....	1
Abstract.....	3
Capítulo I. Introducción y objetivos .....	5
1.1. El carbono del suelo y los incendios.....	5
1.2. Estimación del carbono del suelo mediante espectroscopía .....	7
1.3. Estimación del carbono del suelo mediante teledetección.....	11
1.4. Área de estudio .....	16
1.5. Datos utilizados.....	20
1.5.1. Datos de campo.....	20
1.5.2. Datos de laboratorio.....	21
1.5.3. Datos hiperespectrales de sensores aeroportados .....	23
1.5.4. Datos hiperespectrales de satélite .....	26
1.6. Preguntas de investigación e hipótesis.....	29
1.7. Objetivos.....	30
Capítulo II. Resultados y discusión .....	33
2.1. Análisis químico de las muestras de suelo.....	33
2.2. Estimación del carbono del suelo mediante espectroscopía .....	34
2.2.1. Técnica PLSR y validación cruzada .....	34
2.2.2. Modelos PLSR para estimar el carbono del suelo y regiones del espectro más importantes para la predicción.....	36
2.3. Identificación de los sensores de teledetección más adecuados para estimar el carbono del suelo .....	41
2.3.1. Método para identificar los sensores más adecuados para estimar el carbono del suelo. Remuestreo de los espectros de laboratorio .....	41
2.3.2. Modelos PLSR para estimar el carbono del suelo usando los espectros de laboratorio remuestreados .....	44

2.3.3. Comparación de los modelos PLSR basados en los espectros de laboratorio remuestreados con otros modelos de predicción del carbono del suelo .....	47
2.4. Estimación del carbono del suelo con el sensor AHS usando espectroscopía.....	50
2.4.1. Modelos PLSR para estimar el carbono del suelo usando los espectros de laboratorio remuestreados para el sensor AHS .....	50
2.4.2. Transferencia de los modelos de espectroscopía de laboratorio a la imagen AHS y obtención de mapas de carbono .....	53
2.5. Estimación del carbono del suelo con los sensores AHS e Hyperion usando índices espectrales .....	58
2.5.1. Obtención de índices espectrales de diferencia normalizada.....	58
2.5.2. Correlación entre el carbono y las reflectividades e índices espectrales .....	59
2.5.3. Obtención de los modelos para estimar el carbono del suelo usando el sensor AHS .....	63
2.5.4. Obtención de los modelos para estimar el carbono del suelo usando el sensor Hyperion .....	64
2.5.5. Modelos para estimar el carbono del suelo usando AHS e Hyperion.....	65
2.5.6. Longitudes de onda importantes para la estimación del carbono .....	69
2.5.7. Mapas del carbono orgánico del suelo.....	71
2.5.8. Comparación de los modelos SMLR basados en índices con otros modelos de carbono.....	73
Capítulo III. Conclusiones .....	77
3.1. Conclusiones.....	77
3.2. Conclusions.....	80
Publicaciones .....	83
Publicación 1. Evaluation of the spectral characteristics of five hyperspectral and multispectral sensors for soil organic carbon estimation in burned areas .....	83

Publicación 2. Spatial modelling of organic carbon in burned mountain soils using hyperspectral images, field datasets, and NIR spectroscopy (Cantabrian Range; NW Spain) .....	95
Publicación 3. Prediction of topsoil organic carbon using airborne and satellite hyperspectral imagery .....	107
Factor de impacto de las publicaciones .....	131
Bibliografía .....	135
Financiación .....	155



## Resumen

El carbono orgánico es un componente esencial de la materia orgánica del suelo. La medida de las reservas del carbono a distintas escalas es todavía un reto en la actualidad, debido principalmente a su elevada variabilidad espacial y temporal. La aplicación de los métodos tradicionales para cartografiar las reservas de carbono, basados en el análisis de muestras puntuales de suelo, es cara y requiere mucho tiempo, debido al gran número de muestras necesarias para capturar la gran variabilidad del carbono. Surge por lo tanto la necesidad de desarrollar métodos para cuantificar las reservas de carbono de forma rápida, precisa y con un coste inferior al de los métodos tradicionales. En esta tesis se evalúa la posibilidad de la espectroscopía y la teledetección en la región espectral del óptico (400–2500 nm) para estimar el carbono orgánico del suelo en zonas forestales quemadas del suroccidente de Asturias.

En los últimos años se ha utilizado de forma creciente la espectroscopía para estimar en el laboratorio el carbono de muestras puntuales de suelo, con una precisión a menudo comparable a la obtenida con los métodos convencionales de análisis químico. En la tesis se ha utilizado la espectroscopía para estimar el carbono orgánico en muestras puntuales de suelo en el laboratorio y se ha demostrado el gran potencial de esta técnica. El uso de la espectroscopía en la tesis ha sido fundamental, dado que ha permitido establecer un puente entre los datos de laboratorio y los de teledetección.

El uso de técnicas de teledetección (con imágenes de satélite o de sensores aeroportados) puede resultar muy útil para estimar la distribución espacial y temporal de las reservas de carbono a una escala regional. Sin embargo, la teledetección ha sido escasamente utilizada para estimar el carbono orgánico del suelo debido a múltiples limitaciones, entre las que se encuentran la absorción y dispersión atmosférica, la mezcla espectral y la relativamente baja relación señal-ruido de los sensores. Debido a estas limitaciones, los trabajos de teledetección para estimar el carbono del suelo se han restringido principalmente a zonas agrícolas y se han basado generalmente en el uso de sensores hiperespectrales (con decenas o cientos de bandas), que son los sensores de teledetección más afines a los utilizados en espectroscopía. En esta tesis se ha investigado el uso de distintos sensores y técnicas estadísticas para estimar el carbono del suelo en zonas forestales quemadas, que reúnen unas condiciones mucho más desfavorables (orografía, presencia de vegetación, etc.) que las de las zonas agrícolas en las que se han realizado la gran mayoría de los trabajos previos de otros autores.

Una de las principales contribuciones de esta tesis ha sido la evaluación de las características espectrales de cinco sensores aeroportados o desde satélite para la estimación del carbono orgánico del suelo, tres de estos sensores hiperespectrales (CASI, AHS e Hyperion) y dos multiespectrales (Landsat-TM5 y MODIS). Los resultados mostraron que el sensor con mayor potencial para estimar este carbono del suelo fue el AHS. Otra contribución de la tesis ha sido el análisis de la posibilidad de transferir los modelos de predicción de carbono del suelo obtenidos en el laboratorio a imágenes del sensor AHS, para obtener estimaciones de carbono del suelo del área de estudio. La principal aportación de la tesis ha sido el desarrollo de algoritmos para estimar el carbono orgánico del suelo a escala de teledetección usando índices espectrales y técnicas estadísticas más sencillas que las utilizadas habitualmente. Estos algoritmos se probaron en imágenes AHS e Hyperion de zonas forestales quemadas y se obtuvo una precisión comparable o incluso mejor que la obtenida con los métodos utilizados habitualmente. Los algoritmos desarrollados en la tesis son por lo tanto más sencillos que los utilizados previamente, y también más precisos, incluso en zonas con unas condiciones más desfavorables.



## **Abstract**

Organic carbon is an essential component of soil organic matter. Currently, the measurement of soil carbon stocks at different scales still remains a challenge, mainly due to its high spatial and temporal variability. The application of traditional methods for estimating soil carbon stocks, based on the analysis of point soil samples, is expensive and time-consuming because of the large number of samples required to capture the high variability of soil carbon. Hence, the need arises to develop methods to quantify carbon stocks quickly, accurately and cheaper than using traditional methods. In this thesis, it has been evaluated the possibility of using spectroscopy and optical remote sensing (400–2500 nm) to estimate soil organic carbon in burned forest areas located in southwestern Asturias.

In recent years, spectroscopy has been increasingly used to estimate the carbon content of point soil samples in the laboratory, with an accuracy often similar to conventional methods of chemical analysis. In this thesis, spectroscopy has been used to estimate the organic carbon content of point soil samples in the laboratory and the great potential of this technique has been proven. Spectroscopy has been essential in this thesis, as it has allowed us to build a bridge between laboratory and remote sensing data.

Remote sensing techniques (with airborne or satellite images) may be very useful to estimate the carbon stocks spatially and temporally, at a regional scale. However, remote sensing has rarely been used to estimate soil organic carbon due to several limitations, including atmospheric absorption and scattering, spectral mixing, and the relatively low signal-to-noise ratio of the sensors. Because of these limitations, remote sensing studies for estimating soil carbon have been restricted mainly to agricultural areas and have been usually based on hyperspectral sensors (with tens or hundreds of spectral bands), which are the remote sensing sensors most similar to those used in spectroscopy. This thesis has investigated the use of different sensors and statistical techniques to estimate soil carbon in burned forest areas, which have much more unfavourable conditions (orography, presence of vegetation, etc.) than agricultural areas where most of the previous studies have been carried out.

One of the main contributions of this thesis has been the evaluation of the spectral characteristics of five airborne or satellite sensors for estimating soil organic carbon, three of them were hyperspectral (CASI, AHS and Hyperion) and two multispectral (Landsat- TM5 and MODIS). AHS showed the greatest potential to estimate soil organic carbon. Another

contribution of this thesis has been the analysis of the possibility of transferring the soil carbon prediction models obtained in the laboratory to images of the AHS sensor, in order to obtain soil carbon estimates of the study area. The main contribution of this thesis has been the development of algorithms to estimate soil organic carbon at a remote sensing scale using spectral indices and simpler statistical techniques than those commonly used. These algorithms were tested on AHS and Hyperion images of burned forest areas and obtained similar or even better accuracy than commonly used methods. The algorithms developed in this thesis are therefore simpler than previously used algorithms and more accurate too, even in areas with more unfavourable conditions.

## Capítulo I. Introducción y objetivos

### 1.1. El carbono del suelo y los incendios

El suelo contiene la mayor reserva de carbono de la superficie terrestre, con una estimación de 2500 Pg (Lal 2004), de los que 1500–2000 Pg se encuentran en el primer metro de profundidad del suelo (Houghton 2007; Novara *et al.* 2011; Batjes 2016). Casi el 70 % del carbono del suelo es orgánico (Soil Organic Carbon, SOC) (Batjes 1996), dividiéndose en fracciones con diferente tiempo de permanencia en el suelo: formas lábiles activas (días o años), fracciones con actividad intermedia (años o décadas) y materia orgánica refractaria (carbono pirogénico) (siglos o milenios) (Skjemstad *et al.* 1998). Dada la gran cantidad de SOC almacenado en los suelos (el doble del presente en la atmósfera, 760 Pg, y hasta el triple del de los organismos vivos, 560 Pg), pequeñas desviaciones en la proporción de las fracciones citadas pueden tener efectos significativos en el balance global del carbono y afectar al clima (Lal 2004; Smith *et al.* 2014).

El carbono orgánico es un componente esencial de la materia orgánica del suelo (Soil Organic Matter, SOM) que desempeña una función importante en las propiedades físicas y químicas del suelo, afectando a la densidad, disponibilidad de nutrientes, estabilidad estructural, conductividad y biodiversidad del suelo (Trumbore y Czimczik 2008). Las reservas de carbono orgánico del suelo son esenciales para el control del clima mediante la regulación de los flujos de C y N y dan soporte a la producción primaria de los ecosistemas (Brevik *et al.* 2015). En un ecosistema sin alterar como un bosque, la cantidad de carbono del suelo es estable a lo largo del tiempo. La mineralización del carbono del suelo se equilibra mediante la producción de materia orgánica (Novara *et al.* 2011) y la mayor parte del carbono se almacena como materia orgánica parcialmente descompuesta (Schulze *et al.* 2000).

En general, la evolución y las transformaciones de la materia orgánica son resultado de la actividad microbiana (Guénon *et al.* 2013; Wang *et al.* 2015), pero también pueden ser originadas por transformaciones abióticas inducidas por factores externos, entre los que se encuentra principalmente el fuego (Hatcher y Spiker 1988; Certini 2005; Santín y Doerr 2016). Es ampliamente aceptado que el fuego causa alteraciones en las propiedades físicas, químicas y biológicas del suelo (Neary *et al.* 1999; Knicker 2007; Mataix-Solera y Guerrero 2007; Úbeda y Outeiro 2009). Los efectos del fuego en la cantidad y la concentración del carbono orgánico del suelo que se han observado en distintos estudios son muy diversos (Santín y

Doerr 2019), desde estudios en los que no se encontraron diferencias notables en la cantidad de carbono orgánico del suelo tras el fuego (Alexis *et al.* 2007; Novara *et al.* 2013), hasta otros en los que se observó un incremento (De la Rosa *et al.* 2012; Francos *et al.* 2018) o una disminución sustancial (Badía *et al.* 2014). Los efectos que produce el fuego en la cantidad del carbono orgánico del suelo varían, entre otros, con la temperatura del fuego, el tiempo transcurrido desde el mismo y la profundidad y humedad del suelo; lo que explicaría la gran diversidad de efectos observados en los distintos estudios (Santín y Doerr 2019). En lo relativo a la materia orgánica del suelo, los incendios conducen a la transformación de los compuestos lábiles en formas orgánicas recalcitrantes (González-Pérez *et al.* 2004), que contribuyen al secuestro prolongado de C y N en el suelo (Kuhlbusch y Crutzen 1995; Schmidt y Noack 2000).

Anualmente se queman en torno a 0.4 millones de hectáreas en el mundo (Andela *et al.* 2017). Los incendios forestales en la región atlántica de España tienen una elevada recurrencia (Álvarez y Marquínez 2007). En la parte occidental de la Cordillera Cantábrica, el uso del fuego durante milenios ha modificado la cubierta vegetal (Díaz González y Fernández 1994) y ha promovido transformaciones intensas del suelo. Investigaciones previas en esta región concluyeron que los incendios influyen en las tasas de secuestro de SOC, con un contenido de 32 Mg/ha medido en suelos no quemados y 90 Mg/ha en suelos quemados (Fernández-Menéndez *et al.* 2011). Los incendios han contribuido a la acumulación de materia orgánica en los suelos de esta región (Santín *et al.* 2008). El mayor contenido de materia orgánica en los suelos quemados se podría atribuir a la incorporación de necromasa procedente de la vegetación parcialmente carbonizada y al aumento de la producción de mantillo y la disminución de la tasa de mineralización del carbono tras el fuego (Fernández *et al.* 1999; González-Pérez *et al.* 2004; Knicker *et al.* 2005; Santín *et al.* 2008). Los incendios alteran el carbono orgánico del suelo, pero la cantidad y distribución de la materia orgánica del suelo en el paisaje depende no solo de las pérdidas por combustión y los aportes de los materiales calcinados (Knicker *et al.* 2005), sino también de la erosión post-incendio, los procesos de sedimentación y la redistribución en el paisaje (Rumpel *et al.* 2006).

El aumento de la erosión tras los incendios ha sido ampliamente documentado (Wondzell y King 2003; Shakesby y Doerr 2006). Varios procesos están involucrados en la erosión post-incendio, principalmente erosión hídrica, y causan la pérdida de la materia orgánica del suelo (Canfield *et al.* 2005; Rumpel *et al.* 2006; Shakesby y Doerr 2006). Aunque la recuperación

de la cubierta vegetal no es completa en áreas de elevada recurrencia de incendios (Fernández *et al.* 2005; Marquínez *et al.* 2008), la rápida recuperación de la vegetación debida a las características del clima atlántico dificulta el seguimiento de los suelos afectados por incendios.

La medida de las reservas del carbono del suelo a distinta escala espacial y temporal es un reto todavía (Lal 2009; Vaudour *et al.* 2016). En este sentido, es necesario el desarrollo de métodos precisos para mejorar la estimación de las reservas de carbono edáfico (Burras *et al.* 2001), su distribución espacial y su dinámica temporal (Saiano *et al.* 2013; Sreenivas *et al.* 2016). Los métodos tradicionales para cartografiar las reservas de carbono edáfico están basados en la toma y análisis de muestras de suelo, la calibración de una función de predicción y la interpolación de la función al área de estudio (Minasny *et al.* 2013). La aplicación de estos métodos es cara y requiere mucho tiempo debido al gran número de muestras necesarias para capturar la gran variabilidad espacial del carbono del suelo (Ellert *et al.* 2001; Stevens *et al.* 2010).

En esta tesis se evalúa el potencial de distintas técnicas para estimar el carbono orgánico del suelo en zonas quemadas de montaña del suroccidente de Asturias, en las que el reiterado uso del fuego durante milenios ha alterado la materia orgánica y el carbono orgánico del suelo.

## **1.2. Estimación del carbono del suelo mediante espectroscopía**

La medida del carbono del suelo usando métodos estándar de laboratorio, como la oxidación química (Walkley y Black 1934) y la combustión en seco (Heiri *et al.* 2001), involucra procedimientos costosos. La espectroscopía de reflectividad difusa en el visible (VIS, 400–700 nm), infrarrojo próximo o cercano (Near-Infrared, NIR, 700–1300 nm) e infrarrojo medio de onda corta (Short-Wave Infrared, SWIR, 1300–2500 nm) ofrece una alternativa a los métodos tradicionales de laboratorio para la estimación del carbono. Actualmente la espectroscopía se considera una técnica precisa, rápida y no destructiva para predecir no solo el contenido en carbono, sino también un amplio rango de propiedades del suelo (Viscarra Rossel *et al.* 2006b; Gehl y Rice 2007).

La estimación del carbono del suelo mediante espectroscopía se basa en el uso de espectros continuos de reflectividad del suelo, formados a menudo por miles de lecturas (habitualmente con un intervalo de muestreo de 1 nm). Para la obtención de estos espectros se hace incidir radiación electromagnética con longitudes de onda en la región del óptico (VIS–NIR–SWIR,

400–2500 nm) o del infrarrojo medio (Mid-Infrared, MIR, 2500–25000 nm) sobre las muestras de suelo. Esta radiación provoca vibraciones fundamentales de los enlaces químicos, como O–H, C–H y N–H, de los compuestos presentes en la muestra (Guerrero *et al.* 2007). Dado que la radiación es absorbida de acuerdo a la distinta concentración de estos compuestos, los espectros de reflectividad resultantes presentan una forma característica que puede ser utilizada para analizar la composición de la muestra (Stenberg *et al.* 2010).

Las vibraciones fundamentales de los grupos funcionales químicos se localizan en la región del MIR, mientras que el NIR–SWIR se caracteriza por la presencia de sobretonos y combinaciones de estas vibraciones fundamentales, y el VIS está dominado por absorciones debidas a transiciones electrónicas. Los sobretonos y combinaciones de vibraciones fundamentales presentes en el NIR–SWIR se solapan, lo que hace que la interpretación cuantitativa y cualitativa de los espectros sea más complicada en esta región que en el MIR, donde es posible realizar una interpretación directa al producirse en el MIR las vibraciones fundamentales (Janik *et al.* 1998; Guerrero *et al.* 2007).

A pesar de la dificultad para la interpretación de los espectros en la región VIS–NIR–SWIR, es posible obtener mucha información de las propiedades del suelo utilizando espectros medidos en esta región. La respuesta espectral del suelo en el visible se caracteriza por amplias bandas de absorción que controlan el color del suelo (Owen 2000; Nocita *et al.* 2015). Algunas propiedades del suelo como el contenido en carbono orgánico, el contenido en hierro y la textura han mostrado altas correlaciones con el color (Viscarra Rossel *et al.* 2006a). Los suelos con mayor contenido en materia orgánica son en general más oscuros (Schulze *et al.* 1993). Por otro lado, en la región NIR–SWIR la respuesta espectral del suelo se caracteriza por absorciones bien definidas asociadas al agua (1455 y 1915 nm) y a minerales de arcilla (1415 y 2207 nm) (Ben-Dor *et al.* 1997; Nocita *et al.* 2015). La respuesta espectral en esta región se asocia también a los grupos funcionales C–H, C–O y C–N que dominan la materia orgánica (Soriano-Disla *et al.* 2014). En general, la reflectividad en el NIR–SWIR disminuye a mayor contenido en agua y materia orgánica (Nocita *et al.* 2015).

Los espectros de reflectividad del suelo en la región VIS–NIR–SWIR se caracterizan por patrones de absorción complejos, causados por el solape de las múltiples absorciones de los distintos componentes del suelo. Esta complejidad hace que no sea posible la interpretación directa de los espectros como ocurre en la región del MIR, y que resulte necesario el uso de técnicas del ámbito de la quimiometría para extraer la información contenida en los espectros.

La quimiometría es una disciplina que utiliza métodos matemáticos y estadísticos para el tratamiento de datos químicos (Kowalski 1980; Viscarra Rossel 2008). Tiene un carácter interdisciplinar y se utiliza habitualmente en el campo de la espectroscopía (Geladi 2003). La predicción de las propiedades del suelo se realiza mediante el uso de métodos de calibración empíricos, basados en la relación existente entre los espectros de reflectividad de las muestras de suelo y los resultados del análisis químico de las mismas obtenidos mediante métodos estándar de laboratorio.

En espectroscopía, la predicción de propiedades del suelo, entre las que se incluye el contenido en carbono y materia orgánica, se basa usualmente en técnicas estadísticas multivariantes o en métodos de minería de datos, como la regresión lineal múltiple (Multiple Linear Regression, MLR) (Dalal y Henry 1986; Vasques *et al.* 2008), la regresión de componentes principales (Principal Component Regression, PCR) (Chang *et al.* 2001; Islam *et al.* 2003), árboles de regresión (Vasques *et al.* 2009), máquinas de soporte vectorial (Support Vector Machine Regression, SVMR) (Vohland *et al.* 2011) y redes neuronales artificiales (Artificial Neural Networks, ANN) (Viscarra Rossel y Behrens 2010). La regresión de mínimos cuadrados parciales (Partial Least-Squares Regression, PLSR) es una de las técnicas más utilizadas, principalmente porque es capaz de manejar la multicolinealidad existente en los espectros de reflectividad y es una técnica robusta en términos del ruido de los datos (Viscarra Rossel *et al.* 2006b; Viscarra Rossel y Behrens 2010).

El contenido en carbono del suelo ha sido estimado satisfactoriamente mediante espectroscopía en el VIS–NIR–SWIR y MIR. Soriano-Disla *et al.* (2014) compararon múltiples trabajos para la estimación de propiedades del suelo mediante espectroscopía y observaron valores elevados de  $R^2$  en las validaciones, tanto para el carbono orgánico (cuya mediana fue  $R^2 = 0.83$  usando espectros en el VIS–NIR–SWIR y  $R^2 = 0.93$  en el MIR), como para el carbono total (cuya mediana fue  $R^2 = 0.89$  en el VIS–NIR–SWIR y  $R^2 = 0.93$  en el MIR). Los resultados son similares a los obtenidos en otra comparación de distintos trabajos realizada anteriormente por Viscarra Rossel *et al.* (2006b), en la que observaron los siguientes valores medios de  $R^2$  en la predicción del carbono orgánico del suelo y la materia orgánica:  $R^2 = 0.78$  usando espectros en el VIS,  $R^2 = 0.81$  en el NIR–SWIR y  $R^2 = 0.96$  en el MIR. Aunque en general los resultados de la predicción son mejores usando espectroscopía en el MIR que en el VIS–NIR–SWIR, las medidas en el MIR requieren instrumentación más compleja y cara (Viscarra Rossel *et al.* 2006b) y también un mayor pretratamiento de las

muestras (Guerrero *et al.* 2007). Debido a ello, se utiliza habitualmente la espectroscopía en el VIS–NIR–SWIR para predecir el contenido en carbono, como un compromiso entre la precisión de los resultados y el coste de la tecnología.

La espectroscopía en el VIS–NIR–SWIR se utiliza en el laboratorio para estimar el contenido en carbono del suelo desde la década de 1980, si bien el mayor desarrollo se produce en los últimos años. En la Tabla 1 (resultado de la revisión bibliográfica realizada para la elaboración de esta tesis e incluidos también los resultados de ésta para su comparación) se muestra una lista de trabajos en los que se ha utilizado la espectroscopía en el VIS–NIR–SWIR para predecir el contenido en carbono orgánico y carbono total del suelo, empleando principalmente la técnica de modelización de PLSR. La validación obtenida en estos trabajos ha sido generalmente satisfactoria, con valores de  $R^2$  típicamente en el rango 0.80–0.95 y errores comparables a los obtenidos en el laboratorio; lo que ha favorecido la consolidación de la espectroscopía en el VIS–NIR–SWIR como una alternativa a los métodos estándar de análisis químico en el laboratorio. A pesar del gran desarrollo de la espectroscopía en los últimos años, cabe mencionar que ésta no reemplaza completamente a los métodos tradicionales de análisis químico de laboratorio, en la medida que resulta indispensable el uso de estos métodos para la calibración inicial de los modelos de predicción utilizados en espectroscopía.

Aunque la mayoría de los estudios previos para la estimación del carbono del suelo con espectroscopía se han centrado en la estimación del carbono total, son de gran interés también otros trabajos más recientes en los que el carbono del suelo se ha separado en fracciones con distinto tiempo de permanencia en el suelo. En esta línea, Vasques *et al.* (2009) estimaron de forma precisa formas lábiles de carbono orgánico y carbono recalcitrante usando la técnica de PLSR.

En esta tesis se evalúa el potencial de la espectroscopía de laboratorio en el VIS–NIR–SWIR en combinación con técnicas de estadística multivariante como el PLSR, para la estimación del carbono orgánico total (Total Organic Carbon, TOC) y la fracción de carbono oxidable (Oxidizable Carbon, OC) de muestras de suelo de zonas quemadas de montaña del suroccidente de Asturias.



Tabla 1. Estudios previos y los obtenidos en esta tesis para la estimación del carbono orgánico y carbono total del suelo usando espectroscopía VIS–NIR–SWIR en el laboratorio.

Propiedad	Rango espectral <sup>a</sup>	Técnica <sup>b</sup>	n <sub>cal</sub>   n <sub>val</sub> <sup>c</sup>	RMSE <sup>d</sup>	R <sup>2d</sup>	Autores
C orgánico	1100–2500 (NS)	MLR (3)	72 48		0.93	Dalal y Henry (1986)
C orgánico	1100–2300 (NS)	PLSR (8)	174 x-val	0.99 g/kg	0.94	Reeves y McCarty (2001)
C orgánico	400–2498 (VNS)	PLSR (6)	76 32	0.62 g/kg	0.89	Chang y Laird (2002)
C orgánico	1100–2498 (NS)	PLSR	274 x-val		0.75	Martin <i>et al.</i> (2002)
C orgánico	1100–2498 (NS)	PLSR (18)	177 60		0.82	McCarty <i>et al.</i> (2002)
C orgánico	350–2500 (VNS)	PLSR	30 x-val	0.90 g/kg	0.93	Patzold <i>et al.</i> (2008)
C orgánico	350–2500 (VNS)	PLSR (8)	117 x-val	1.2 g/kg		Stevens <i>et al.</i> (2008)
C orgánico	400–2500 (VNS)	PLSR	60 x-val		0.86/0.93	Nduwamungu <i>et al.</i> (2009)
C orgánico	350–2500 (VNS)	PLSR (12)	102 39		0.86	Vasques <i>et al.</i> (2009)
C orgánico	453–2448 (VNS)	PLSR	133 15	0.4 %	0.8	Mouazen <i>et al.</i> (2010)
C orgánico	400–2400 (VNS)	PLSR (8)	75 36	4.40 g/kg	0.88	Nocita <i>et al.</i> (2011)
C orgánico	400–2498 (VNS)	PLSR (16)	200 54		0.85	St. Luce <i>et al.</i> (2012)
C orgánico	401–2423 (VNS)	PLSR	216 54	1.26 %	0.88	Tekin <i>et al.</i> (2012)
C orgánico	400–2350 (VNS)	PLSR	95 x-val	3.11 g/kg	0.75	Jiang <i>et al.</i> (2016)
C total	1100–2498 (NS)	PLSR (7)	120 59	0.89 g/kg	0.96	Reeves <i>et al.</i> (1999)
C total	400–2498 (VNS)	PLSR (5)	76 32	0.65 g/kg	0.91	Chang y Laird (2002)
C total	1100–2498 (NS)	PLSR (16)	177 60		0.86	McCarty <i>et al.</i> (2002)
C total	1100–2500 (NS)	PLSR (10)	120 x-val	0.72 g/kg	0.99	Madari <i>et al.</i> (2006)
C total	400–2500 (VNS)	PLSR	60 x-val		0.79/0.96	Nduwamungu <i>et al.</i> (2009)
C total	400–2500 (VNS)	PLSR (7)	109 40	0.18 %	0.88	Vohland <i>et al.</i> (2011)
C total	350–2500 (VNS)	PLSR	144 72	0.71 %	0.79	Luca <i>et al.</i> (2017)
C total	400–2450 (VNS)	PLSR (7)	89 x-val	7.01 %	0.78	Peón <i>et al.</i> (2017a)
C oxidable	400–2450 (VNS)	PLSR (9)	89 x-val	3.53 %	0.88	Peón <i>et al.</i> (2017a)

<sup>a</sup> La región espectral se indica entre paréntesis: visible (V, 400-700 nm), infrarrojo cercano (Near-Infrared, N, 700-1300 nm), infrarrojo medio de onda corta (Short-Wave Infrared, S, 1300-2500 nm). <sup>b</sup> Técnica de modelización: regresión lineal múltiple (Multiple Linear Regression, MLR), regresión de mínimos cuadrados parciales (Partial Least-Squares Regression, PLSR). El número de componentes de los modelos PLSR se indica entre paréntesis. <sup>c</sup> n<sub>cal</sub>|n<sub>val</sub> indica el número de muestras usadas en la calibración y en la validación, respectivamente. “x-val” indica que la validación se ha realizado usando el método de validación cruzada. <sup>d</sup> Coeficiente de determinación (R<sup>2</sup>) y error cuadrático medio (Root-Mean-Square Error, RMSE) de la validación.

### 1.3. Estimación del carbono del suelo mediante teledetección

El uso de técnicas de teledetección, ya sea con imágenes de satélite o de sensores aeroportados (o aerotransportados), puede resultar muy útil para estimar la distribución espacial y temporal de las reservas de carbono del suelo a una escala regional. La teledetección ha demostrado ser un medio rápido y reproducible para proporcionar estimaciones cuantitativas de propiedades

edáficas (Irons *et al.* 1989). Permite realizar estimaciones espacio-temporales de las cubiertas terrestres y las prácticas de manejo de la tierra que tienen un impacto en la dinámica del carbono del suelo (Gehl y Rice 2007). Aunque la teledetección se ha utilizado ampliamente para cartografiar los tipos de suelo, se ha utilizado en menor medida para la cuantificación directa de propiedades de la superficie del suelo, como el contenido en carbono y materia orgánica; debido a varios factores limitantes, entre los que se encuentran la absorción de la atmósfera que interfiere con la reflectividad del suelo, la variación en las condiciones de iluminación de la zona de estudio, la relativamente baja relación señal-ruido (Signal-To-Noise Ratio, SNR) de los sensores y la mezcla espectral (spectral mixing) o presencia de varias cubiertas dentro de un mismo píxel (Ben-Dor *et al.* 2009; Croft *et al.* 2012). Debido a estas limitaciones, los trabajos previos en los que se cuantifica SOC o SOM de forma directa en la capa superficial del suelo se han restringido principalmente a zonas agrícolas y zonas de suelo desnudo (Ben-Dor *et al.* 2002; Uno *et al.* 2005; Selige *et al.* 2006; Patzold *et al.* 2008; Gomez *et al.* 2012).

La espectroscopía en el VIS–NIR–SWIR, considerada una técnica precisa para estimar el carbono del suelo en el laboratorio, puede ser extendida a una escala regional usando sensores aeroportados o desde satélite que recojan información en el rango espectral VIS–NIR–SWIR. Los sensores utilizados en el ámbito de la teledetección más afines a los empleados en la espectroscopía de laboratorio son los sensores hiperespectrales. Estos sensores se caracterizan por tener un número elevado de bandas estrechas y contiguas (habitualmente del orden de decenas o incluso cientos de bandas), que permiten obtener firmas espectrales continuas de las cubiertas terrestres, similares a las generadas en el laboratorio con un espectrofotómetro. Los sensores hiperespectrales, a pesar de su similitud con los espectrofotómetros de laboratorio que son ampliamente empleados para estimar propiedades del suelo, han sido escasamente utilizados para estimar el carbono y la materia orgánica del suelo a escala regional; debido a las múltiples limitaciones de la teledetección (absorción de la atmósfera, mezcla espectral, etc.).

Aunque en la actualidad se observa un número creciente de estudios que utilizan imágenes hiperespectrales del VIS–NIR–SWIR para la cartografía superficial del suelo, éstos permanecen aún en la fase de prueba y no se utilizan como método operativo para la cartografía y seguimiento del carbono edáfico. En la Tabla 2 (fruto también de la revisión bibliográfica

Tabla 2. Estudios previos y los obtenidos en esta tesis para la estimación del carbono orgánico y materia orgánica del suelo usando imágenes hiperespectrales de sensores aeroportados o de satélite en el VIS–NIR–SWIR (adaptado de Peón *et al.* 2017b).

Sensor <sup>a</sup>	Rango espectral (nm) <sup>b</sup> , número de bandas, y resolución espacial (m)	Área de estudio (País) <sup>c</sup>	Propiedad del suelo <sup>d</sup>	Técnica <sup>e</sup>	n <sub>cal</sub>  n <sub>val</sub> <sup>f</sup>	RMSE <sup>g</sup>	R <sup>2g</sup>	RPD <sup>g</sup>	Autores
AHS*	400-1600 (VNS), 21, 2.6	Campos agríc. (Bélgica)	C org.	PLSR (2)	110 xval	1.7 g/kg	0.54	1.47	Stevens <i>et al.</i> (2008)
AHS*	430-1600 (VNS), 21, 2.6	Campos agríc. (Luxemburgo)	C org.	PLSR	267 134	4.3 g/kg	0.72	1.89	Stevens <i>et al.</i> (2010)
AHS*	430-1600 (VNS), 21, 2.6	Campos agríc. (Luxemburgo)	C org.	PLSR	400 xval	3.9 g/kg	0.79	2.33	Stevens <i>et al.</i> (2012)
AHS*	430-2540 (VNS), 63, 2.6	Campos agríc. (Luxemburgo)	C org.	PLSR	91 xval	3.7 g/kg	0.96	3.13	Denis <i>et al.</i> (2014)
AHS*	450-2120 (VNS), 30, 2.6	Campos agríc. con vegetación (Bélgica)	C org.	PLSR (8)	52 16	1.7 g/kg	0.56	1.50	Bartholomeus <i>et al.</i> (2011)
AHS*	442-1019 (VN), 20, 2.6	Campos agríc. (Luxemburgo)	C org.	PLSR	46 31	2.2 g/kg	0.74	1.9	Steinberg <i>et al.</i> (2016)
AHS*	430-2335 (VNS), 38, 5	Zonas quemadas (España)	C total	PLSR (7)	89 10	7.8 %	0.73	1.92	Fernández <i>et al.</i> (2016)
AHS*	430-2335 (VNS), 38, 5	Zonas quemadas (España)	C oxid.	PLSR (7)	89 10	5.1 %	0.72	1.89	Peón <i>et al.</i> (2017b)
HyMap*	420-2480 (VNS), 127, 6	Campos agríc. (Alemania)	C total	SMLR (8)	39 xval	9.1 %	0.62	1.62	Peón <i>et al.</i> (2017b)
HyMap*	420-2480 (VNS), 127, 6	Campos agríc. (Alemania)	C org.	PLSR (7)	60 xval	0.29 %	0.90		Selige <i>et al.</i> (2006)
HyMap*	450-2500 (VNS), 128, 4	Campos agríc. (Alemania)	C org.	MLR (4)	60 xval	0.22 %	0.86		
HyMap*	420-2480 (VNS), 110, 6	Suelo desnudo (España)	C total	PLSR	9 xval	1.6 g /kg	0.74		Patzold <i>et al.</i> (2008)
HyMap*	420-2480 (VNS), 128, 4	Campos agríc. (Alemania)	C total	PLSR	61 61	0.13 %	0.77	1.92	Schwanghart y Jarmer (2011)
HyMap*	450-2480 (VNS), 128, 4	Campos agríc. (Alemania)	C org.	PLSR (2)	38 29	2.1 g/kg	0.71	1.80	Gerighausen <i>et al.</i> (2012)
HyMap*	400-2500 (VNS), 124, 5	Campos agríc. (Francia)	C org.	PLSR	95 xval	2.6 g/kg	0.02	0.99	Gomez <i>et al.</i> (2012)
HyMap*	539-2477 (VNS), 126, 8	Campos agríc. (Alemania)	C org.	PLSR (7)	204 xval	1.1 g/kg	0.83	2.45	Hbirkou <i>et al.</i> (2012)
DAIS*	400-2500 (VNS), 69, 8	Campos agríc. (Israel)	OM	MLR (4)	62 5		0.83		Ben-Dor <i>et al.</i> (2002)
HSTIR*	400-2450 (VNS), 178, 2.5	Campos agríc. (EEUU)	C org.	PLSR (8)	269 xval	0.18 %	0.64	1.39	Hively <i>et al.</i> (2011)
P-AISA*	400-2500 (VNS), 282, 1	Suelos degradados (Brasil)	OM	PLSR (8)	60 xval	2.8 g/kg	0.60	1.60	Franceschini <i>et al.</i> (2015)
AVNIR*	429-1010 (VN), 60, 1.2	Campos agríc. (California)	C total	MLR (4)	321 -	0.08 %	0.27		DeTar <i>et al.</i> (2008)
CASI*	409-947 (VN), 71, 2	Campos agríc. (Canadá)	OM	MLR (4)	321 -	0.08 %	0.49		
CASI*	405-950 (VN), 96, 6	Campos agríc. (Bélgica)	OM	PCA-SMLR	47 xval	0.5 %	0.75	1.57	Uno <i>et al.</i> (2005)
CASI*	405-950 (VN), 96, 6	Campos agríc. (Bélgica)	C org.	PLSR (2)	170 57	5.1 g/kg	0.85	1.86	Stevens <i>et al.</i> (2006)
HYP**	427-2355 (VNS), 152, 30	Campos agríc. y pastos (Australia)	C org.	PLSR (3)	72 xval	0.73 %	0.51	1.43	Gomez <i>et al.</i> (2008)
HYP**	468-1770 (VNS), 98, 30	Bosques, pastos y campos agríc. (EEUU)	C org.	SMLR-ANN	227 76	11.3 t/ha		0.68	Jaber <i>et al.</i> (2011)
HYP**	400-2500 (VNS), 158, 30	Campos agríc. (China)	C org.	PLSR (3)	47 xval	1.6 g/kg	0.63	1.65	Lu <i>et al.</i> (2013)
HYP**	400-2500 (VNS), 150, 30	Campos agríc. (EEUU)	C total	PLSR (3)	20 8	0.33 %	0.48	1.48	Zhang <i>et al.</i> (2013)
HYP**	436-2345 (VNS), 171, 30	Cultivos de maíz (Italia)	OM	PLSR (4)	20 8	0.66 %	0.74	1.91	
HYP**	436-2345 (VNS), 171, 30	Cultivos de maíz (Italia)	OM	OLS MNF	72 xval	0.15 %		2.93	Castaldi <i>et al.</i> (2014)
HYP**	427-2335 (VNS), 155, 30	Zonas quemadas (España)	C total	SMLR (18)	200 xval	7.6 %	0.49	1.39	Peón <i>et al.</i> (2017b)
HYP**	427-2335 (VNS), 155, 30	Zonas quemadas (España)	C oxid.	SMLR (20)	200 xval	3.7 %	0.61	1.58	

<sup>a</sup> Los asteriscos indican el tipo de sensor: aeroportado (\*), satélite (\*\*). Nombre de los sensores: HSTIR = HyperSpecTIR, P-AISA = ProSpecTIR-AISA, HYP = Hyperion. <sup>b</sup> La región espectral se muestra

entre paréntesis: visible (V, 400-700 nm), infrarrojo cercano (Near-Infrared, N, 700-1300 nm), infrarrojo medio de onda corta (Short-Wave Infrared, S, 1300-2500 nm). <sup>c</sup> Campos agríc. = campos agrícolas. <sup>d</sup> C org. = C orgánico, C oxid. = C oxidable, OM = materia orgánica. <sup>e</sup> MLR = regresión lineal múltiple (Multiple Linear Regression), SMLR = regresión lineal múltiple paso a paso (Stepwise Multiple Linear Regression), PLSR: regresión de mínimos cuadrados parciales (Partial Least-Squares Regression), PCA = análisis de componentes principales (Principal Component Analysis), ANN = redes neuronales artificiales (Artificial Neural Networks), OLS MNF = mínimos cuadrados ordinarios (Ordinary Least Squares) usando los vectores propios de la fracción de mínimo ruido (Minimum Noise Fraction). El número de canales o de componentes PLSR usados en los modelos se indica entre paréntesis. <sup>f</sup> n<sub>cal</sub>|n<sub>val</sub> indica el número de muestras usadas en la calibración y en la validación, respectivamente. “xval” indica que la validación se ha realizado usando el método de validación cruzada. <sup>g</sup> Error cuadrático medio (Root-Mean-Square Error, RMSE), coeficiente de determinación (R<sup>2</sup>) y cociente entre la desviación típica de la muestra y el error cuadrático medio (Ratio of Performance to Deviation, RPD) obtenidos en la validación.

de esta tesis e incluidos los resultados de ésta para su comparación; Peón *et al.* 2017b) se incluye una lista detallada de trabajos en los que el carbono y la materia orgánica del suelo se estimaron usando datos hiperespectrales de sensores aeroportados o de satélite. La tabla incluye también el tipo y localización del área de estudio, el rango espectral de los datos utilizados, el número de bandas y resolución espacial de las imágenes, la técnica de modelización utilizada, así como los resultados obtenidos en la validación de los modelos. Los resultados de la validación se expresan mediante el error cuadrático medio (Root-Mean-Square Error, RMSE), el coeficiente de determinación R<sup>2</sup> y el cociente entre la desviación típica de la muestra y el error cuadrático medio (Ratio of Performance to Deviation, RPD).

El carbono y la materia orgánica fueron estimados en estos trabajos usando imágenes hiperespectrales de sensores aeroportados, con un número de canales que osciló entre 20 y 282 en la región VIS–NIR–SWIR, y una resolución espacial entre 1 y 8 m (Tabla 2). El objetivo de la mayoría de estos trabajos fue la estimación del carbono orgánico del suelo en áreas agrícolas o de suelo desnudo. En solo dos trabajos de los 18 mostrados en la Tabla 2 se estimó el carbono del suelo en áreas agrícolas parcialmente cubiertas de vegetación, usando en ambos la técnica de PLSR (Bartholomeus *et al.* 2011; Franceschini *et al.* 2015). En ninguno de los trabajos de la Tabla 2 (excluyendo los realizados en esta tesis) se estimó el carbono del suelo usando sensores hiperespectrales aeroportados en un entorno natural parcialmente cubierto de vegetación.

En cuanto a los sensores hiperespectrales aeroportados empleados para estimar el carbono y la materia orgánica del suelo, los más utilizados fueron los sensores HyMap (Selige *et al.* 2006; Patzold *et al.* 2008; Schwanghart y Jarmer 2011; Gerighausen *et al.* 2012; Gomez *et al.* 2012; Hbirkou *et al.* 2012) y Airborne Hyperspectral Scanner (AHS) (Stevens *et al.* 2008;

Stevens *et al.* 2010; Bartholomeus *et al.* 2011; Stevens *et al.* 2012; Denis *et al.* 2014; Steinberg *et al.* 2016). Aunque en menor medida, se han empleado también otros sensores hiperespectrales aeroportados, como el Compact Airborne Spectrographic Imager (CASI) (Uno *et al.* 2005; Stevens *et al.* 2006), AVNIR (DeTar *et al.* 2008), DAIS-7915 (Ben-Dor *et al.* 2002), ProSpecTIR-AISA (Franceschini *et al.* 2015) y el sensor HyperSpecTIR (Hively *et al.* 2011).

Los resultados de la validación de los estudios previos en los que se utilizaron datos de sensores hiperespectrales aeroportados para predecir el carbono y la materia orgánica del suelo en áreas agrícolas o de suelo desnudo fueron heterogéneos, con  $R^2$  en el rango entre 0.02–0.96 y RPD entre 0.99 y 3.13. Los mejores resultados fueron obtenidos con el sensor AHS corrigiendo el efecto de la sombra del suelo en la imagen de reflectividad mediante el uso de un factor de corrección calculado a partir de fotografías verticales del suelo tomadas en el campo (Denis *et al.* 2014). También se obtuvieron resultados satisfactorios en otros trabajos en los que se utilizaron conjuntos de datos relativamente grandes y se realizaron modelos locales para las distintas regiones y condiciones superficiales (principalmente la textura) presentes en el área de estudio (Hbirkou *et al.* 2012; Stevens *et al.* 2012). La mayor parte de los trabajos para la predicción de SOC en áreas de suelo desnudo usando imágenes de sensores aeroportados se basaron en la técnica de PLSR y mostraron un valor de  $R^2$  en la validación típicamente en el rango ~0.6-0.8 y RPD entre 1.4 y 1.9 (Tabla 2).

Por otra parte, el uso de datos hiperespectrales de satélite para la estimación del carbono del suelo apenas ha sido investigado. En este sentido, solo se ha utilizado el sensor Hyperion de 30 m de resolución espacial para predecir el carbono y la materia orgánica del suelo en campos agrícolas y áreas de suelo desnudo (Gomez *et al.* 2008; Lu *et al.* 2013; Zhang *et al.* 2013). La validación de estos trabajos mostró valores de  $R^2$  en el rango entre 0.48–0.74 y RPD entre 1.43 y 1.65 (Tabla 2). También se han utilizado datos de Hyperion para estimar SOC y materia orgánica en cultivos de maíz (Castaldi *et al.* 2014), con resultados satisfactorios (RPD = 2.93); y en bosques, pastos y campos agrícolas (Jaber *et al.* 2011), con resultados poco precisos (RPD = 0.68). En ninguno de los trabajos realizados con Hyperion que se muestran en la Tabla 2 (excluyendo los realizados en esta tesis) se estimó con un resultado satisfactorio el carbono del suelo en un entorno natural parcialmente cubierto de vegetación.

También se han utilizado datos multiespectrales de satélite para la estimación cuantitativa de propiedades edáficas como el carbono y la materia orgánica, pero el número de trabajos es

relativamente menor. Entre los sensores de resolución espacial media, Landsat fue el más utilizado para estimar el contenido en carbono y materia orgánica del suelo: Huang *et al.* (2007) en suelos glaciares, Jarmer *et al.* (2010) en zonas no agrícolas áridas y semiáridas, Nanni y Demattê (2006) en suelos desnudos, y Peng *et al.* (2015) en un área principalmente agrícola ( $R^2$  de 0.46, 0.80-0.91, 0.51 y 0.46 respectivamente). El sensor MODIS (Moderate Resolution Imaging Spectroradiometer) se ha utilizado recientemente para cartografiar el carbono orgánico del suelo en África a una resolución espacial de 500 m (Vågen *et al.* 2016) y se obtuvieron resultados satisfactorios ( $R^2 = 0.74$ ). El carbono orgánico del suelo también se ha estimado a escala global con una resolución espacial de 250 m en un trabajo reciente de Hengl *et al.* (2017), en el que utilizaron datos del sensor MODIS e información complementaria para estimar el carbono del suelo, tanto en la superficie del suelo como a distintas profundidades. Para la modelización utilizaron técnicas de aprendizaje automático (Machine Learning, ML) y obtuvieron resultados moderadamente satisfactorios en la validación ( $R^2 = 0.64$ ).

Hasta el momento, la estimación del carbono orgánico del suelo usando sensores hiperespectrales aeroportados y desde satélite ha sido restringida principalmente a zonas agrícolas y zonas de suelo desnudo, en ambos casos de pequeña extensión, y todavía permanece en fase de pruebas. Por otra parte, se han utilizado en varios trabajos sensores multiespectrales desde satélite para cuantificar el carbono y materia orgánica del suelo, pero éstos aún no se emplean para cartografiar operativamente el carbono y la materia orgánica del suelo.

En esta tesis se evaluará la posibilidad de la teledetección para estimar el carbono orgánico total y el carbono oxidable del suelo en zonas de montaña quemadas del suroccidente de Asturias. Para ello se emplearán sensores hiperespectrales aeroportados y desde satélite en la región espectral del óptico.

#### **1.4. Área de estudio**

El área de estudio de esta tesis se localiza en el suroccidente de Asturias, en el noroeste de España (Figura 1). Como zona de estudio, se seleccionaron las zonas quemadas situadas en un área rectangular de 60 km<sup>2</sup> aproximadamente, orientada en la dirección noroeste-sureste y ubicada en el sector occidental de la Cordillera Cantábrica, en los concejos de Allande, Cangas

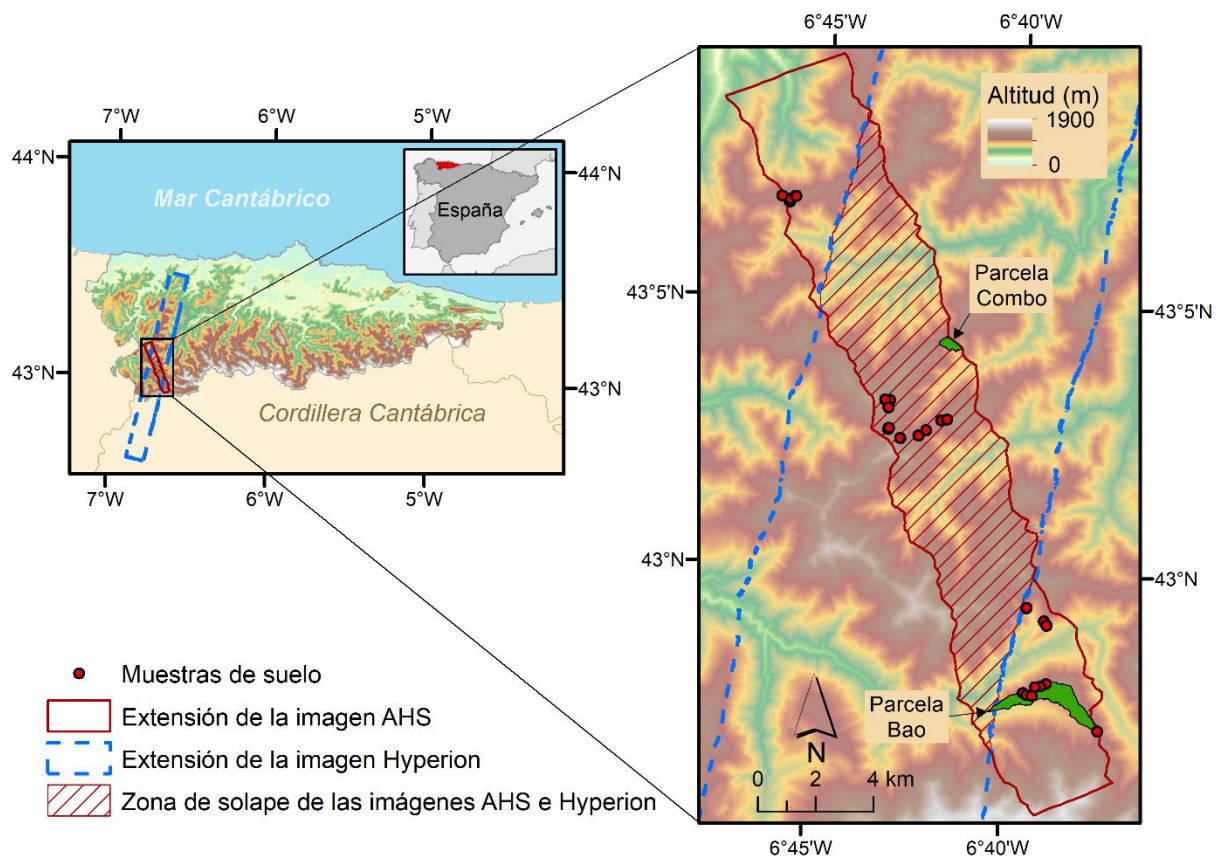


Figura 1. Localización del área de estudio en el noroeste de España, ubicación de las muestras de suelo, extensión de la imagen del sensor Airborne Hyperspectral Scanner (AHS) y de la imagen Hyperion adquirida el 30 de septiembre de 2014 (adaptado de Peón *et al.* 2017b).

de Narcea, Degaña e Ibias. En la zona de estudio se realizó una campaña de vuelo el 10 de octubre de 2011 y se obtuvo una imagen hiperespectral con el sensor AHS (la extensión de esta imagen se señala en rojo en la Figura 1). La zona de estudio de la tesis se limita por lo tanto a las zonas quemadas situadas en la imagen AHS, que suman una superficie total de  $\sim 8$  km<sup>2</sup>. La orografía del área de estudio corresponde a zonas de montaña de altitud media-baja, con altitudes entre 200 y 1200 m sobre el nivel del mar, y una pendiente media de 25° aproximadamente. El clima es atlántico, con una precipitación anual media de 1500 mm y temperaturas moderadas, con un valor anual medio de  $\sim 8$  °C.

Las características geológicas y geomorfológicas de esta zona, junto a su elevada frecuencia de incendios forestales (Álvarez y Marquínez 2007), hacen que resulte muy adecuada para este estudio. El sustrato rocoso está formado principalmente por arenisca, cuarcita y pizarra, dando lugar a un alto grado de homogeneidad litológica. Los suelos desarrollados sobre este sustrato se clasifican como litosoles, histosoles y regosoles, de acuerdo a la Base Referencial Mundial (World Reference Base, WRB) (FAO 2014); y son arenosos, poco profundos,

pedregosos y ricos en materia orgánica (Fernández et al. 2005) (Figura 2). El mapa de recurrencia de incendios obtenido con datos Landsat (Recondo *et al.* 2003; Recondo *et al.* 2007; Sánchez Fanjul 2013) muestra regiones del área de estudio quemadas hasta en cuatro ocasiones en el periodo 1984–2011. Los últimos incendios en la zona de estudio registrados en esta cartografía datan de 2005 (centro del área de estudio), 2006 (zona sur) y 2011 (zona norte y centro-sur).

Históricamente, la actividad ganadera ha dado lugar a quemas reiteradas en zonas extensas de esta región, que han causado una degradación severa del suelo y de la vegetación natural. En la actualidad, la mayoría de las laderas están deforestadas, alternando matorrales de brezo y tojo con áreas pedregosas en las que el suelo ha desaparecido completamente. La vegetación dominante es el brezal (*Erica australis* subsp. *aragonensis* (Willk.) Cout. y *Calluna vulgaris*

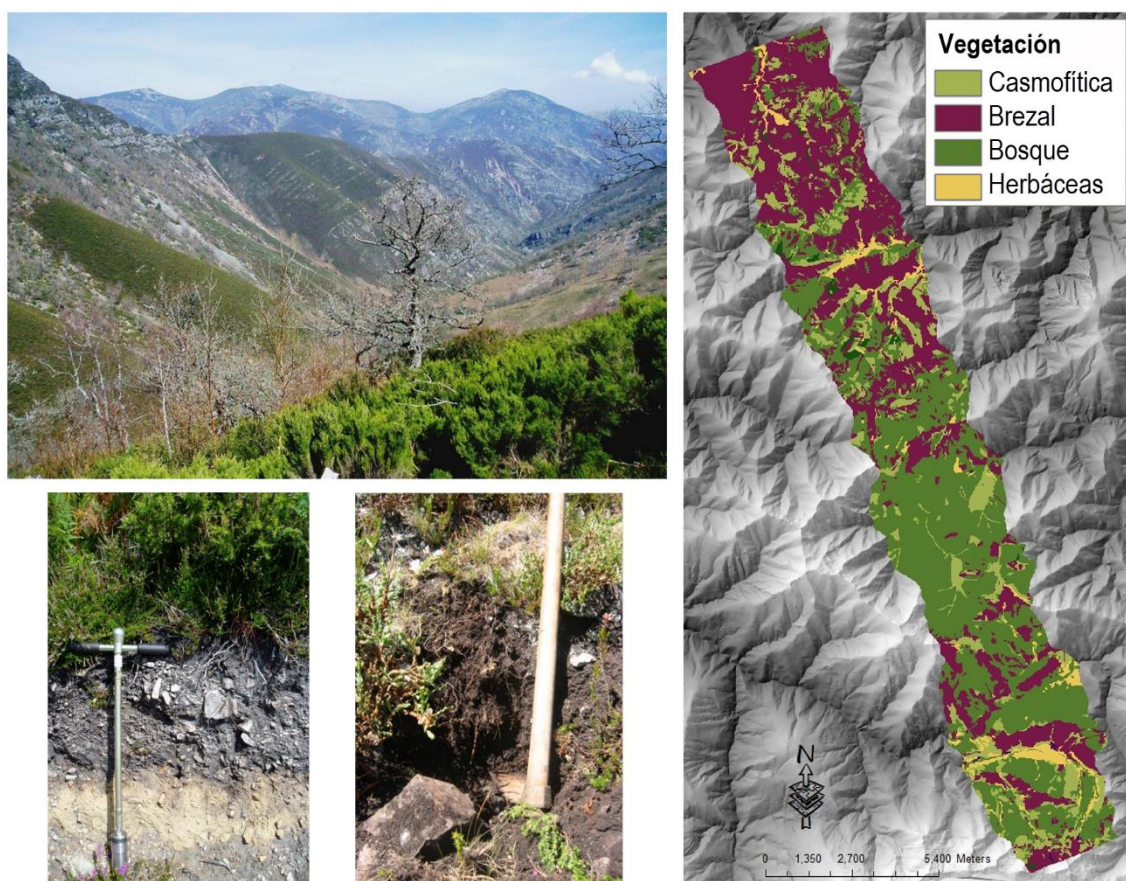


Figura 2. Vista general del área de estudio (panel superior izquierdo) y de los perfiles ricos en materia orgánica (panel inferior izquierdo e inferior central). En el mapa de vegetación (panel derecho), el color morado representa brezales y el color verde claro la vegetación típica (casmofítica) que cubre los suelos esqueléticos y pedregosos originados principalmente por la erosión post-incendio. El bosque se representa en color verde oscuro y el pasto para uso ganadero en color amarillo (adaptado de Fernández *et al.* 2016).



(L) Hull), un resultado de la degradación sufrida por la vegetación natural a causa de los incendios forestales (Díaz González y Fernández 1994). La abundancia de brezales en la zona de estudio varía a lo largo de un gradiente en la dirección norte-sur, con mayor abundancia en la zona norte (Figura 2). En lo que respecta a los bosques, en la actualidad, éstos se han reducido a robledales de diferentes especies (*Quercus petraea* subsp. *Petraea* (Matt.) Liebl., *Quercus robur* L. y *Quercus pyrenaica* Willd.).

Durante la primera mitad del siglo XX, los incendios forestales fueron extremadamente frecuentes en el norte de la Península Ibérica, y en épocas más recientes son aún muy frecuentes en esta región. Trabajos recientes en esta zona y en áreas próximas mostraron alteraciones de las propiedades de los suelos quemados, como la pérdida significativa del contenido en arcilla y la degradación textural y estructural que afecta al comportamiento hidrológico de los suelos quemados, el aumento de las tasas de infiltración (0.0107 a 0.1070 cm/s) (Fernández *et al.* 2005) y el aumento de la erosión del suelo, con unos valores medios de pérdida de suelo de 6.5 t ha<sup>-1</sup> año<sup>-1</sup>, medidos con <sup>137</sup>Cs en laderas quemadas (Menéndez Duarte *et al.* 2008). Los incendios también afectan a la materia orgánica del suelo. Santín *et al.* (2008) obtuvieron valores de concentración de carbono orgánico en la capa superficial del suelo (0–5 cm de profundidad) que variaron entre 390.2 mg g<sup>-1</sup> en suelos de laderas quemadas cubiertas de brezal y 157.1 mg g<sup>-1</sup> en suelos de bosques no quemados. En la capa del suelo entre 5 y 10 cm de profundidad, la acumulación de carbono orgánico fue notablemente inferior, con valores que variaron entre 289.5 mg g<sup>-1</sup> en suelos de laderas quemadas y 70.7 mg g<sup>-1</sup> en suelos no quemados.

Los suelos quemados de la zona de estudio resultan muy adecuados para investigar la posibilidad de estimar el carbono orgánico del suelo usando técnicas de espectroscopía y teledetección, dado que estos suelos tienen una elevada concentración y rango de variación de carbono orgánico. Si bien esta elevada concentración de carbono hace que la zona de estudio sea idónea para aplicar la teledetección, existen factores que dificultan notablemente el uso de esta técnica. Entre estos factores se incluye el fuerte relieve de esta zona de montaña, que causa diferencias de iluminación en las imágenes y hace necesaria la aplicación de una corrección topográfica; las condiciones meteorológicas poco favorables, con presencia frecuente de nieve, lluvia y niebla, que dificulta el uso de imágenes de la región del óptico; y la presencia de vegetación en las zonas quemadas a medida que éstas se van recuperando, lo que enmascara la señal del suelo que reciben los sensores aeroportados y de satélite.

Todos estos factores que concurren en el área de estudio hacen que el uso de la teledetección para estimar el carbono del suelo en esta región sea un reto y genere mucho interés, ya que la mayoría de los trabajos previos basados en el uso de teledetección se han restringido principalmente a zonas agrícolas y zonas de suelo desnudo. En lo que respecta al uso de sensores hiperespectrales aeroportados, solo en dos trabajos de los 18 mostrados en la Tabla 2 (exceptuando los trabajos derivados de esta tesis) se estimó el carbono del suelo en áreas parcialmente cubiertas de vegetación, ambos trabajos en zonas agrícolas muy controladas y ninguno de ellos en un ambiente natural como el de la zona de estudio. En cuanto al uso de sensores hiperespectrales de satélite, se empleó el sensor Hyperion para estimar el carbono en zonas naturales cubiertas de vegetación como bosques, pero se obtuvieron resultados poco precisos (Tabla 2). La ausencia de trabajos previos en los que se haya estimado satisfactoriamente el carbono del suelo en áreas quemadas y la importancia de éstas como sumideros de carbono orgánico justifican el interés de la zona de estudio elegida en la tesis.

## **1.5. Datos utilizados**

### ***1.5.1. Datos de campo***

En el verano de 2013 se realizó una campaña de campo en el área de estudio para la toma de 89 muestras de la capa superficial de los suelos (0–5 cm de profundidad) de las laderas quemadas (Figura 1). Las muestras se tomaron aleatoriamente en tres zonas situadas en el norte, centro y sur del área de estudio, tratando de representar el gradiente en la dirección N-S asociado a la abundancia de brezales, que son claramente más frecuentes en la zona norte (Figura 2). Todas las muestras fueron tomadas en laderas de brezal, que es una cubierta vegetal resultante del manejo del fuego en el territorio (Díaz González y Fernández 1994). La localización de los puntos de muestreo se obtuvo con un dispositivo Global Positioning System (GPS) de mano, con una precisión de 3–5 m (95 % típica).

El muestreo se diseñó originalmente para la imagen del sensor aeroportado AHS, dado que ésta ya había sido adquirida en el momento de la toma de las muestras de campo. Los puntos de muestreo se seleccionaron por lo tanto dentro de los límites de la imagen AHS (Figura 1). Si bien se tomaron un total de 89 muestras de suelo, el número de muestras disponibles para los distintos métodos de estimación del carbono utilizados en la tesis es variable. Para la estimación del carbono del suelo usando técnicas de espectroscopía en el laboratorio resulta adecuado el conjunto completo de 89 muestras de suelo. Sin embargo, el número de muestras

disponibles para teledetección es menor, ya que no todas las muestras son adecuadas para la estimación del carbono usando las imágenes aeroportadas o de satélite. Por ejemplo, algunas muestras cercanas entre sí quedan contenidas en un mismo píxel de las imágenes, lo que reduce el número de muestras disponibles. Esta reducción del número de muestras es mayor en imágenes con mayor tamaño de píxel, como la imagen Hyperion (30 m de resolución espacial), que en otras imágenes de menor tamaño de píxel como la imagen AHS (5 m de resolución espacial). Las muestras de suelo situadas cerca de cubiertas muy distintas al brezal, como carreteras, caminos y roquedos, tampoco son adecuadas para su uso en teledetección, ya que la proximidad de estas cubiertas al brezal puede generar efectos de adyacencia que contaminen la señal procedente de éste. Por lo tanto, tras filtrar las muestras y seleccionar únicamente aquellas contenidas en zonas homogéneas de brezal en la imagen y alejadas de cubiertas distintas al brezal, el conjunto de 89 muestras de suelo se reduce a 39 muestras para la imagen AHS y a solamente 6 muestras para la imagen Hyperion (Figura 1), cuya adquisición no estaba prevista en el momento de la toma de las muestras en el campo.

En la campaña de campo, además de las 89 muestras de suelo se tomaron muestras en 12 parcelas, para la validación de los modelos de carbono del suelo obtenidos usando AHS. El muestreo en estas parcelas se realizó siguiendo la metodología establecida en el proyecto VALERI (Validation of Land European Remote sensing Instruments) (Rossello y Baret 2007), en el que se fijaron estrategias para la validación de varios productos obtenidos con teledetección. Para aminorar el efecto del tamaño del píxel de la imagen AHS (5 m de resolución espacial) y el efecto del error en la georreferenciación de la imagen (cuyo valor es inferior al tamaño de un píxel), se seleccionaron parcelas de 15×15 m, lo que corresponde a una región de 3×3 píxeles de la imagen AHS. Para obtener una muestra representativa de cada parcela, en el diseño del muestreo se tuvo en cuenta la variabilidad existente dentro de cada una de ellas. Es por ello por lo que en cada parcela se tomaron 5 muestras de la capa superficial del suelo (0–5 cm de profundidad), en el centro y en las cuatro esquinas de la misma, y se mezclaron y homogeneizaron posteriormente para obtener una muestra representativa de la parcela.

### ***1.5.2. Datos de laboratorio***

Las muestras de suelo, tanto las 89 individuales como las 12 de las parcelas de validación, se trasladaron al laboratorio, donde se secaron a 70°C en una estufa de secado, se tamizaron (<2 mm) y se homogeneizaron. Posteriormente cada muestra se separó en dos partes, una de ellas

para la realización del análisis químico y la otra para el análisis espectral con técnicas de espectroscopía.

Por una parte, en cada muestra de suelo se realizaron dos análisis químicos usando métodos convencionales: un análisis para determinar la fracción de carbono oxidable (Oxidizable Carbon, OC) y otro para determinar el contenido de carbono orgánico total (Total Organic Carbon, TOC). Inicialmente, las muestras se enviaron al Laboratorio de Técnicas Instrumentales de la Universidad de León para la determinación del carbono oxidable, usando el método de oxidación con dicromato (Walkley y Black 1934). Si bien es posible estimar el carbono orgánico total a partir del carbono oxidable mediante la aplicación de un factor de conversión, en la tesis se prefirió determinar el carbono orgánico total mediante combustión seca, usando un analizador de C, que a pesar de ser una técnica más costosa es muy utilizada en la actualidad debido a su mayor precisión. Por lo tanto, las muestras se enviaron a los Servicios Científico-Técnicos de la Universidad de Oviedo para analizar el carbono orgánico total, por duplicado, mediante combustión seca a 950°C (Heiri *et al.* 2001), usando un analizador Vario C-N del fabricante alemán Elementar Analysensysteme GmbH. Al haberse realizado los análisis del carbono oxidable y del carbono orgánico total en dos laboratorios independientes, y al existir una alta relación entre el carbono oxidable y el carbono orgánico total, fue posible compararlos y obtener así un grado extra de fiabilidad en los resultados obtenidos. En el área de estudio el carbono orgánico total equivale al carbono total, dado que los suelos no son calcáreos (Fernández *et al.* 2005).

Por otra parte, se obtuvieron en el laboratorio los espectros de reflectividad de las muestras de suelo usando un espectrofotómetro Analytical Spectral Devices (ASD) LabSpec® 2600, con un rango espectral entre 350–2500 nm (región del óptico, VIS–NIR–SWIR), un intervalo de muestreo de 1 nm, y una resolución espectral de 3 nm a 700 nm y de 6 nm a 1400 nm y a 2100 nm. Las medidas se realizaron usando una sonda de contacto (Contact probe) con fuente de iluminación halógena incorporada. La superficie de contacto de la sonda corresponde a un círculo de 10 mm de diámetro. Como blanco de referencia se utilizó un panel Spectralon® con una reflectividad del 100 % en el rango del óptico. El espectro de reflectividad de cada muestra de suelo se obtuvo promediando 10 lecturas de reflectividad. Los espectros fueron reducidos del rango original (350–2500 nm) al rango entre 400–2450 nm para eliminar el ruido presente en la parte inicial y final de los mismos.

### ***1.5.3. Datos hiperespectrales de sensores aeroportados***

El Instituto Nacional de Técnica Aeroespacial (INTA) realizó una campaña de vuelo en la que se tomaron datos hiperespectrales del área de estudio usando los sensores Airborne Hyperspectral Scanner (AHS) y Compact Airborne Spectrographic Imager (CASI), ambos instalados en el avión CASA 212-200. Las condiciones meteorológicas durante el vuelo fueron favorables, con cielo despejado y viento ligero de componente este.

La imagen AHS que ha sido utilizada en la tesis se tomó el 10 de octubre de 2011 a las 11:05 UTC (la extensión de la imagen se señala en rojo en la Figura 1). AHS es un sensor de tipo “whisk-broom” con campo de visión (Field Of View, FOV) de 90° y 750 píxeles en la dirección perpendicular a la trayectoria del vuelo (dirección “across-track”). El campo de visión instantáneo (Instantaneous FOV, IFOV) es de 2.5 mrad, lo que equivale a una resolución espacial de 5 m para una altura de vuelo de ~1860 m sobre el terreno. El sensor AHS tiene 80 canales: 63 en la región del óptico (visible, infrarrojo próximo e infrarrojo medio de onda corta, VIS–NIR–SWIR), 7 en la región del infrarrojo medio entre 3177 nm y 5251 nm (MIR) y 10 en la región del infrarrojo térmico entre 8310 nm y 12952 nm (TIR). En la tesis se han utilizado solamente los 63 canales de la región del óptico: 20 canales en la región entre 443–1001 nm (VIS–NIR), con una anchura a media altura (Full Width at Half Maximum, FWHM) de 27–29 nm, y una relación señal-ruido media (Signal-to-Noise Ratio, SNR) de 473:1, 1 canal a 1590 nm (SWIR) con FWHM de 85 nm y SNR de 207:1, y 42 canales en la región entre 1924–2553 nm (SWIR) con FWHM de 14–18 nm y SNR media de 18:1.

Se realizó una corrección radiométrica y geométrica de la imagen de AHS en colaboración con Eduardo de Miguel y Laura Carretero, del Área de Sistemas de Teledetección del Departamento de Observación de la Tierra y Atmósfera del INTA. La corrección geométrica fue realizada usando el software de georreferenciación directa PARGE (Schlapfer y Richter 2002) y un modelo digital de elevaciones (Digital Elevation Model, DEM) de 5 m de resolución espacial proporcionado por el Instituto Geográfico Nacional (IGN). La imagen se georreferenció en el sistema geodésico World Geodetic System 1984 (WGS84) y proyección Universal Transversa de Mercator (UTM) en el huso 30, zona norte. La imagen se corrigió de atmósfera y topografía usando el software Atmospheric & Topographic Correction (ATCOR4) (Richter y Schlapfer 2002), para obtener el factor de reflectividad hemisférica direccional (Hemispherical-Directional Reflectance Factor, HDRF) a partir de la radiancia medida por el sensor en el techo de la atmósfera (Top Of Atmosphere, TOA). Se eliminaron los canales de

la imagen que tenían un valor bajo de SNR ( $SNR < 10$ ) y aquellos situados en regiones con una fuerte absorción de vapor de agua atmosférico. En la tesis se empleó un total de 38 canales de la imagen AHS, 9 en la región VIS, 10 en el NIR y 19 en el SWIR. En la Tabla 3 se muestra un resumen de las características del sensor AHS y de otros sensores de teledetección utilizados en la tesis, así como las del sensor ASD de laboratorio para una comparación conjunta.

Tabla 3. Características de los sensores empleados en la tesis y número de bandas utilizadas en cada región espectral.

Sensor <sup>a</sup>	ASD-LS	CASI	AHS	Hyperion	Landsat-TM5	MODIS
Tipo de sensor	Laboratorio	Aeroportado	Aeroportado	Satélite	Satélite	Satélite
Clasificación <sup>b</sup>		HS	HS	HS	MS	MS
Rango espectral (nm)	400–2450	407–1053	443–2326	427–2355	485–2223	413–2130
Número de bandas:						
VIS (400–700 nm)	301	62	9	27	3	10
NIR (700–1300 nm)	600	74	10	57	1	7
SWIR (1300–2500 nm)	1150		19	71	2	3
VIS–NIR–SWIR	2051	136	38	155	6	20
Ancho de banda (nm) <sup>c</sup>	3–6	6	17–85	10–12	66–252	10–50
Resolución espacial (m)		1.5	5	30	30	1000 <sup>d</sup>
Ancho de barrido (km)		1.5	4.1	7.5	185	2330
Resolución temporal (días)				200	16	1

<sup>a</sup> Los sensores se ordenan en la tabla de menor a mayor tamaño de píxel. ASD-LS = Analytical Spectral Devices LabSpec® 2600; CASI = Compact Airborne Spectrographic Imager; AHS = Airborne Hyperspectral Scanner; Landsat-TM5 = Landsat 5 Thematic Mapper; MODIS = Moderate Resolution Imaging Spectroradiometer. <sup>b</sup> Los sensores de teledetección se clasifican en dos grupos en función del número de bandas: multiespectrales (MS) e hiperespectrales (HS). <sup>c</sup> Los valores del ancho de banda corresponden a la anchura a media altura (Full Width at Half Maximum, FWHM). <sup>d</sup> El sensor MODIS tiene dos bandas a una resolución espacial de 250 m, cinco a 500 m y las restantes a 1000 m.

En la imagen AHS corregida de atmósfera y topografía se realizó una clasificación supervisada para identificar las áreas quemadas de la zona de estudio y otras cubiertas presentes en la escena. En la clasificación se definieron cuatro clases usando una composición en color real de la imagen AHS (con las bandas a 650, 560 y 443 nm en los canales rojo, verde y azul, respectivamente): roquedo, bosque, herbáceas y zonas quemadas. El área de estudio de la tesis se restringe a las zonas quemadas, cuya superficie total es de  $\sim 8 \text{ km}^2$ . Para la clasificación de la imagen se establecieron áreas de entrenamiento en la escena (entre 13 y 21 áreas en cada una de las cuatro clases) y se utilizó posteriormente un clasificador de máxima probabilidad (Richards 2013). Las áreas de entrenamiento se determinaron usando un mapa de usos del suelo a escala 1:25000, obtenido a partir de observaciones de campo. La fiabilidad global de la clasificación fue de 93.5 %. En la Figura 3 se muestra el mapa de usos del suelo obtenido en la clasificación.

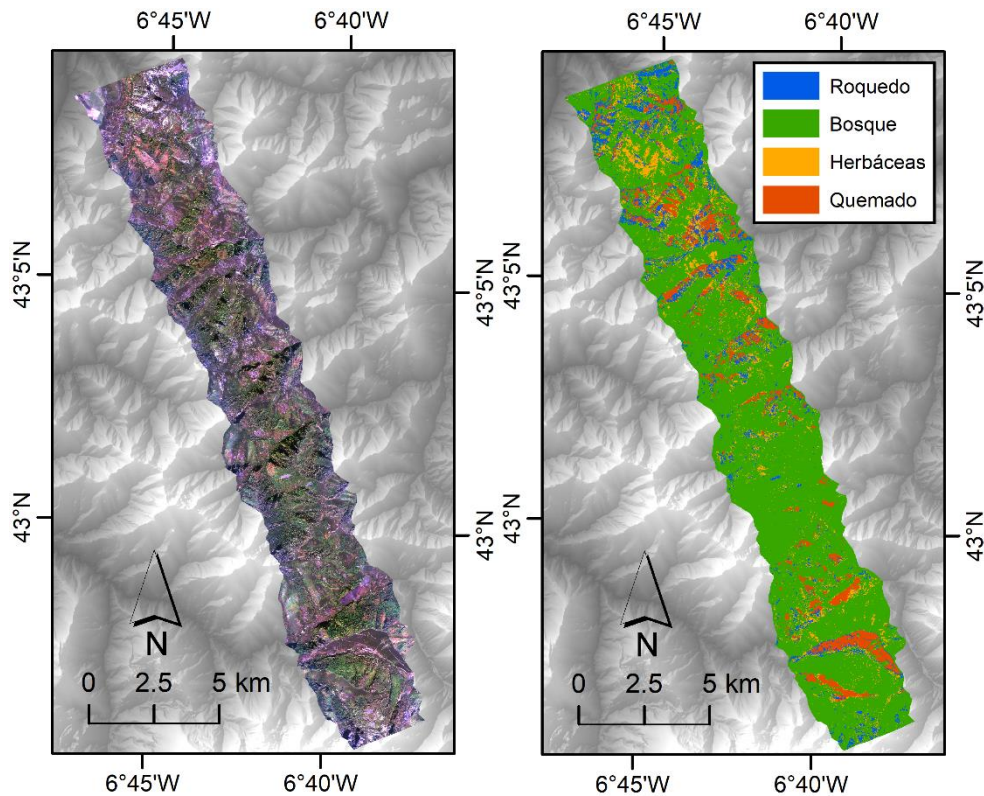


Figura 3. Composición en color real de la imagen de AHS, con las bandas a 650, 560 y 443 nm en los canales rojo, verde y azul, respectivamente (izquierda). Mapa de usos del suelo obtenido en la clasificación (derecha).

En la campaña de vuelo realizada por el INTA en la zona de estudio también se tomaron imágenes usando CASI, que es un sensor hiperspectral aeroportado de tipo “pushbroom”. CASI mide la radiancia recibida hasta en 288 canales, que se pueden configurar por el usuario en cualquier región espectral del rango entre  $\sim 380\text{--}1050$  nm. En el vuelo realizado sobre la zona de estudio el 10 de octubre de 2011, el sensor se configuró para adquirir 144 bandas en la región entre  $368\text{--}1053$  nm, con FWHM de 6 nm. El FOV del sensor es de  $40^\circ$  y el IFOV es de 0.5 mrad, lo que equivale a una resolución espacial de 1.5 m para una altura de vuelo de  $\sim 1860$  m sobre el terreno. En la tesis se valoró inicialmente el uso de los dos sensores aeroportados CASI y AHS para estimar el carbono orgánico del suelo, dado que se adquirieron imágenes hiperspectrales del área de estudio con ambos sensores de forma simultánea. Tras un análisis inicial se descartó el uso del sensor CASI en la tesis debido a su menor anchura de barrido respecto al sensor AHS (1.5 km de CASI frente a 4.1 km de AHS) y a la ausencia de bandas en la región del SWIR (Tabla 3), que se reveló como una región importante para estimar el carbono orgánico del suelo.

#### **1.5.4. Datos hiperespectrales de satélite**

En la tesis se han utilizado imágenes adquiridas con Hyperion, que es un sensor hiperespectral instalado en el satélite Earth Observing-1 (EO-1). Este satélite fue lanzado en el año 2000 por la Administración Nacional de la Aeronáutica y del Espacio (National Aeronautics and Space Administration, NASA), como parte de una misión de validación y demostración de un año. Una vez finalizada la misión en el año 2001, la comunidad científica mostró un gran interés en continuar con la adquisición de datos y se extendió su duración en un acuerdo entre la NASA y el Servicio Geológico de los Estados Unidos (United States Geological Survey, USGS). En el marco de la misión extendida se continuaron tomando datos bajo petición hasta el desmantelamiento definitivo del satélite en el año 2017.

En mayo de 2014, enviamos una petición de toma de datos para el área de estudio de la tesis, usando el sistema experimental SensorWeb de la NASA. Como resultado de esta petición, se tomaron 3 escenas Hyperion entre septiembre y diciembre de 2014. Si bien en el sistema SensorWeb es el propio usuario quien define el área y el rango de fechas de interés para la toma de datos, éste no tiene control total sobre la cobertura de la imagen a adquirir, dado que solo suministra las coordenadas del centro de la misma; ni sobre la fecha exacta de la toma, ya que el sistema selecciona todas las fechas posibles en función del paso del satélite y finalmente se toma una o varias imágenes atendiendo a un criterio de prioridades. A pesar de no conocer con antelación la fecha exacta de la toma de las imágenes ni su extensión geográfica exacta, lo que hubiera permitido tomar datos de campo de forma simultánea para la calibración de las imágenes, la adquisición de éstas supuso una gran oportunidad para complementar la tesis con datos hiperespectrales de satélite, tomados con Hyperion, que fue el primer sensor hiperespectral en órbita terrestre y que contaba con una capacidad muy limitada de toma de datos, de solo unas 12 imágenes al día.

Hyperion es un sensor de tipo “pushbroom” con dos espectrómetros, uno en la región del VIS–NIR y otro en el SWIR. Tiene 242 canales contiguos en el rango espectral entre 360 nm y 2580 nm, con un ancho de banda (FWHM) de 10–12 nm y una resolución espacial de 30 m. La relación señal-ruido (SNR) de Hyperion disminuye a medida que aumenta la longitud de onda: 161:1 a 550 nm, 147:1 a 700 nm, 110:1 a 1125 nm y 40:1 a 2125 nm (Pearlman *et al.* 2003). El campo de visión (FOV) de 0.63° a la altura de 705 km de la órbita de EO-1 permite tomar imágenes con un ancho de barrido (swath width) de 7.5 km. Las tres escenas de Hyperion del área de estudio se adquirieron en las siguientes fechas de 2014: 30 de septiembre



(9:51 UTC), 3 de octubre (10:03 UTC) y 23 de diciembre (10:16 UTC) (Figura 4). Las imágenes, que tienen una longitud de ~100 km, se descargaron gratuitamente de la plataforma EarthExplorer del USGS con un nivel de procesamiento 1T (L1T), corregidas radiométrica y geoméricamente usando puntos de control, y georreferenciadas en el sistema de coordenadas UTM-WGS84-29N. Las imágenes se transformaron al sistema UTM-WGS84-30N, dado que éste fue el que se seleccionó para el resto de imágenes y cartografía de la zona de estudio. En cada imagen, se eliminaron las bandas que no estaban calibradas, las situadas en regiones de fuerte absorción de vapor de agua atmosférico y las localizadas en la región de solape de los dos espectrómetros. También se descartaron las bandas inestables con un valor bajo de relación señal-ruido (SNR). En la tesis se han utilizado 155 bandas en total, que corresponden al conjunto de bandas estables seleccionado por Datt *et al.* (2003).

Para la tesis se seleccionó la mejor de las tres imágenes Hyperion disponibles, que fue la del 30 de septiembre de 2014. La imagen del 3 de octubre se descartó debido a la presencia de




Figura 4. Composiciones en falso color de las tres imágenes Hyperion del año 2014, tomadas el 30 de septiembre (izquierda), 3 de octubre (centro) y 23 de diciembre (derecha). En las composiciones de color se utilizaron las bandas a 752, 661 y 478 nm en los canales rojo, verde y azul, respectivamente.

nubes en la misma y la del 23 de diciembre por su elevada superficie de zonas en sombra. El bajo ángulo de elevación solar de la imagen del 23 de diciembre ( $17.2^\circ$ ) y el fuerte relieve de la zona de estudio causan una elevada superficie en sombra en la imagen (Figura 4), motivo por el que se descartó el uso de la misma.

La imagen Hyperion del 30 de septiembre fue corregida de atmósfera y topografía usando ATCOR4 (Richter y Schlapfer 2002), que es un software basado en el código de transferencia radiativa MODTRAN5 (MODerate resolution atmospheric TRANsmission). El proceso de corrección de esta imagen se realizó en colaboración con el Departamento de Observación de la Tierra y Atmósfera del INTA, que cuenta con el software ATCOR4 en su laboratorio. Para la generación del DEM utilizado en la corrección topográfica se combinaron varias hojas de DEM de 5 m de resolución espacial obtenidas del IGN y remuestreadas posteriormente a la resolución espacial de Hyperion (30 m). En la corrección atmosférica se seleccionó el modelo de aerosoles “Rural” y se utilizaron mapas de visibilidad y vapor de agua derivados de la propia imagen. La obtención del mapa de vapor de agua se realizó empleando el pico de absorción de agua situado a 1130 nm.

La imagen también se corrigió del efecto de la función de distribución de reflectancia bidireccional (Bidirectional Reflectance Distribution Function, BRDF), que no es despreciable en el área de estudio debido que ésta tiene un relieve muy accidentado. Se probaron varias combinaciones de parámetros de entrada de la corrección BRDF en ATCOR4, y las imágenes de reflectividad obtenidas usando las distintas combinaciones de parámetros se compararon con unos valores de reflectividad de referencia para determinar la corrección que proporcionaba los mejores resultados. Dado que no fue posible la toma de datos de reflectividad en el campo de forma simultánea a la adquisición de la imagen Hyperion, al no conocer con antelación la fecha exacta de la toma, se consideraron como datos de reflectividad de referencia los mejores disponibles, que fueron los obtenidos de una imagen MODIS adquirida 1 hora y 2 minutos después de la toma de la imagen Hyperion. El producto de reflectividad en superficie de MODIS utilizado fue el de mejor resolución espacial, 250 m (MOD09GQ). La comparación entre los valores de reflectividad de MODIS y los de Hyperion obtenidos usando distintas combinaciones de parámetros en la corrección BRDF se realizó en 12 regiones de la escena: 6 en laderas orientadas al Sol y 6 en laderas no orientadas al Sol. La imagen corregida del efecto BRDF cuyos valores de reflectividad fueron más similares a los de MODIS en estas 12 regiones se consideró como la mejor y fue la que se empleó en la tesis.

La mejor corrección del efecto BRDF incluyó dos correcciones por separado, una para las áreas de vegetación de la imagen y otra para las áreas no vegetadas.

Tras una inspección visual de la imagen corregida, se apreció la presencia de ruido residual y un ligero bandeo vertical en algunas bandas de la imagen. Para la reducción del ruido y del bandeo se utilizó una transformación de componentes principales (Richards 2013), que convirtió la imagen corregida en un conjunto de 155 bandas linealmente independientes o componentes principales. Las primeras componentes contienen la mayor parte de la varianza de la imagen, mientras que las últimas componentes contienen menor información y mayor ruido. Se aplicó una rotación inversa para transformar las componentes principales al espacio de la imagen original, pero usando solamente las cuatro primeras componentes, que no estaban afectadas por ruido y contenían el 98.6 % de la varianza de la imagen. La imagen Hyperion con 155 bandas obtenida tras la reducción del ruido y del bandeo es la que se ha empleado en la tesis.

## **1.6. Preguntas de investigación e hipótesis**

El proyecto de tesis se ha diseñado para responder a las siguientes preguntas de investigación:

- ¿Es posible estimar el contenido de carbono orgánico de la capa superficial del suelo a escala de teledetección, utilizando sensores hiperspectrales (con decenas o cientos de bandas) en la región espectral del óptico (VIS–NIR–SWIR)? ¿Es posible realizar también la estimación con sensores multispectrales (con un número reducido de bandas, habitualmente menor a ~20)?
- ¿Cuáles son las regiones del espectro y las longitudes de onda más importantes para estimar el carbono orgánico del suelo?
- ¿Qué sensores aeroportados o desde satélite son más adecuados para estimar el carbono orgánico del suelo?
- ¿Es posible transferir los modelos de carbono orgánico del suelo obtenidos con espectroscopía VIS–NIR–SWIR en el laboratorio a imágenes hiperspectrales y obtener estimaciones a escala de teledetección?
- ¿Es posible estimar el carbono orgánico del suelo a escala de teledetección con técnicas estadísticas más sencillas que el método de mínimos cuadrados parciales (PLSR),

utilizado habitualmente en el ámbito de la espectroscopía y la teledetección hiperespectral?

El desarrollo del proyecto de tesis se basa en las siguientes hipótesis:

- Existe una relación estadística entre el contenido de carbono del suelo y la respuesta espectral del suelo en la región del óptico.
- Existen regiones espectrales en el óptico y longitudes de onda especialmente importantes para estimar el carbono orgánico del suelo.
- Existen sensores en teledetección, principalmente hiperespectrales, con una configuración espectral adecuada para estimar el carbono orgánico del suelo.
- Es posible transferir los modelos de carbono orgánico del suelo obtenidos con espectroscopía VIS–NIR–SWIR en el laboratorio a imágenes hiperespectrales y obtener estimaciones a escala de teledetección.
- Para la estimación del carbono del suelo a escala de teledetección, es posible construir modelos de regresión lineal múltiple basados en índices sencillos obtenidos a partir de imágenes hiperespectrales en la región del óptico.

### **1.7. Objetivos**

El objetivo general de la tesis ha sido evaluar la posibilidad de la espectroscopía y la teledetección en la región espectral del óptico (VIS–NIR–SWIR) para estimar el carbono orgánico de la capa superficial del suelo en zonas quemadas del suroccidente de Asturias.

Los objetivos específicos de la tesis han sido los siguientes:

1. Analizar el potencial de la espectroscopía VIS–NIR–SWIR en el laboratorio y las técnicas estadísticas multivariantes para estimar el contenido de carbono orgánico del suelo en zonas quemadas, como alternativa a los métodos convencionales de análisis químico utilizados habitualmente en el laboratorio. Se ha analizado el estado actual y las tendencias de la espectroscopía para estimar propiedades edáficas, especialmente el carbono orgánico del suelo, y se han seleccionado y aplicado en la tesis los métodos que han proporcionado mejores resultados en estudios previos.
2. Identificar los sensores de teledetección y las regiones del espectro óptico con mayor potencial para estimar el carbono orgánico del suelo. Se han evaluado las

características espectrales (número de bandas, localización y ancho de banda) de cinco sensores aeroportados o desde satélite, tres de ellos hiperespectrales (CASI, AHS e Hyperion) y dos multiespectrales (Landsat-TM5 y MODIS). La evaluación se ha realizado en cuatro regiones del espectro: VIS, NIR, SWIR y VIS–NIR–SWIR.

3. Analizar la posibilidad de transferir los modelos de predicción de carbono del suelo obtenidos con espectroscopía VIS–NIR–SWIR en el laboratorio a imágenes hiperespectrales y obtener estimaciones a escala de teledetección. Se han transferido a las imágenes los modelos que han proporcionado los mejores resultados en el laboratorio y se ha evaluado la precisión de las estimaciones.
4. Identificar las bandas de cada sensor que son más importantes para estimar el carbono orgánico del suelo. La identificación se ha realizado en aquellos sensores que han proporcionado mejores resultados.
5. Desarrollar algoritmos para estimar el carbono orgánico del suelo a escala de teledetección basados en técnicas estadísticas más sencillas que el método PLSR, utilizado habitualmente en el ámbito de la espectroscopía y la teledetección hiperespectral. Como alternativa al método PLSR, se ha estudiado la posibilidad de usar modelos de regresión lineal múltiple basados en índices de diferencia normalizada.



## Capítulo II. Resultados y discusión

### 2.1. Análisis químico de las muestras de suelo

Los resultados de los análisis químicos realizados en el laboratorio para las muestras individuales y las muestras de las parcelas de validación se resumen en la Tabla 4, y han sido presentados como resultados de esta tesis en Fernández *et al.* (2016) y Peón *et al.* (2017b). Los resultados mostraron que el área de estudio es heterogénea, con variaciones amplias en el carbono del suelo, lo que concuerda bien con los resultados obtenidos en estudios realizados anteriormente en esta región (Fernández *et al.* 2005; Santín *et al.* 2008). El contenido medio de carbono orgánico total de las muestras fue del ~30 % y el de carbono oxidable del ~20 %. Los valores máximos de carbono fueron relativamente altos, superiores a un 45 % en TOC y a un 30 % en OC, y podrían tener un origen geomorfológico relacionado con la acumulación de materia orgánica en paleosuelos heredados de glaciaciones del Pleistoceno, situados en la parte superior de las laderas. Los valores mínimos de carbono, inferiores a un 5 % en TOC y a un 3 % en OC, se relacionaron con la degradación erosiva producida en las laderas quemadas en las que el suelo inalterado corresponde principalmente a un regolito de grano grueso. Los incendios frecuentes en estas laderas han causado una degradación del suelo muy intensa y como resultado estos suelos tienen horizontes orgánicos de muy bajo espesor (Fernández *et al.* 2005; Menéndez Duarte *et al.* 2008). Los valores más altos de carbono se obtuvieron principalmente en el norte y centro del área de estudio, y los valores más bajos en el sur (Figura 1). Se observó una correlación positiva fuerte entre TOC y OC, con un coeficiente de correlación de Pearson (R) de 0.92 en las 89 muestras de suelo individuales y 0.97 en las 12 muestras de parcela. Dado que los análisis del carbono oxidable y del carbono orgánico total

Tabla 4. Estadísticos de las muestras de suelo.

	Muestras individuales utilizadas para espectroscopía (n = 89)		Subconjunto de muestras individuales utilizadas para teledetección con la imagen AHS (n = 39)		Muestras de parcela utilizadas para validar los modelos obtenidos con la imagen AHS (n = 12)	
	TOC (%)	OC (%)	TOC (%)	OC (%)	TOC (%)	OC (%)
Mínimo	4.3	2.7	4.3	2.7	4.5	2.9
Máximo	63.2	37.9	51.7	37.9	45.9	33.8
Media	29.4	19.5	33.3	22.5	25.7	18.1
Desviación típica	14.9	10.3	14.6	10.3	11.2	8.3

n = número de muestras; TOC = carbono orgánico total (Total Organic Carbon); OC = carbono oxidable (Oxidizable Carbon).

de las muestras se realizaron mediante métodos distintos y en dos laboratorios independientes, esta fuerte correlación es un indicador de la alta fiabilidad de los resultados obtenidos.

## **2.2. Estimación del carbono del suelo mediante espectroscopía**

### **2.2.1. Técnica PLSR y validación cruzada**

Con el fin de evaluar el potencial de la espectroscopía de laboratorio en el VIS–NIR–SWIR para estimar el carbono del suelo, como posible alternativa a los métodos estándar de laboratorio, se ha utilizado el conjunto de 89 muestras de suelo individuales. Los datos disponibles para cada muestra son, por una parte, su contenido en carbono oxidable y en carbono orgánico total, determinados en el laboratorio mediante oxidación química y combustión en seco, respectivamente; y por otra, los espectros de reflectividad en el VIS–NIR–SWIR (350–2500 nm) obtenidos en el laboratorio usando el espectrofotómetro ASD LabSpec® 2600.

La técnica utilizada para modelizar el carbono del suelo y relacionar el contenido en carbono de las muestras con sus espectros de reflectividad fue la regresión de mínimos cuadrados parciales o PLSR, por sus siglas en inglés (Wold *et al.* 2001). El PLSR es una técnica estadística multivariante utilizada frecuentemente en el ámbito de la quimiometría y en el análisis espectral cuantitativo de las propiedades del suelo. Esta técnica permite construir modelos de predicción cuando se dispone de un número elevado de variables predictoras que son altamente colineales. Cuando se ajusta un modelo PLSR se espera encontrar un pequeño conjunto de componentes o variables latentes que expliquen la mayor parte de la variación observada en las variables predictoras y en las variables respuesta (Haaland y Thomas 1988; Viscarra Rossel *et al.* 2006b). El número de componentes a incluir en cada modelo se determinó mediante validación cruzada dejando-uno-fuera (leave-one-out cross-validation, LOO X-val), seleccionando como número óptimo de componentes aquél que minimizase el Criterio de Información de Akaike (Akaike Information Criterion, AIC), para evitar el infra- y el sobre-ajuste del modelo final (Akaike 1969; Li *et al.* 2002). A menor valor de AIC, mejor es el modelo.

La identificación de las longitudes de onda más importantes para la predicción del carbono mediante espectroscopía en el laboratorio se realizó empleando los coeficientes PLSR (b) (Haaland y Thomas 1988) y la importancia de la variable en la proyección (Variable Importance for Projection, VIP) (Wold *et al.* 2001), siguiendo la metodología de Viscarra



Rossel *et al.* (2008). La utilidad del uso del VIP para identificar variables predictoras relevantes se describe con mayor detalle en Chong y Jun (2005). A mayor valor absoluto de los coeficientes  $b$  y a mayor valor del VIP, más importante es la variable, de acuerdo a Wold *et al.* (2001). Las longitudes de onda más importantes se identificaron fijando umbrales en  $b$  y en el VIP. Los umbrales de  $b$  se basaron en sus desviaciones típicas (Viscarra Rossel *et al.* 2008), y los umbrales del VIP se fijaron en el valor 1, siguiendo la sugerencia de Chong y Jun (2005). Estos umbrales han sido utilizados también en otros trabajos recientes basados en PLSR y espectroscopía en el VIS–NIR–SWIR (Gomez *et al.* 2015). En la Figura 5 se muestra el proceso realizado para estimar el carbono del suelo utilizando espectroscopía de laboratorio y el proceso para identificar las longitudes de onda más importantes. En esta figura, publicada en Peón *et al.* (2017a), se incluye también el proceso de identificación de los sensores más adecuados para estimar el carbono del suelo, que será descrito con más detalle en el apartado siguiente de la memoria.

Para analizar la calidad de los modelos PLSR se utilizaron tres parámetros: el coeficiente de determinación de la validación cruzada ( $R^2_{cv}$ ), el error cuadrático medio de la validación

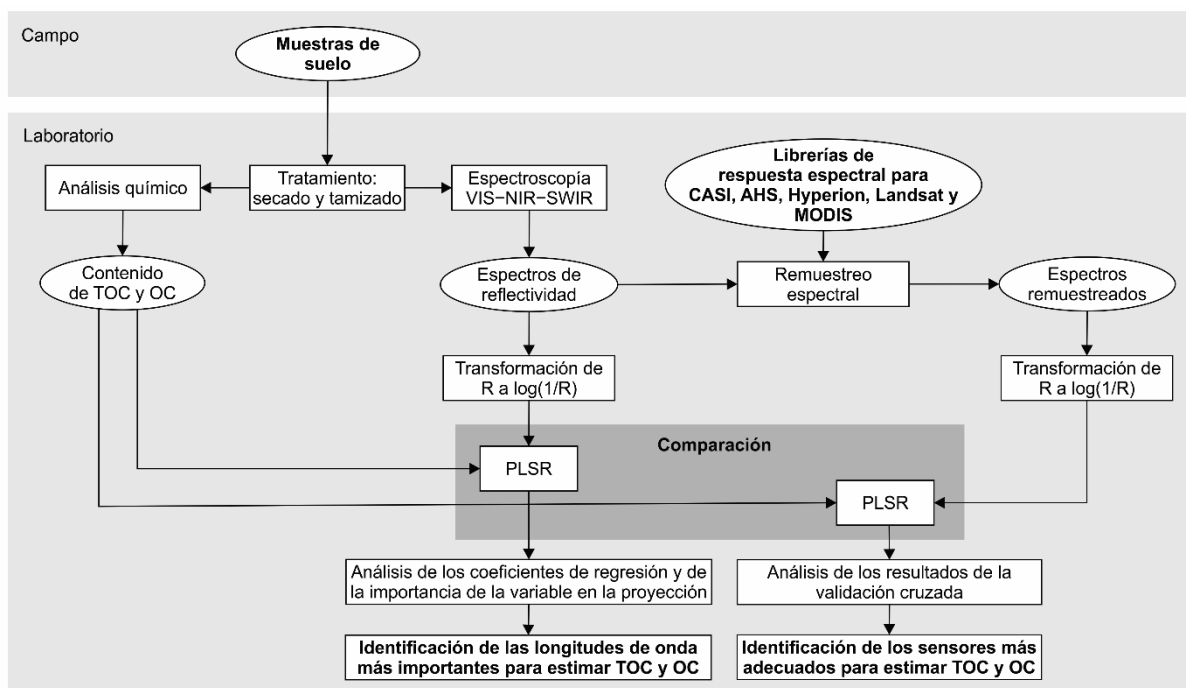


Figura 5. Diagrama de flujo para la identificación de las longitudes de onda y los sensores más adecuados para estimar el carbono del suelo (adaptado de Peón *et al.* 2017a). R = reflectividad; TOC = carbono orgánico total (Total Organic Carbon); OC = carbono oxidable (Oxidizable Carbon); VIS–NIR–SWIR = visible–infrarrojo próximo–infrarrojo medio de onda corta (visible–Near-Infrared–Short-Wave Infrared); PLSR = regresión de mínimos cuadrados parciales (Partial Least–Squares Regression).

cruzada ( $RMSE_{cv}$ ) y el cociente entre la desviación típica de la muestra y el error cuadrático medio, o RPD (Ratio of Performance to Deviation). El modelo con mayor valor de RPD es considerado como el mejor modelo. Chang *et al.* (2001) definieron tres categorías de modelos en función del valor de RPD: los modelos de categoría I ( $RPD > 2$ ) se consideran buenos y capaces de predecir de forma precisa la propiedad del suelo; los modelos de categoría II ( $2 > RPD > 1.4$ ) pertenecen a una clase intermedia y se caracterizan por una capacidad de predicción más limitada; y los modelos de categoría III ( $RPD < 1.4$ ) se considera que no tienen capacidad para predecir de forma precisa la propiedad del suelo.

### ***2.2.2. Modelos PLSR para estimar el carbono del suelo y regiones del espectro más importantes para la predicción***

Los modelos PLSR para predecir el carbono del suelo se pueden generar utilizando directamente los espectros de reflectividad medidos con el espectrofotómetro en el laboratorio. Sin embargo, se suelen aplicar distintas técnicas de pretratamiento a los espectros, ya que habitualmente la precisión de los modelos suele mejorar al aplicar estas técnicas. En la tesis se probaron varias técnicas de pretratamiento utilizadas frecuentemente en espectroscopía, entre las que se incluyen la primera y la segunda derivada de los espectros, la transformación  $A = \log(1/R)$  que convierte los espectros de reflectividad (R) en espectros de absorptividad (A), el filtro de suavizado de Savitzky-Golay usando diferentes tamaños de ventana (Savitzky y Golay 1964), el centrado de los espectros que consiste en restar a cada espectro el espectro medio, y distintas combinaciones de estas técnicas. En la Tabla 5 se muestran varios indicadores de la calidad y la precisión de los modelos PLSR obtenidos aplicando varias técnicas de pretratamiento. Estos modelos se han realizado utilizando los espectros en el VIS–NIR–SWIR del conjunto de 89 muestras de suelo individuales. La mejor técnica, aquella con el valor más alto de RPD, fue la transformación  $\log(1/R)$ , tanto en los modelos de carbono orgánico total como en los de carbono oxidable (Tabla 5), y fue la que se seleccionó para pretratar los espectros de laboratorio empleados en la tesis. El RPD de los modelos con esta transformación fue entre un 18 % y un 56 % mejor que el de los modelos basados en espectros de reflectividad (R), lo que concuerda bien con otros estudios previos en los que también se observó un aumento notable del RPD al aplicar esta transformación (Griffiths y Dahm 2007). Puede verse en la Tabla 5, que a igual valor de RPD en distintos pretratamientos, se ha

Tabla 5. Indicadores de calidad de los modelos PLSR para estimar el carbono del suelo obtenidos usando los espectros de reflectividad en el VIS–NIR–SWIR con distintos pretratamientos.

Propiedad del suelo	Pretratamiento	NF	AIC	$R^2_{cv}$	RMSE <sub>cv</sub> (%)	RPD
TOC (%)	Sin pretratamiento (R)	8	204.7	0.70	8.33	1.79
	Primera derivada de R	6	203.6	0.67	8.61	1.73
	Segunda derivada de R	5	237.6	0.30	12.90	1.16
	R con filtro SG (tamaño de ventana 3)	8	204.7	0.70	8.33	1.79
	log(1/R)	7	187.3	0.78	7.01	2.13
	Primera derivada de log(1/R)	6	189.9	0.76	7.38	2.02
	Segunda derivada de log(1/R)	6	251.1	0.16	14.69	1.02
	log(1/R) con filtro SG (tamaño de ventana 3)	7	187.4	0.77	7.02	2.13
	log(1/R) con espectros centrados	7	187.3	0.78	7.01	2.13
OC (%)	Sin pretratamiento (R)	8	167.5	0.73	5.49	1.88
	Primera derivada de R	6	164.3	0.72	5.53	1.87
	Segunda derivada de R	5	200.8	0.36	8.53	1.21
	R con filtro SG (tamaño de ventana 3)	8	167.5	0.73	5.49	1.88
	log(1/R)	9	130.2	0.88	3.53	2.93
	Primera derivada de log(1/R)	6	139.7	0.83	4.20	2.46
	Segunda derivada de log(1/R)	8	219.3	0.22	9.82	1.05
	log(1/R) con filtro SG (tamaño de ventana 3)	9	130.0	0.88	3.52	2.93
	log(1/R) con espectros centrados	9	132.0	0.88	3.60	2.87

Los modelos se han obtenido con los espectros de las 89 muestras de suelo individuales. R = reflectividad; SG = Savitzky-Golay; NF = número de variables latentes o componentes PLSR (PLSR factors); AIC = Criterio de Información de Akaike (Akaike Information Criterion);  $R^2_{cv}$  = coeficiente de determinación de la validación cruzada; RMSE<sub>cv</sub> = error cuadrático medio de la validación cruzada; RPD = Ratio of Performance to Deviation (cociente entre la desviación típica de la muestra y el error cuadrático medio).

preferido seleccionar el más sencillo. Por ejemplo, en el caso del TOC, se ha considerado como mejor técnica la transformación log(1/R) en vez de la transformación log(1/R) con el filtro de Savitzky-Golay (tamaño de ventana 3) o la transformación log(1/R) con los espectros centrados; todas ellas con un valor de RPD = 2.13.

Para analizar el potencial de las distintas regiones del espectro óptico para estimar el carbono del suelo mediante espectroscopía de laboratorio, se realizaron modelos PLSR usando tanto los espectros completos en la región del óptico (VIS–NIR–SWIR; 400–2450 nm), como la parte de los mismos correspondiente al rango del visible (VIS; 400–700 nm), del infrarrojo próximo o cercano (Near-Infrared, NIR; 700–1300 nm) y del infrarrojo medio de onda corta (Short-Wave Infrared, SWIR; 1300–2450 nm). En la Tabla 6 se muestran varios indicadores de la calidad y la precisión de los modelos de carbono obtenidos en estas cuatro regiones del espectro. En esta tabla también se incluyen los modelos basados en espectros de laboratorio remuestreados para cinco sensores multiespectrales e hiperspectrales usados en teledetección. En este apartado se analizarán exclusivamente los modelos basados en los espectros de

Tabla 6. Indicadores de calidad de los modelos PLSR para estimar el carbono del suelo usando espectroscopía de laboratorio (adaptado de Peón *et al.* 2017a).

Propiedad del suelo	Región del espectro	Parámetro <sup>a</sup>	Espectros de laboratorio	Espectros de laboratorio remuestreados					
			ASD-LS <sup>b</sup>	CASI	AHS	HYP <sup>c</sup>	L5TM <sup>d</sup>	MODIS	
TOC (%)	VIS	NF	6	6	6	6	6	6	
		AIC	186.6	188.1	185.8	187.1	190.7		
		R <sup>2</sup> <sub>cv</sub>	0.77	0.76	0.78	0.77	0.75		
		RMSE <sub>cv</sub> (%)	7.11	7.24	7.05	7.15	7.44		
	NIR	RPD	2.10	2.06	2.12	2.09	2.00		
		NF	6	8	7	6	6		
		AIC	196.6	211.0	214.8	196.8	220.7		
		R <sup>2</sup> <sub>cv</sub>	0.72	0.65	0.59	0.72	0.51		
	SWIR	RMSE <sub>cv</sub> (%)	7.96	8.95	9.54	7.97	10.44		
		RPD	1.87	1.67	1.56	1.87	1.43		
		NF	4		6	5	3		
		AIC	181.5		180.9	184.1	211.3		
	VIS-NIR-SWIR	R <sup>2</sup> <sub>cv</sub>	0.78		0.80	0.77	0.55		
		RMSE <sub>cv</sub> (%)	7.02		6.67	7.07	10.04		
		RPD	2.12		2.24	2.11	1.49		
		NF	7	8	7	7	6	7	
	OC (%)	VIS	AIC	187.3	189.9	181.2	185.7	209.8	192.4
			R <sup>2</sup> <sub>cv</sub>	0.78	0.78	0.81	0.79	0.62	0.75
			RMSE <sub>cv</sub> (%)	7.01	7.06	6.55	6.88	9.23	7.42
			RPD	2.13	2.11	2.28	2.17	1.62	2.01
NIR		NF	5	5	6	5	7		
		AIC	133.3	134.3	132.6	133.0	134.0		
		R <sup>2</sup> <sub>cv</sub>	0.85	0.85	0.86	0.85	0.86		
		RMSE <sub>cv</sub> (%)	4.00	4.04	3.88	3.98	3.85		
SWIR		RPD	2.58	2.56	2.66	2.59	2.68		
		NF	11	8	8	10	6		
		AIC	153.6	164.2	164.4	158.6	168.9		
		R <sup>2</sup> <sub>cv</sub>	0.82	0.75	0.74	0.79	0.68		
VIS-NIR-SWIR		RMSE <sub>cv</sub> (%)	4.39	5.29	5.30	4.75	5.83		
		RPD	2.35	1.95	1.95	2.18	1.77		
		NF	4		4	4	3		
		AIC	133.5		135.3	135.2	169.4		
NIR		R <sup>2</sup> <sub>cv</sub>	0.84		0.84	0.84	0.63		
		RMSE <sub>cv</sub> (%)	4.10		4.18	4.18	6.27		
		RPD	2.52		2.47	2.47	1.65		
		NF	9	8	7	7	6	9	
VIS-NIR-SWIR	AIC	130.2	133.7	124.8	130.3	157.0	129.5		
	R <sup>2</sup> <sub>cv</sub>	0.88	0.87	0.89	0.87	0.75	0.88		
	RMSE <sub>cv</sub> (%)	3.53	3.75	3.47	3.69	5.10	3.50		
	RPD	2.93	2.75	2.97	2.80	2.03	2.95		

Los modelos se han obtenido usando los espectros log(1/R) de las 89 muestras de suelo individuales. <sup>a</sup> La descripción de estos parámetros se puede consultar en el pie de la Tabla 5. <sup>b</sup> ASD-LS = espectrofotómetro Analytical Spectral Devices LabSpec® 2600. <sup>c</sup> HYP = Hyperion. <sup>d</sup> L5TM = Landsat 5 Thematic Mapper.

laboratorio medidos con el espectrofotómetro ASD, mientras que los modelos basados en espectros remuestreados (cuyos resultados se muestran en las 5 últimas columnas de la Tabla 6) serán analizados detalladamente en el apartado siguiente de la memoria.

Se obtuvieron modelos precisos para predecir el carbono del suelo usando espectroscopía de laboratorio, tanto para TOC como para OC ( $R^2_{cv} > 0.78$  y  $RPD > 2.13$ ) (Tabla 6). Entre las dos propiedades del suelo modelizadas, OC fue estimado con mayor precisión. De acuerdo con la clasificación de modelos basada en el valor de RPD propuesta por Chang *et al.* (2001), es posible afirmar que la espectroscopía de laboratorio es una técnica fiable para estimar TOC y OC. Los resultados obtenidos en la tesis son similares a los obtenidos en otros estudios previos en los que también se estimó el carbono del suelo usando espectroscopía de laboratorio: Chang y Laird (2002) ( $R^2 = 0.89$ ), Martin *et al.* (2002) ( $R^2 = 0.75$ ;  $RPD = 1.97$ ), y Mouazen *et al.* (2010) ( $R^2 = 0.8$ ) (en la Tabla 1 se pueden consultar más detalles de estos tres estudios). Los mejores modelos se obtuvieron usando la región del VIS–NIR–SWIR, pero cabe destacar que se obtuvieron resultados similares usando únicamente las regiones del VIS y del SWIR. Los peores modelos se obtuvieron usando la región del NIR.

En la Figura 6 se muestran los coeficientes de regresión y los valores de la importancia de la variable en proyección de los modelos PLSR basados en espectroscopía de laboratorio en la región VIS–NIR–SWIR. Las longitudes de onda más importantes para la estimación del TOC y OC, identificadas estableciendo umbrales en los coeficientes de regresión  $b$  y en el VIP, se muestran en la Tabla 7. En el VIS, los coeficientes de regresión fueron similares para el TOC y OC. En el modelo de TOC fueron importantes la región del azul entre 400–413 nm y la región del verde entre 556–570 nm. Estos resultados concuerdan bien con los obtenidos por Viscarra Rossel *et al.* (2006b), quienes observaron picos importantes para la estimación del carbono a 410 y 570 nm; y con los resultados de Vasques *et al.* (2009), quienes también encontraron coeficientes de regresión significativos con valor positivo entre 380–430 nm. Krishnan *et al.* (1980) observaron que 564 nm era una longitud de onda óptima para predecir la materia orgánica del suelo. La región entre 471–526 nm fue una región importante para la predicción del TOC, lo que es consistente con los resultados de Vasques *et al.* (2009), quienes también obtuvieron coeficientes de regresión significativos con valor negativo en esta región. Además de estas regiones, también fueron importantes para la estimación del OC dos rangos de longitudes de onda del VIS: 651–668 nm, atribuido a los pigmentos de clorofila alrededor de 664 nm (Ben-Dor *et al.* 1997), y la región del rojo entre 692–703 nm. Los resultados obtenidos en esta tesis están en la línea de los obtenidos en estudios previos, en los que el VIS también fue una región importante para la estimación del carbono y la materia orgánica (Krishnan *et al.* 1980; Cozzolino y Morón 2006; Mouazen *et al.* 2007; Stevens *et al.* 2010).

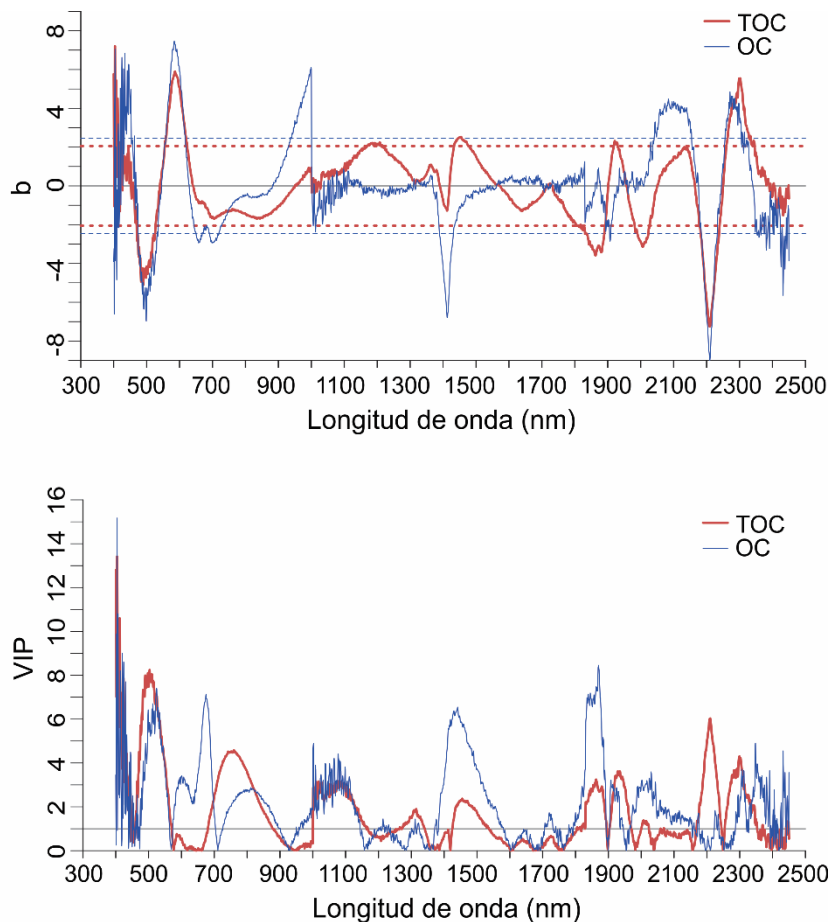


Figura 6. Coeficientes de regresión (b) de los modelos PLSR para estimar el carbono del suelo usando espectroscopía de laboratorio (arriba), e importancia de la variable en la proyección (VIP = Variable Importance for Projection) (abajo). Las líneas horizontales discontinuas en el gráfico superior representan los umbrales basados en las desviaciones típicas de los coeficientes de regresión (en color rojo los correspondientes al carbono orgánico total, TOC, con un valor de  $\pm 2.05$ ; y en color azul los del carbono oxidable, OC, con un valor de  $\pm 2.46$ ). La línea horizontal sólida de color negro en el gráfico inferior representa el umbral de VIP fijado en el valor 1 (adaptado de Peón *et al.* 2017a).

En la región del NIR no se identificaron regiones relevantes para la predicción del carbono del suelo, excepto la región entre 961–1000 nm, que fue importante para la estimación del OC. Esta región alrededor de 970 nm también fue importante en los modelos PLSR de materia orgánica de Kooistra *et al.* (2003). En el SWIR se encontraron regiones importantes para la predicción del TOC y OC (Tabla 7). Las regiones más importantes para estimar TOC fueron: 2180–2239 nm, que también fue identificada por Morgan *et al.* (2009) y Vasques *et al.* (2009) como una región relevante que podría estar asociada a compuestos orgánicos intensamente mineralizados (Bellon-Maurel y McBratney 2011); y 2261–2346 nm, que también fue relevante en los modelos de Vasques *et al.* (2009). Para la predicción del OC fueron importantes dos regiones adicionales del SWIR: 1390–1431 nm, que también fue identificada por Kooistra *et al.* (2003) y podría atribuirse a las absorciones de los enlaces O–H (Viscarra

Rossel *et al.* 2006b); y 2041–2154 nm, importante también en los modelos de Vasques *et al.* (2009). En esta última región, a 2100 nm, McMorro *et al.* (2004) observaron picos de absorción relacionados con la celulosa. El SWIR se ha revelado como una región importante para estimar el carbono del suelo en multitud de estudios previos, siendo el mejor rango para la predicción el situado entre 1650 y 2500 nm (Lee *et al.* 2009; Morgan *et al.* 2009; Vasques *et al.* 2009; Bellon-Maurel y McBratney 2011).

Tabla 7. Longitudes de onda más importantes para la predicción del TOC y OC obtenidas de los modelos basados en espectros de laboratorio en el VIS–NIR–SWIR (publicado en Peón *et al.* 2017a).

Región del espectro	Longitud de onda (nm)	
	TOC	OC
VIS	400–413 (+)	400–409 (–)
	420–425 (+)	420–452 (+)
	471–526 (–)	475–534 (–)
	556–570 (+)	559–563 (+)
		574–616 (+)
		651–668 (–)
		692–703 (–)
		961–1000 (+)
NIR		
SWIR	1434–1476 (+)	1390–1431 (–)
	1805–1814 (–)	1906–1908 (–)
	1819–1892 (–)	2041–2154 (+)
	1919–1930 (+)	2223–2231 (–)
	2001–2023 (–)	2287–2315 (+)
	2180–2239 (–)	2353–2365 (–)
	2261–2346 (+)	2381–2385 (–)
	2425–2444 (–)	

El signo mostrado entre paréntesis en cada rango de longitudes de onda corresponde al signo de los coeficientes de regresión del modelo PLSR (coeficientes b).

### 2.3. Identificación de los sensores de teledetección más adecuados para estimar el carbono del suelo

#### 2.3.1. Método para identificar los sensores más adecuados para estimar el carbono del suelo. Remuestreo de los espectros de laboratorio

Para estimar el carbono del suelo usando teledetección es fundamental elegir un sensor adecuado. Las características espectrales varían notablemente entre los distintos sensores de teledetección disponibles, lo que dificulta considerablemente la elección del sensor idóneo. Con el objeto de identificar aquellos sensores de teledetección más adecuados para estimar el carbono del suelo, como paso previo a la predicción usando imágenes de los mismos, se realizó una simulación utilizando los espectros de reflectividad obtenidos en el laboratorio con el espectrofotómetro ASD. Se evaluaron las características espectrales (número de bandas,

localización y ancho de banda) de cinco sensores aeroportados o desde satélite, en cuatro regiones del espectro: VIS, NIR, SWIR y VIS–NIR–SWIR. De los cinco sensores seleccionados, tres de ellos son hiperespectrales (CASI, AHS e Hyperion) y dos multiespectrales (Landsat-TM5 y MODIS).

Los espectros de reflectividad en el VIS–NIR–SWIR del conjunto de 89 muestras de suelo individuales se remuestrearon para simular la reflectividad que tendrían estas muestras si fueran observadas por cada uno de los cinco sensores seleccionados. El proceso realizado para remuestrear los espectros de reflectividad e identificar los sensores más adecuados para estimar el carbono del suelo, publicado como resultado de esta tesis en Peón *et al.* (2017a), se muestra en la Figura 5. Inicialmente se seleccionaron los sensores a evaluar. Se procuró elegir sensores en la región del óptico (VIS–NIR–SWIR) con características espectrales muy distintas; todos ellos utilizados habitualmente en teledetección, desde los hiperespectrales aeroportados CASI y AHS, usados principalmente para fines de investigación, hasta sensores multiespectrales mucho más utilizados por la comunidad científica como son el Landsat-TM5 y MODIS (Salomonson *et al.* 1989). Para realizar esta evaluación se prefirió utilizar el sensor Landsat-TM5 en vez de otros sensores Landsat más recientes, dado que la disponibilidad de un extenso archivo histórico de imágenes de este sensor, con más de 28 años de observaciones, hace que resulte muy adecuado para realizar análisis multitemporales. Además, dado que las características espectrales de los sensores ópticos de las distintas generaciones de Landsat son muy similares entre sí, los resultados obtenidos en esta tesis usando Landsat-TM5 serán también muy parecidos a los obtenidos utilizando otros sensores más recientes como los de los satélites Landsat 7 y Landsat 8.

En cada uno de los cinco sensores seleccionados se excluyeron las bandas situadas fuera del rango de los espectros de laboratorio entre 400–2450 nm, las bandas afectadas habitualmente por ruido y aquellas situadas en regiones de fuerte absorción de vapor de agua atmosférico. En el caso de Hyperion se utilizaron 155 bandas en total, las correspondientes al conjunto de bandas estables seleccionado por Datt *et al.* (2003). El número de bandas seleccionadas y las especificaciones técnicas de cada sensor se incluyen en la Tabla 3. Para remuestrear los espectros de reflectividad obtenidos con el espectrofotómetro ASD se utilizaron las librerías de respuesta espectral de los cinco sensores. Las curvas de respuesta espectral que forman estas librerías se pueden ver en la Figura 7. Las librerías para CASI e Hyperion se obtuvieron



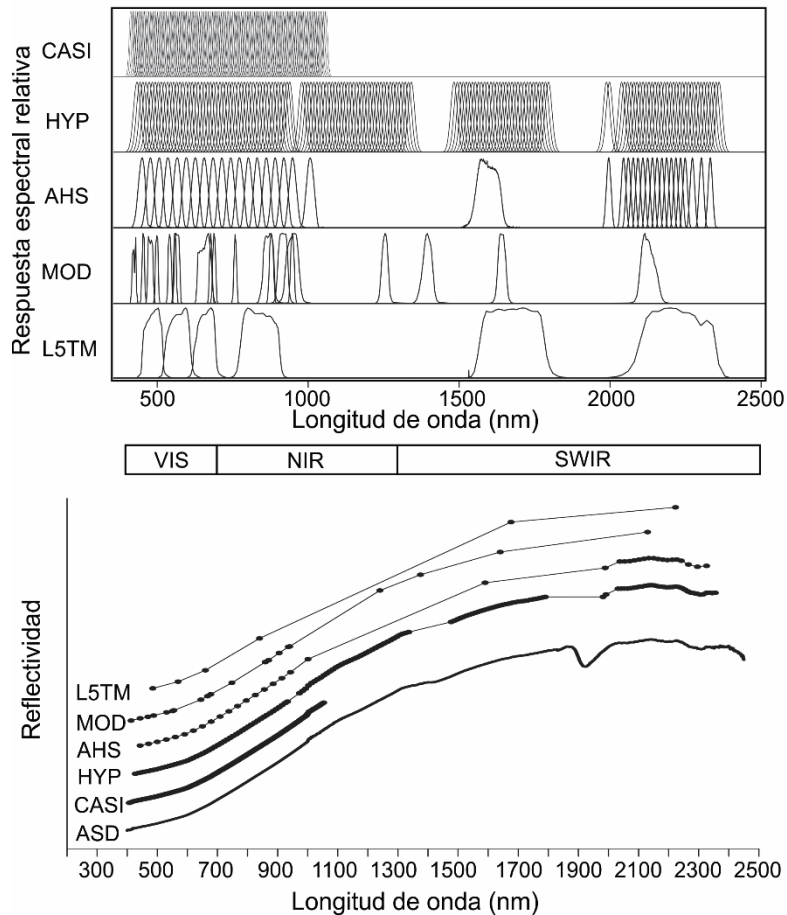


Figura 7. Respuesta espectral relativa de los cinco sensores analizados: CASI, AHS, HYP (Hyperion), MOD (MODIS) y L5TM (Landsat 5 Thematic Mapper) (arriba). Espectro de reflectividad de una muestra de suelo obtenido con el espectrofotómetro ASD en el VIS–NIR–SWIR y el mismo espectro remuestreado para los cinco sensores (abajo). Los espectros remuestreados se han desplazado verticalmente para una mayor claridad de la figura (adaptado de Peón *et al.* 2017a).

usando un modelo gaussiano con la media y la desviación típica fijadas en el valor de la longitud de onda de cada banda y en el ancho de banda (Full Width at Half Maximum, FWHM), respectivamente. En la Figura 7 también se muestra como ejemplo el espectro de reflectividad de una muestra de suelo remuestreado para los cinco sensores. En esta figura se puede apreciar la degradación gradual que sufre el espectro de reflectividad a medida que disminuye la resolución espectral, desde el espectro de ASD en el VIS–NIR–SWIR, con un intervalo de muestreo de 1 nm; hasta el espectro remuestreado para el sensor Landsat-TM5 con solo 6 bandas en este rango. En el espectro de ASD de la Figura 7 se puede apreciar también el pico de absorción del agua a ~1900 nm (Viscarra Rossel y Behrens 2010; Croft *et al.* 2012).

Los espectros de reflectividad remuestreados para los distintos sensores se transformaron a  $\log(1/R)$  y se obtuvieron cuatro modelos PLSR para cada propiedad del suelo y sensor, uno para cada una de las cuatro regiones espectrales analizadas: VIS, NIR, SWIR y VIS–NIR–SWIR (Figura 5). En el caso del Landsat-TM5 se obtuvo únicamente el modelo en la región del VIS–NIR–SWIR debido al reducido número de bandas (6) de este sensor en este rango. Aunque la técnica PLSR es adecuada principalmente para sensores con un número elevado de bandas, también se utilizó para Landsat-TM5 con el objeto de comparar los resultados entre sensores utilizando el mismo método de modelización. No se obtuvieron modelos PLSR en el SWIR para el sensor CASI dado que este sensor no tiene bandas en esta región. El proceso realizado para obtener los modelos PLSR con los espectros de laboratorio remuestreados fue el mismo que el utilizado con los espectros de laboratorio (descrito en el apartado anterior). En primer lugar se aplicó el mejor pretratamiento a los espectros de reflectividad, que fue la transformación  $\log(1/R)$ ; posteriormente se generaron los modelos PLSR eligiendo el número óptimo de componentes mediante el uso del AIC obtenido en la validación cruzada (LOO X-val); y, por último, se analizó la calidad de los modelos usando los parámetros  $R^2_{cv}$ ,  $RMSE_{cv}$  y RPD.

### ***2.3.2. Modelos PLSR para estimar el carbono del suelo usando los espectros de laboratorio remuestreados***

En la Tabla 6 se muestran varios indicadores de la calidad y la precisión de los modelos PLSR para estimar el carbono del suelo usando los espectros de laboratorio remuestreados. En el VIS los resultados obtenidos con los tres sensores hiperespectrales (CASI, AHS e Hyperion) fueron muy similares a los obtenidos con el espectrofotómetro ASD, tanto para el TOC (RPD = 2.06–2.12) como para el OC (RPD = 2.56–2.66). Los mejores resultados en el VIS se obtuvieron con el sensor AHS. Las mayores diferencias entre sensores se observaron en el NIR. Los mejores modelos se obtuvieron con Hyperion, tanto para el TOC (RPD = 1.87) como para el OC (RPD = 2.18), y fueron similares a los obtenidos con el espectrofotómetro ASD. La estimación con CASI y AHS tuvo una menor precisión, lo que se atribuyó a la distribución de sus bandas en el NIR, situadas únicamente en la región ~700–1050 nm (Figura 7). En el NIR, CASI tiene más bandas que Hyperion y más estrechas (CASI: 74 bandas con FWHM de 6 nm; Hyperion: 57 bandas con FWHM de 10–12 nm); sin embargo, su distribución es menos adecuada para estimar el carbono del suelo que la de las bandas de Hyperion, que cubren completamente la región del NIR entre 700–1300 nm. Además, las bandas de CASI no cubren

la región importante para estimar el carbono, que se sitúa entre 1390–1431 nm (Tabla 7 y Figura 6), lo que podría explicar la menor precisión observada. Los resultados obtenidos en el SWIR con AHS e Hyperion fueron muy similares a los obtenidos con el espectrofotómetro ASD, tanto para el TOC (RPD = 2.11–2.24) como para el OC (RPD = 2.47).

La mejor estimación de ambas propiedades del suelo usando los tres sensores hiperespectrales se obtuvo en el VIS–NIR–SWIR. Los resultados en esta región fueron similares para los tres sensores hiperespectrales y para el espectrofotómetro ASD, con un RPD = 2.11–2.28 en los modelos del TOC y un RPD = 2.75–2.97 en los del OC. De acuerdo con la clasificación de modelos basada en el valor de RPD propuesta por Chang *et al.* (2001), se puede afirmar que estos modelos proporcionan estimaciones precisas. El hecho de que los resultados sean similares para el ASD y para los espectros remuestreados para los tres sensores hiperespectrales estudiados concuerda con lo obtenido por Gomez *et al.* (2008), quienes remuestrearon los espectros de laboratorio para el sensor Hyperion y observaron que la disminución de la resolución espectral asociada al remuestreo no reducía notablemente la precisión de los modelos PLSR, independientemente del rango de variación del carbono y del número de muestras utilizadas. Lu *et al.* (2013) evaluaron la precisión de los modelos PLSR para estimar el carbono y otras propiedades del suelo usando espectros de laboratorio y espectros de laboratorio remuestreados para el sensor Hyperion, y también observaron que la precisión de los modelos basados en espectros remuestreados era muy similar a la obtenida con los espectros de laboratorio sin remuestrear. Estos resultados muestran el gran potencial de la teledetección hiperespectral para estimar el carbono del suelo.

En lo que respecta a los sensores multiespectrales, se obtuvieron modelos precisos para MODIS en el VIS, con un RPD = 2.00 en el modelo del TOC y un RPD = 2.68 en el del OC. La precisión de estos modelos fue muy similar a la de los modelos obtenidos con el espectrofotómetro ASD (Tabla 6). Los modelos basados en las bandas del NIR de MODIS tuvieron una capacidad de predicción limitada, tanto el del TOC (RPD = 1.43) como el del OC (RPD = 1.77). Los modelos basados en las bandas del SWIR de MODIS también tuvieron una precisión limitada. Esta notable bajada de la precisión observada al utilizar los espectros de laboratorio remuestreados para las bandas de MODIS en el NIR y en el SWIR, respecto a utilizar los espectros de ASD, se atribuyó al bajo número de bandas de MODIS en estas regiones: siete bandas en el NIR y solamente tres en el SWIR. La bajada de la precisión se podría atribuir también a la localización de las bandas y al ancho de las mismas. Las bandas

podrían ser demasiado anchas para detectar satisfactoriamente algunos picos de absorción importantes para estimar el carbono del suelo. Cabe destacar que algunas regiones importantes para la predicción del carbono del suelo, como son las regiones entre 2041–2154 nm y entre 2287–2315 nm (Tabla 7 y Figura 6), no están completamente cubiertas por las bandas de MODIS. La precisión de los modelos de MODIS en el VIS–NIR–SWIR fue similar a la obtenida con el sensor ASD, tanto el del TOC como el del OC.

La precisión de los modelos del Landsat-TM5 en el VIS–NIR–SWIR fue menor que la obtenida con el sensor ASD, pero de acuerdo a la clasificación de modelos de Chang *et al.* (2001) el modelo para el OC proporcionó estimaciones que todavía pueden ser consideradas como precisas, con un valor de RPD de 2.03. El modelo para estimar el TOC mostró una capacidad de predicción intermedia (RPD = 1.62). Cabe mencionar que las bandas del Landsat-TM5 no cubren completamente regiones importantes para la predicción del carbono, como son las regiones entre 961–1000 nm y 1390–1431 nm; lo que podría explicar la menor precisión obtenida con este sensor. La banda del Landsat-TM5 situada a 2223 nm es muy ancha (FWHM = 252 nm) e incluye la información de las tres regiones importantes para estimar el carbono situadas entre 2041–2154 nm, 2223–2231 nm y 2287–2315 nm; por lo que esta banda no resulta adecuada para observar separadamente la información contenida en estas tres regiones.

Si se considera solamente la región espectral con mejores resultados en la Tabla 6, que es la región del VIS–NIR–SWIR, no se aprecian diferencias notables entre la precisión de los modelos obtenidos con el sensor ASD (2051 bandas) y los modelos obtenidos con los espectros de ASD remuestreados para los tres sensores hiperespectrales (38–155 bandas) y MODIS (20 bandas). A pesar de la notable diferencia que existe entre el número de bandas del espectrofotómetro ASD y el de estos sensores de teledetección, tanto el TOC como el OC fueron estimados satisfactoriamente usando modelos PLSR con menos de 10 componentes. La precisión más baja se obtuvo en los modelos del Landsat-TM5, pero estos modelos mostraron incluso resultados moderadamente satisfactorios, con un error entre un ~30–45 % mayor que el observado en los modelos de carbono obtenidos con el sensor ASD.

### **2.3.3. Comparación de los modelos PLSR basados en los espectros de laboratorio remuestreados con otros modelos de predicción del carbono del suelo**

Los resultados de los modelos de predicción basados en los espectros de laboratorio remuestreados para los distintos sensores se compararon con los obtenidos anteriormente en otros trabajos en los que se estimó el carbono del suelo a escala local o regional. Esta comparación se realizó con el objeto de analizar el grado de coincidencia entre los resultados de la simulación y los resultados obtenidos en trabajos que usaron datos reales de estos sensores. De esta forma, fue posible analizar los resultados de la simulación desde una perspectiva más amplia, teniendo presente en todo momento que el objetivo último de la simulación era el de identificar los sensores más adecuados para estimar el carbono del suelo y utilizar finalmente datos reales de los mismos para obtener estimaciones a escala local o regional. La comparación entre los resultados obtenidos en la simulación realizada en esta tesis y los obtenidos usando datos reales permitió analizar también el grado de validez y verosimilitud de la simulación realizada. Para comparar los resultados de la validación de los modelos PLSR mostrados en la Tabla 6 con los de otros estudios previos se utilizaron los valores de  $R^2$  y RPD obtenidos en la validación. El uso del RMSE de la validación fue descartado, ya que los valores de éste no son comparables entre estudios en los que el carbono del suelo tenía rangos de variación muy diferentes y en los que el carbono se expresaba en unidades distintas.

En los resultados mostrados en la Tabla 6 se puede ver que se han obtenido modelos precisos para el sensor CASI, con valores de  $R^2$  entre 0.78–0.87 y un RPD entre 2.11–2.75. Stevens *et al.* (2006) y Uno *et al.* (2005) usaron datos del sensor CASI para estimar el carbono del suelo y la materia orgánica en campos agrícolas y obtuvieron valores similares de  $R^2$  ( $R^2 = 0.75$ – $0.85$ ) y valores más bajos de RPD (RPD = 1.57–1.86) que los obtenidos en la simulación realizada en esta tesis.

Los modelos obtenidos en esta tesis para predecir el carbono del suelo usando los espectros remuestreados para AHS también fueron precisos, con un  $R^2 = 0.81$ – $0.89$  y un RPD = 2.28–2.97 (Tabla 6). Stevens *et al.* (2008) estimaron el carbono orgánico del suelo en campos agrícolas usando la técnica de PLSR, tanto en el laboratorio ( $R^2 = 0.76$  y RPD = 2.03) como a escala regional usando imágenes AHS ( $R^2 = 0.54$  y RPD = 1.47). El error obtenido usando datos de AHS fue aproximadamente dos o tres veces mayor que el valor obtenido en el laboratorio. Stevens *et al.* (2010) usaron datos de AHS para estimar el carbono orgánico del

suelo en campos agrícolas y obtuvieron un  $R^2 = 0.72$  y un  $RPD = 1.89$ . Stevens *et al.* (2012) obtuvieron mejores resultados en la predicción del carbono del suelo con el sensor AHS usando un gran número de observaciones y realizando modelos locales para las distintas regiones y texturas del suelo del área de estudio ( $R^2 = 0.79$  y  $RPD = 2.33$ ).

En esta tesis también se estimó el carbono orgánico del suelo utilizando una imagen AHS del área de estudio. Estos resultados se publicaron en Fernández *et al.* (2016) y Peón *et al.* (2017b), y si bien éstos se describirán con mayor detalle en los apartados siguientes de esta memoria, se resumen aquí brevemente para poder comparar los resultados de la simulación con los obtenidos usando datos del sensor AHS. Los modelos de predicción del carbono del suelo de Fernández *et al.* (2016) obtenidos de la simulación tuvieron una precisión satisfactoria, con un  $R^2 = 0.72-0.73$  y un  $RPD = 1.89-1.92$ . Los modelos de Peón *et al.* (2017b) también tuvieron una precisión moderadamente satisfactoria, con un  $R^2 = 0.60-0.62$  y un  $RPD = 1.60-1.62$ . Los modelos de predicción del carbono orgánico del suelo basados en datos del sensor AHS mostraron un valor de RPD un  $\sim 28\%$  (Fernández *et al.* 2016) y un  $\sim 39\%$  (Peón *et al.* 2017b) peor que el obtenido en la simulación realizada usando los espectros de laboratorio remuestreados para AHS. Esta menor precisión obtenida usando datos reales del sensor AHS respecto al uso de datos simulados resulta razonable si consideramos las múltiples limitaciones de la teledetección (absorción de la atmósfera, mezcla espectral, etc.) que no han sido tenidas en cuenta en la simulación.

Los modelos PLSR para estimar el carbono orgánico del suelo usando los espectros remuestreados para Hyperion mostraron un  $R^2 = 0.79-0.87$  y un  $RPD = 2.17-2.80$  (Tabla 6), por lo que estos modelos se consideraron precisos de acuerdo a la clasificación de Chang *et al.* (2001). Estos resultados son mejores que los obtenidos en estudios previos en los que se usaron datos reales de Hyperion: Gomez *et al.* (2008) en campos agrícolas y pastos ( $R^2 = 0.51$  y  $RPD = 1.43$ ); y Lu *et al.* (2013) en campos agrícolas ( $R^2 = 0.63$  y  $RPD = 1.65$ ). Los modelos obtenidos en ambos estudios mostraron una habilidad de predicción intermedia. La precisión de los modelos de Zhang *et al.* (2013), quienes también usaron datos de Hyperion para estimar el carbono y la materia orgánica del suelo en campos agrícolas, fue intermedia, con un  $R^2 = 0.48-0.74$  y un  $RPD = 1.48-1.91$ . Jaber *et al.* (2011) usaron datos de Hyperion para predecir el carbono del suelo en campos agrícolas, pastos y bosques, pero sus modelos de predicción tuvieron muy baja precisión ( $RPD = 0.68$ ). Los modelos basados en datos de Hyperion fueron menos precisos que los modelos basados en espectroscopía de laboratorio, lo que se atribuyó

a la presencia de diferentes cubiertas dentro de un mismo píxel (spectral mixing) y al ruido presente en la imagen (Gomez *et al.* 2008; Jaber *et al.* 2011; Lu *et al.* 2013).

En esta tesis también se estimó el carbono orgánico del suelo usando una imagen Hyperion del área de estudio (Peón *et al.* 2017b). Los resultados se analizarán detalladamente en los apartados siguientes de esta memoria, pero también se resumen aquí brevemente, al igual que se ha hecho con el sensor AHS, para comparar los resultados obtenidos en la simulación con los obtenidos usando datos reales. Los modelos realizados en esta tesis para estimar el carbono del suelo usando datos de Hyperion mostraron un  $R^2 = 0.49-0.61$  y un RPD = 1.39–1.58, que fue un ~40 % peor que el obtenido usando los espectros de laboratorio remuestreados.

Los modelos obtenidos en esta tesis usando los espectros remuestreados para el Landsat-TM5 mostraron una precisión intermedia, con un  $R^2 = 0.62-0.75$  y un RPD = 1.62–2.03 (Tabla 6). En estudios previos en los que se usaron datos Landsat para estimar el carbono y la materia orgánica del suelo se obtuvieron valores de  $R^2$  similares o incluso mejores. Nanni y Demattê (2006) estimaron la materia orgánica en suelos desnudos usando, por una parte, espectros de laboratorio remuestreados a Landsat-TM5 ( $R^2 = 0.53$ ), y por otra imágenes de Landsat ( $R^2 = 0.51$ ). Huang *et al.* (2007) estimaron el contenido de carbono total del suelo en depósitos glaciares y obtuvieron un  $R^2 = 0.46$  usando datos de reflectividad de Landsat, y un  $R^2 = 0.62$  al añadir al modelo variables topográficas. Peng *et al.* (2015) utilizaron Landsat para predecir el carbono del suelo en un área principalmente agrícola y obtuvieron un  $R^2 = 0.46$  y un RPD = 1.3. El carbono orgánico del suelo también se estimó en áreas áridas y semiáridas no agrícolas usando Landsat-TM5, con un  $R^2 = 0.80-0.91$  (Jarmer *et al.* 2010).

En la Tabla 6 se puede ver, por último, que los modelos obtenidos en esta tesis para el sensor MODIS mostraron un  $R^2 = 0.77-0.88$  y un RPD = 2.01–2.95. Vågen *et al.* (2016) usaron datos MODIS para cartografiar el carbono orgánico del suelo a escala continental, en África, con una resolución espacial de 500 m, y obtuvieron un valor similar de  $R^2$  ( $R^2 = 0.74$ ).

Los modelos para estimar el carbono orgánico del suelo obtenidos en estudios previos basados en el uso de datos reales de sensores aeroportados y desde satélite fueron generalmente menos precisos que los modelos obtenidos en esta tesis usando datos simulados. Los valores de RPD de los modelos de estos estudios basados en datos reales fueron, en promedio, un 29.4 % peores para CASI, un 27.6 % para AHS y un 42.5 % para Hyperion. Esta disminución en los valores de RPD que se observa al usar datos reales de los sensores en vez de datos simulados

concuera con los resultados obtenidos en esta tesis, en la que los valores de RPD disminuyeron un ~28–39 % para AHS y un ~40 % para Hyperion. Estas diferencias observadas entre las predicciones en el campo y en el laboratorio se atribuyeron a múltiples factores, entre los que se incluye la presencia de ruido en los datos de satélite y de sensores aeroportados, las condiciones superficiales del suelo como la rugosidad y el contenido de humedad, la presencia de vegetación y diferentes cubiertas dentro de un mismo píxel y la ausencia de una adecuada corrección atmosférica. De los sensores hiperespectrales analizados, el que mostró las mayores diferencias entre el laboratorio y el campo fue Hyperion, lo que se relacionó con la baja relación señal-ruido de este sensor (Pearlman *et al.* 2003) y con su resolución espacial de 30 m. Considerando exclusivamente los resultados obtenidos en la simulación realizada usando los espectros de laboratorio remuestreados, el sensor hiperespectral con más potencial para estimar el carbono del suelo fue el sensor AHS.

En lo que respecta a los sensores multiespectrales, los modelos de carbono del suelo basados en datos reales de reflectividad mostraron valores de  $R^2$  que fueron en promedio un 14.6 % más bajos que los modelos basados en espectros remuestreados para Landsat-TM5 y un 9.2 % más bajos para MODIS. A pesar de que es esperable obtener mejores resultados empleando datos de sensores hiperespectrales, en los estudios realizados anteriormente usando los sensores multiespectrales de Landsat y MODIS se obtuvieron predicciones moderadamente satisfactorias, lo que podría ser muy valioso para cartografiar el carbono superficial del suelo en áreas extensas de suelo desnudo y en áreas afectadas por incendios forestales.

## **2.4. Estimación del carbono del suelo con el sensor AHS usando espectroscopía**

### ***2.4.1. Modelos PLSR para estimar el carbono del suelo usando los espectros de laboratorio remuestreados para el sensor AHS***

La simulación realizada usando los espectros de laboratorio remuestreados para los cinco sensores (Tabla 6) reveló que el AHS era el sensor de teledetección que tenía más potencial para estimar el carbono orgánico del suelo. Los resultados de la simulación indicaron que las características espectrales de este sensor (número de bandas, localización y ancho de las bandas) eran muy adecuadas para la estimación del carbono del suelo. La precisión de los modelos PLSR obtenidos usando los espectros de ASD en el VIS–NIR–SWIR remuestreados para el sensor AHS (38 bandas) fue muy similar, incluso ligeramente superior, a la de los modelos basados en los espectros de ASD (2051 bandas), a pesar de la notable diferencia en



el número de bandas (lo que ya se discutió en el apartado 2.3.2). Los modelos PLSR basados en los espectros de laboratorio en el VIS–NIR–SWIR remuestreados para el sensor AHS fueron los más precisos que se obtuvieron para este sensor y, por tanto, los que se aplicaron posteriormente a la imagen AHS para obtener mapas de carbono del área de estudio. Los indicadores de calidad de estos modelos se pueden consultar en la Tabla 6. El modelo PLSR para estimar el TOC mostró un  $R^2_{cv} = 0.81$  y un  $RMSE_{cv} = 6.55 \%$ , y el modelo para el OC un  $R^2_{cv} = 0.89$  y un  $RMSE_{cv} = 3.47 \%$ . El valor del RPD de estos modelos fue de 2.28 y 2.97, respectivamente; por lo que éstos se consideraron precisos de acuerdo con la clasificación de Chang *et al.* (2001).

Los coeficientes de regresión (b) de los modelos PLSR se muestran en la Figura 8 y los valores de los coeficientes de regresión positivos se incluyen en la Tabla 8. En ambos modelos se observaron unos coeficientes de regresión con un valor absoluto relativamente alto en varias regiones del NIR–SWIR asociadas a sobretonos y combinaciones de vibraciones fundamentales de los enlaces C–O, O–H, C=O, C–H y N–H, que están presentes en compuestos orgánicos como las proteínas, el almidón, la celulosa, los ácidos húmicos y la lignina (Ben-Dor *et al.* 1997; Huang *et al.* 2008). No obstante, cabe mencionar que es complicado interpretar los coeficientes de regresión en la región del NIR–SWIR y asociar éstos a compuestos individuales debido a que los sobretonos y las combinaciones de vibraciones fundamentales están muy solapados en el NIR–SWIR; al contrario que en el MIR, donde se localizan las vibraciones fundamentales y es posible realizar una interpretación directa.

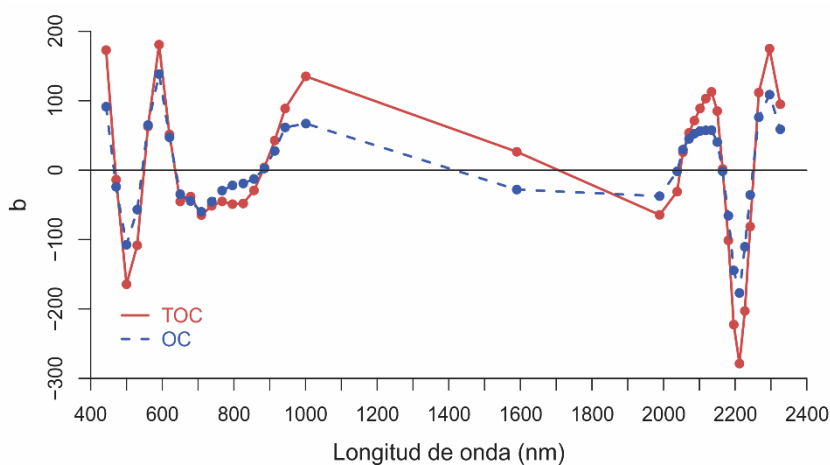


Figura 8. Coeficientes de regresión (b) de los modelos PLSR para estimar el carbono del suelo usando los espectros de laboratorio remuestreados para el sensor AHS (adaptado de Fernández *et al.* 2016).

Tabla 8. Coeficientes de regresión (b) positivos de los modelos PLSR para estimar el carbono del suelo usando los espectros de laboratorio remuestreados para el sensor AHS, e interpretación molecular (publicado en Fernández *et al.* 2016).

Longitud de onda (nm)	Coeficientes PLSR (b)			Interpretación molecular	
	TOC	OC	Diferencia (TOC-OC)	Huang <i>et al.</i> (2008)	Vasques <i>et al.</i> (2009)
443	173.0	91.4	81.6	Lignina	C recalcitrante
560	62.9	65.0	-2.1	Lignina y extraíbles	Formas lábiles del C
591	180.8	138.4	42.4		
620	51.4	47.4	4.0		
885	3.9	2.4	1.5		
914	42.7	27.8	14.9		Pigmentos orgánicos
943	88.8	61.6	27.2		
1001	135.1	67.1	68.0		C recalcitrante
1590	26.5	-28.0	54.5	Hidroxilos de hemicelulosa	
2054	25.8	29.5	-3.7	Carbohidratos	Formas lábiles del C
2071	53.7	45.0	8.7	Celulosa	
2086	71.3	52.5	18.8		
2102	88.9	56.4	32.5	Lignina	C recalcitrante
2118	103.1	57.3	45.8		C recalcitrante
2134	112.8	57.6	55.2		
2150	85.1	40.5	44.6	Lignina	
2165	1.7	1.7	0.0		
2266	111.8	76.2	35.6		C recalcitrante
2296	175.0	108.7	66.3		C recalcitrante
2326	94.9	58.9	36.0	Lignina	C recalcitrante

En general, los valores absolutos de los coeficientes de regresión del modelo para estimar el TOC fueron mayores que los del modelo para estimar el OC, debido probablemente a la mayor cantidad de componentes orgánicos presentes en el TOC. Los valores absolutos más altos en los coeficientes del modelo para estimar el TOC se podrían relacionar con una mayor efectividad del método de extracción química utilizado para determinar el TOC (combustión seca), respecto al utilizado para determinar el OC (oxidación con dicromato) (Tessier *et al.* 1979). A pesar de que generalmente se observaron unos coeficientes con un valor absoluto más alto en el modelo del TOC, se observó que los coeficientes asociados a dos bandas, las situadas a 560 y 2054 nm, tuvieron valores absolutos menores en el modelo para estimar el TOC que en el del OC. Estas regiones corresponden a las formas más lábiles del carbono según la interpretación de Vasques *et al.* (2009), y a lignina, extraíbles y carbohidratos según la interpretación de Huang *et al.* (2008) (Tabla 8). Los coeficientes de regresión a 560 y 2054 nm parecen resaltar la naturaleza más lábil del modelo para estimar el OC. El valor absoluto del resto de coeficientes es mayor en el modelo para estimar el TOC que en el del OC, lo que muestra una mayor cantidad de compuestos estables en el carbono del suelo.

En el modelo para estimar el OC se observó un coeficiente de regresión negativo en la banda situada a 1590 nm, que es la única banda del AHS en la región entre 1000–2000 nm. Si bien

es complicado interpretar los coeficientes asociados a esta banda debido a que es una banda muy ancha con un FWHM de 85 nm (Figura 7), ésta podría estar asociada a la celulosa cristalina y a la lignina (Viscarra Rossel 2007; Huang *et al.* 2008), y a hidrocarburos (~1647, ~1712 nm) presentes solo en el modelo del TOC (Okparanma y Mouazen 2013).

#### **2.4.2. Transferencia de los modelos de espectroscopía de laboratorio a la imagen AHS y obtención de mapas de carbono**

Demostrada la gran similitud entre la espectroscopía de laboratorio y la teledetección hiperespectral en el VIS–NIR–SWIR, se evaluó la posibilidad de transferir los modelos PLSR de espectroscopía a la imagen AHS, como un método directo y sencillo para estimar el carbono del suelo usando el sensor AHS. Además, con este método la estimación del carbono orgánico del suelo en el campo se realizaría usando los modelos más precisos, que son los obtenidos en el laboratorio. La transferencia de los modelos de espectroscopía a la imagen AHS se realizó de forma directa, aplicando los modelos basados en los espectros de laboratorio remuestreados para AHS a la imagen de este sensor, dada la analogía existente entre los espectros de reflectividad obtenidos con el espectrofotómetro y los obtenidos de la imagen AHS. La transferencia de los modelos de laboratorio a la imagen AHS se ha publicado como resultado de esta tesis en Fernández *et al.* (2016).

En la Figura 9 se muestra el diagrama de flujo del proceso realizado para estimar el carbono del suelo con el sensor AHS usando los modelos obtenidos en el laboratorio con espectroscopía. Para obtener los modelos de espectroscopía se aplicó en primer lugar la transformación  $\log(1/R)$  a los espectros de reflectividad remuestreados para el sensor AHS. A continuación se generaron los modelos PLSR eligiendo el número óptimo de componentes mediante el uso del AIC obtenido en la validación cruzada. Posteriormente los modelos PLSR para estimar el TOC y el OC usando los espectros remuestreados para AHS se aplicaron a la imagen AHS corregida de atmósfera y topografía, una vez transformada a  $\log(1/R)$ . Como resultado de la aplicación de los modelos de laboratorio a la imagen AHS se obtuvieron dos mapas del carbono orgánico del suelo (TOC y OC) con una resolución espacial de 5 m.

Para evaluar la calidad de los mapas de carbono se utilizó inicialmente el conjunto de 12 muestras de parcela. En cada mapa de carbono se promediaron los valores de las regiones de 3×3 píxeles correspondientes a las parcelas de campo de 15×15 m, dado que una región de

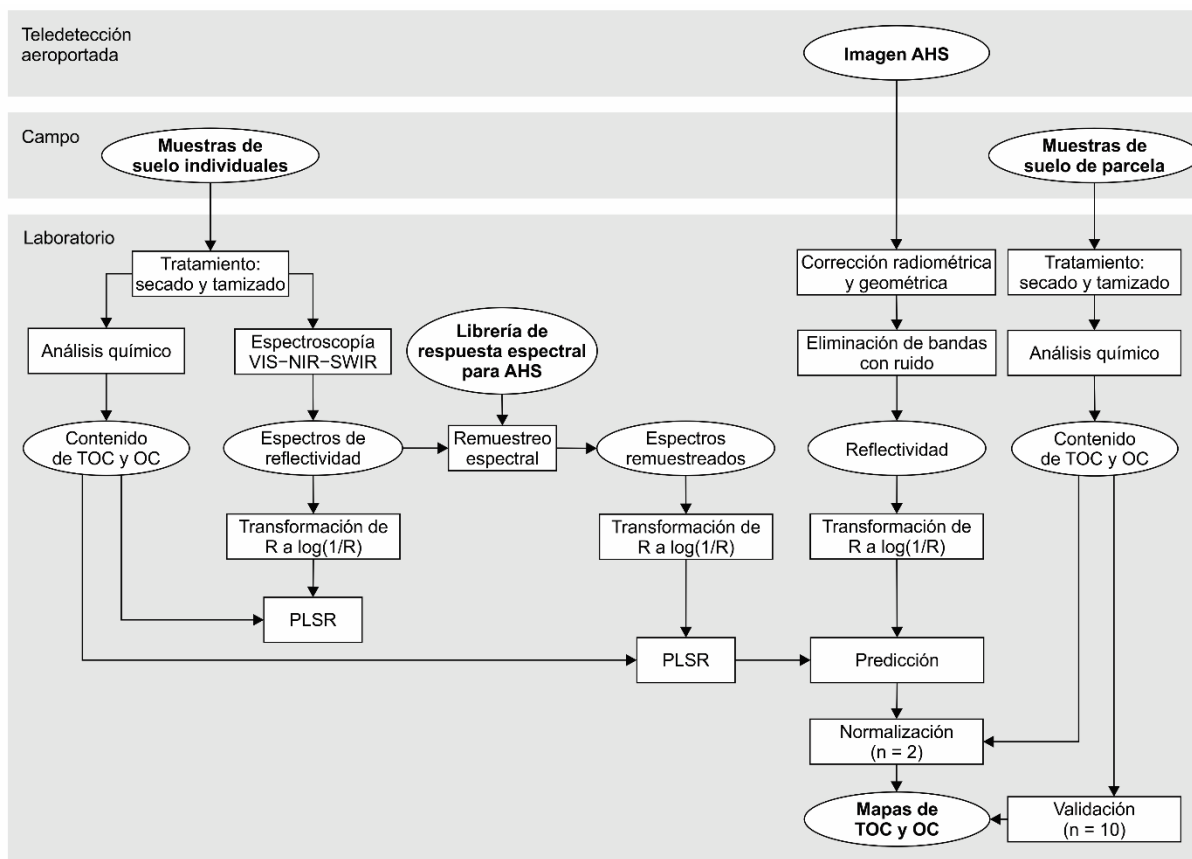


Figura 9. Diagrama de flujo para estimar el carbono orgánico del suelo con el sensor AHS usando los modelos obtenidos en el laboratorio con espectroscopía en el VIS-NIR-SWIR. n = número de muestras.

3×3 píxeles en un mapa de 5 m de resolución espacial tiene un tamaño de 15×15 m en el terreno. A continuación se compararon los valores de carbono obtenidos de los mapas (valores estimados) con los obtenidos en el análisis químico de las muestras (valores observados o valores de referencia). En esta validación, para evaluar la correlación entre ambos valores (estimados y observados) se utilizaron el coeficiente de determinación ( $R^2$ ) y el error estándar de los residuos (Residual Standard Error, RSE), mientras que para cuantificar las diferencias entre ambos se usaron el error cuadrático medio de la predicción (Root-Mean-Square Error of Prediction, RMSEP) y el residuo medio (Bias). Los valores del  $R^2$  (0.74) y del RSE (4.5–6 %) obtenidos usando las 12 muestras de parcela fueron satisfactorios, indicando una adecuada correlación entre los valores comparados, pero no los del RMSEP (>40 %) y del Bias (–40 %), lo que indicó que los modelos de carbono no predecían con exactitud los valores observados, sino que los sobrestimaban considerablemente.

La baja exactitud de los modelos fue debida probablemente a la presencia de vegetación en las zonas quemadas de la imagen, lo que hacía que los espectros de reflectividad obtenidos de la

imagen no correspondieran exclusivamente al suelo, sino a una mezcla del suelo y de la vegetación. Esta mezcla espectral afecta a los datos de teledetección, pero no a los obtenidos con espectroscopía en el laboratorio, donde se tomaron solamente espectros de reflectividad de muestras de suelo. Los resultados de la validación inicial usando las 12 muestras de parcela mostraron que la transferencia de los modelos de laboratorio a la imagen AHS no se podía realizar de forma directa, ya que este método no tenía en cuenta las diferencias existentes entre los espectros de laboratorio y los de la imagen. Estos modelos podrían ser utilizados por tanto para identificar de forma cualitativa las regiones con una mayor y menor concentración de carbono, pero no para determinar de forma exacta el contenido de carbono en un punto determinado.

Se realizó una normalización para tener en cuenta las diferencias entre los espectros de laboratorio y los de la imagen, para adaptar de este modo los modelos a los valores de carbono del área de estudio. Los modelos se normalizaron mediante un ajuste lineal usando 2 muestras de parcela seleccionadas aleatoriamente entre las 12 muestras de las parcelas de validación. A continuación se analizó la calidad de los modelos normalizados utilizando las 10 muestras de parcela restantes. Los indicadores de calidad obtenidos en la validación se muestran en la Tabla 9 y el diagrama de dispersión de los valores observados frente a los estimados se muestra en la Figura 10. Los resultados de la validación de los mapas normalizados fueron satisfactorios, tanto para el TOC ( $R^2 = 0.73$  y  $RMSEP = 7.8\%$ ) como para el OC ( $R^2 = 0.72$  y  $RMSEP = 5.1\%$ ), con una precisión ligeramente inferior a la obtenida en los modelos de laboratorio (Tabla 6). Tras la normalización se observaron unos valores de  $R^2$  y de RSE muy similares a los obtenidos antes de la normalización, como cabía esperar, y unos valores de RMSEP y de Bias notablemente mejores.

Tabla 9. Indicadores de calidad obtenidos en la validación de los mapas de carbono del suelo usando el conjunto de muestras de parcela.

Propiedad del suelo	n	$R^2$	RSE (%)	a	b	RMSEP (%)	Bias (%)
TOC (%)	10	0.73	6.65	$1.5 \pm 0.3$	$-11 \pm 8$	7.80	1.40
OC (%)	10	0.72	4.98	$1.1 \pm 0.2$	$0 \pm 4$	5.05	0.65

RSE = error estándar de los residuos (Residual Standard Error); Observado =  $a \times$  Estimado + b; RMSEP = error cuadrático medio de la predicción (Root-Mean-Square Error of Prediction); Bias = residuo medio.

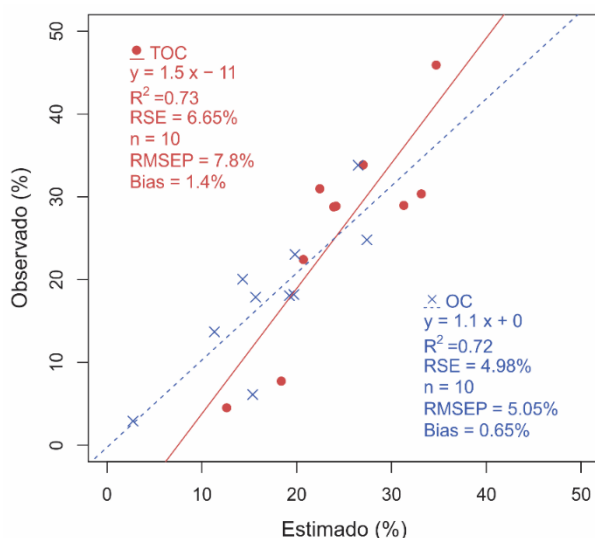


Figura 10. Diagrama de dispersión de los valores de carbono del suelo observados en las parcelas de validación frente a los valores estimados obtenidos de los mapas normalizados. La descripción de los parámetros incluidos en el gráfico se puede consultar en el pie de la Tabla 9 (adaptado de Fernández *et al.* 2016).

En la Figura 11 se muestran los mapas de carbono del suelo (TOC y OC) correspondientes a una ladera parcialmente cubierta de brezal localizada en El Bao, en el sur del área de estudio (Figura 1). Los mapas de carbono incluidos en esta figura se han suavizado usando un filtro de media con un tamaño de ventana de 3×3 para reducir el ruido y mostrar de forma más clara la variación del carbono en la ladera. En trabajos realizados anteriormente también se emplearon imágenes del sensor AHS para obtener mapas del carbono orgánico del suelo, pero estos estudios se restringieron principalmente a zonas agrícolas y a zonas de suelo desnudo (Stevens *et al.* 2008; Stevens *et al.* 2010; Bartholomeus *et al.* 2011; Stevens *et al.* 2012; Denis *et al.* 2014; Steinberg *et al.* 2016) (Tabla 2). Los resultados obtenidos en la validación de estos trabajos, en los que se observó un R<sup>2</sup> medio de 0.72, fueron comparables a los obtenidos en esta tesis al aplicar los modelos de laboratorio a la imagen AHS. Los resultados obtenidos en esta tesis se consideraron moderadamente satisfactorios teniendo en cuenta la complejidad de la zona de estudio, en la que las zonas quemadas se encontraban parcialmente cubiertas de vegetación.

Aunque los resultados de la transferencia de los modelos de laboratorio a la imagen AHS hayan sido satisfactorios y comparables a los obtenidos en otros estudios realizados anteriormente en zonas agrícolas y comparables incluso a los obtenidos en el laboratorio, cabe mencionar que existen algunas limitaciones relevantes que dificultan la aplicación de este

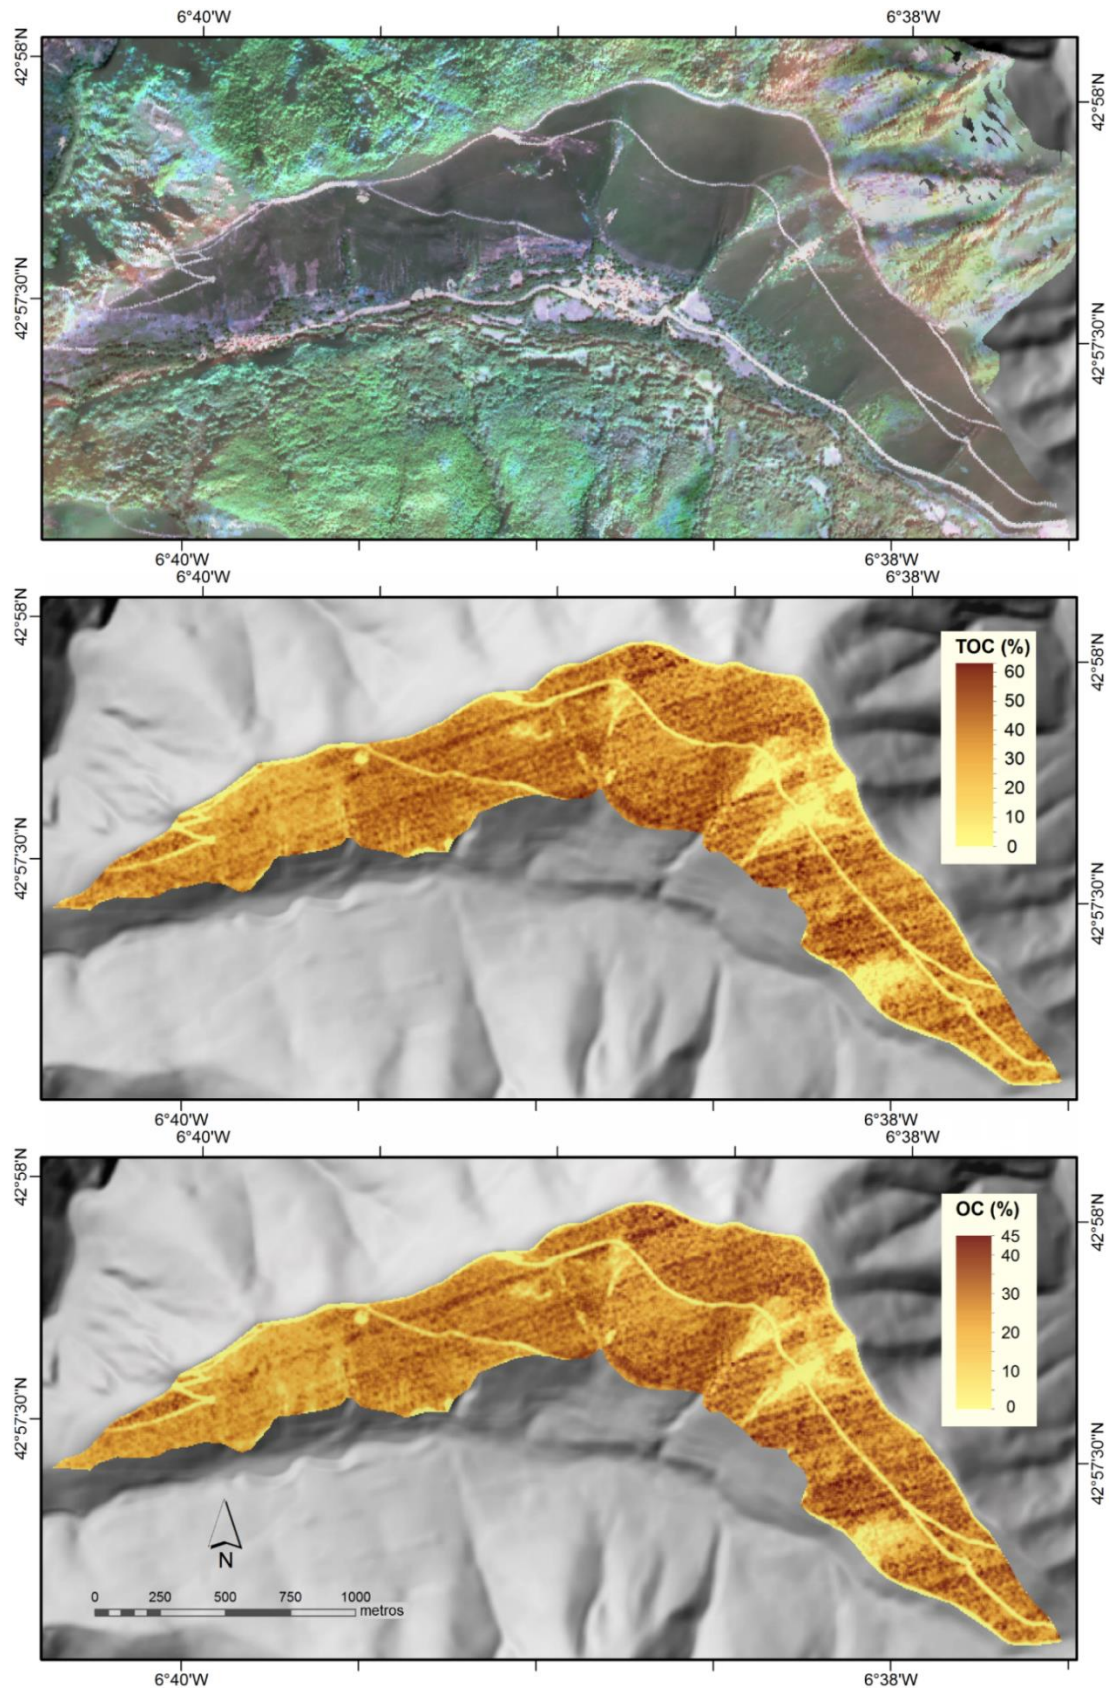


Figura 11. Composición en color real de la imagen AHS, con las bandas a 650, 560 y 443 nm en los canales rojo, verde y azul, respectivamente (arriba). Mapas del contenido de carbono orgánico total (centro) y de carbono oxidable (abajo) correspondientes a una ladera parcialmente cubierta de brezal localizada en El Bao, en el sur del área de estudio (Figura 1) (adaptado de Fernández *et al.* 2016).

método para estimar el carbono a escala regional. La principal limitación se deriva de la necesidad de disponer del análisis químico de varias muestras de suelo de la zona de estudio, para normalizar los modelos de carbono y tener en cuenta de esta forma las diferencias existentes entre los espectros de laboratorio y los de la imagen. La necesidad de esta normalización hace que el método pueda no ser extrapolable a otras zonas de estudio diferentes a la nuestra.

## **2.5. Estimación del carbono del suelo con los sensores AHS e Hyperion usando índices espectrales**

### ***2.5.1. Obtención de índices espectrales de diferencia normalizada***

Una vez estimado el carbono del suelo usando los modelos de espectroscopía transferidos a la imagen AHS y analizadas las limitaciones de este método, se evaluó la posibilidad de realizar la cartografía del carbono usando modelos basados en las imágenes y no en los datos de espectroscopía. En el ámbito de la teledetección hiperespectral la estimación del carbono se realiza habitualmente usando modelos PLSR, en los que la estimación se realiza a partir de los datos de reflectividad obtenidos de las imágenes. Sin embargo, también existe la posibilidad de estimar el carbono usando técnicas estadísticas más sencillas, como la regresión lineal múltiple basada en índices espectrales. En esta tesis se ha analizado el potencial de ambas técnicas para estimar el carbono del suelo usando imágenes de dos sensores hiperespectrales, el AHS y el Hyperion. Este análisis ha sido presentado como resultado de la tesis en Peón *et al.* (2017b).

Los índices espectrales son muy utilizados en teledetección para estimar distintos parámetros biofísicos (Jackson y Huete 1991). El índice de vegetación de diferencia normalizada (Normalized Difference Vegetation Index, NDVI) (Rouse *et al.* 1973) es uno de los índices de vegetación más utilizados debido a su simplicidad y efectividad para estimar diversos parámetros de la cubierta vegetal y para discriminar distintos tipos de cubiertas. El NDVI se basa en la reflectividad medida en una banda del rojo ( $\rho_{\text{rojo}}$ ) y en una banda del NIR ( $\rho_{\text{NIR}}$ ):  $\text{NDVI} = (\rho_{\text{NIR}} - \rho_{\text{rojo}}) / (\rho_{\text{NIR}} + \rho_{\text{rojo}})$ . Es posible transferir fácilmente este índice entre distintos sensores debido a su simple estructura. Un factor importante que permite la transferencia de los índices entre sensores es que los índices proporcionan valores relativos, y por tanto se descartan las diferencias absolutas que existen en la reflectividad obtenida con distintos sensores.



Diversos constituyentes bioquímicos presentes en la vegetación y el suelo, entre los que se encuentran la clorofila, la celulosa y la lignina, influyen en la reflectividad en el VIS–NIR–SWIR (Ben-Dor *et al.* 1997; Bartholomeus *et al.* 2008). Dado que estos constituyentes se relacionan con el carbono orgánico del suelo (Beyer *et al.* 2001), varios autores han identificado longitudes de onda e índices espectrales sensibles al carbono usando espectros de reflectividad en el VIS–NIR–SWIR, obtenidos tanto en el campo como en el laboratorio (Bartholomeus *et al.* 2008; Yu *et al.* 2016).

Los índices espectrales más utilizados se basan habitualmente en diferencias de bandas, diferencias normalizadas y cocientes. La diferencia normalizada es una estructura muy adecuada para estudios de vegetación (Jackson y Huete 1991) y fue la que se seleccionó en esta tesis, dado que las zonas quemadas del área de estudio estaban parcialmente cubiertas por brezal. La estructura del índice espectral seleccionado en la tesis (Spectral Index, SI) es la misma que la del NDVI:  $SI_{\lambda_2-\lambda_1} = (\rho_{\lambda_2} - \rho_{\lambda_1}) / (\rho_{\lambda_2} + \rho_{\lambda_1})$ , donde  $\rho_{\lambda_1}$  y  $\rho_{\lambda_2}$  son los valores de reflectividad en la longitud de onda efectiva ( $\lambda_1$ ) y en la de referencia ( $\lambda_2$ ). Los valores de este índice varían entre -1 y 1. Se calcularon índices con esta estructura usando los valores de reflectividad de las imágenes AHS e Hyperion corregidas de atmósfera y topografía. Los índices se calcularon para todas las combinaciones posibles de las bandas del AHS (38) e Hyperion (155), por lo que se obtuvieron un total de 1406 índices para AHS y 23870 para Hyperion.

### ***2.5.2. Correlación entre el carbono y las reflectividades e índices espectrales***

Con el objeto de identificar las mejores bandas e índices espectrales para estimar el carbono del suelo se realizaron correlogramas entre los valores de carbono y los valores de reflectividad e índices espectrales. Los valores de carbono empleados para AHS fueron los obtenidos en el análisis químico del subconjunto de 39 muestras individuales utilizadas para AHS (Tabla 4). En el caso de Hyperion, debido al bajo número de muestras disponibles, se utilizó un conjunto de datos de carbono de la zona de estudio estimado usando el sensor AHS. Una descripción del origen y las características de este conjunto de datos compuesto por 200 observaciones se puede consultar en el apartado 2.5.4 de la tesis. Se extrajeron los valores de reflectividad y de los índices espectrales en la posición de las muestras y de las observaciones de carbono, y posteriormente se correlacionaron con los valores de carbono usando regresión lineal simple.

Para identificar las mejores bandas del AHS e Hyperion para estimar el carbono se generó el correlograma que se muestra en la Figura 12, en el que se representa el valor del coeficiente de correlación de Pearson (R) entre los valores de carbono (TOC y OC) y las reflectividades de las imágenes. Se observó una correlación negativa relativamente alta en varias bandas, con unos valores de R entre  $-0.5$  y  $-0.65$  aproximadamente. Los suelos más oscuros, con menor reflectividad, tienen generalmente un mayor contenido de materia orgánica (Stoner y Baumgardner 1981; Schulze *et al.* 1993), lo que explica la correlación negativa observada en la Figura 12.




Figura 12. Coeficiente de correlación de Pearson (R) entre el contenido de TOC y OC y los valores de reflectividad de las imágenes AHS e Hyperion (adaptado de Peón *et al.* 2017b).

En general, las regiones espectrales con alta correlación en la Figura 12 son bastante similares para el AHS e Hyperion. Las correlaciones más altas para ambas propiedades del suelo y sensores se observaron en la región del rojo, con la correlación máxima absoluta en 610 y 679–681 nm. Estos resultados son consistentes con los de Stevens *et al.* (2010), quienes también usaron datos del sensor AHS para estimar el carbono orgánico del suelo y encontraron un pico de absorción en torno a 600–750 nm posiblemente relacionado con el carbono orgánico. Bartholomeus *et al.* (2008) estimaron el carbono del suelo usando espectros de reflectividad en el VIS–NIR–SWIR obtenidos en el laboratorio, y también encontraron que la región del rojo era importante para la predicción del carbono orgánico, con la correlación más alta observada en  $\sim 600$  nm usando los valores de reflectividad, y entre 640 y 690 nm usando el inverso de los valores de reflectividad. Vinogradov (1981) también encontró la correlación más alta entre el carbono orgánico y la radiancia en la región espectral del rojo (600–700 nm).

En la región del SWIR también se observó una alta correlación entre el carbono y las reflectividades (Figura 12). Varias longitudes de onda entre ~2100–2500 nm son sensibles a la materia orgánica del suelo (Henderson *et al.* 1992; Hummel *et al.* 2001), lo que podría explicar las correlaciones relativamente altas observadas en esta región. La alta correlación observada en el SWIR concuerda bien con lo observado en los modelos de espectroscopía obtenidos en la tesis, en los que el SWIR fue una de las regiones más importantes para la estimación del carbono (Figura 6 y Tabla 7). La región del SWIR entre ~2100–2350 nm fue de hecho la más importante en los modelos de laboratorio que se transfirieron a la imagen AHS (Figura 8). La correlación entre el carbono y las reflectividades del AHS fue relativamente alta entre 2038–2326 nm y se caracterizó por una elevada variabilidad (Figura 12), lo que se atribuyó al ruido del sensor AHS, que tiene una relación señal-ruido relativamente baja en esta región (SNR medio = 18). En un estudio de Stevens *et al.* (2010) en el que usaron datos de AHS para estimar el carbono del suelo también observaron un patrón similar de variabilidad en esta región. En cambio, los correlogramas entre el carbono y las reflectividades de Hyperion no mostraron esta variabilidad, a pesar de que el sensor Hyperion también tiene una relación señal-ruido relativamente baja en el SWIR (SNR = 40 a 2125 nm). El hecho de que los correlogramas para Hyperion sean más estables en el SWIR se podría relacionar con el método de reducción del ruido basado en componentes principales que se aplicó a la imagen Hyperion, que podría ser más efectivo que el aplicado a la imagen AHS, basado en la eliminación de las bandas con menor SNR.

Con el objeto de identificar las longitudes de onda más importantes para estimar el carbono usando los índices espectrales  $SI_{\lambda_2-\lambda_1}$ , se evaluaron todos los pares de posibles combinaciones de las bandas del AHS e Hyperion usando correlogramas de dos dimensiones (2D). En la Figura 13 se muestra el coeficiente de determinación  $R^2$  obtenido en los modelos de regresión lineal simple para estimar el carbono (TOC y OC) usando los distintos índices espectrales. Los resultados para los índices espectrales basados en las bandas del AHS fueron muy similares para el TOC y el OC. Se encontró una región importante con  $R^2 \geq 0.5$  usando las combinaciones de las bandas del AHS en el rango de  $\lambda_1 = 591-679$  nm y  $\lambda_2 = 709-1001$  nm. Cabe mencionar que  $\lambda_1$  y  $\lambda_2$  se pueden utilizar indistintamente, dado que los valores de  $R^2$  en los gráficos de la Figura 13 son simétricos respecto a la línea 1:1. El valor máximo de  $R^2$  obtenido para el TOC y el OC fue de 0.56, usando el índice  $SI_{1001-679 \text{ nm}}$  para el AHS, que se basa en la banda efectiva  $\lambda_1 = 679$  nm (rojo) relacionada con la absorción de la clorofila

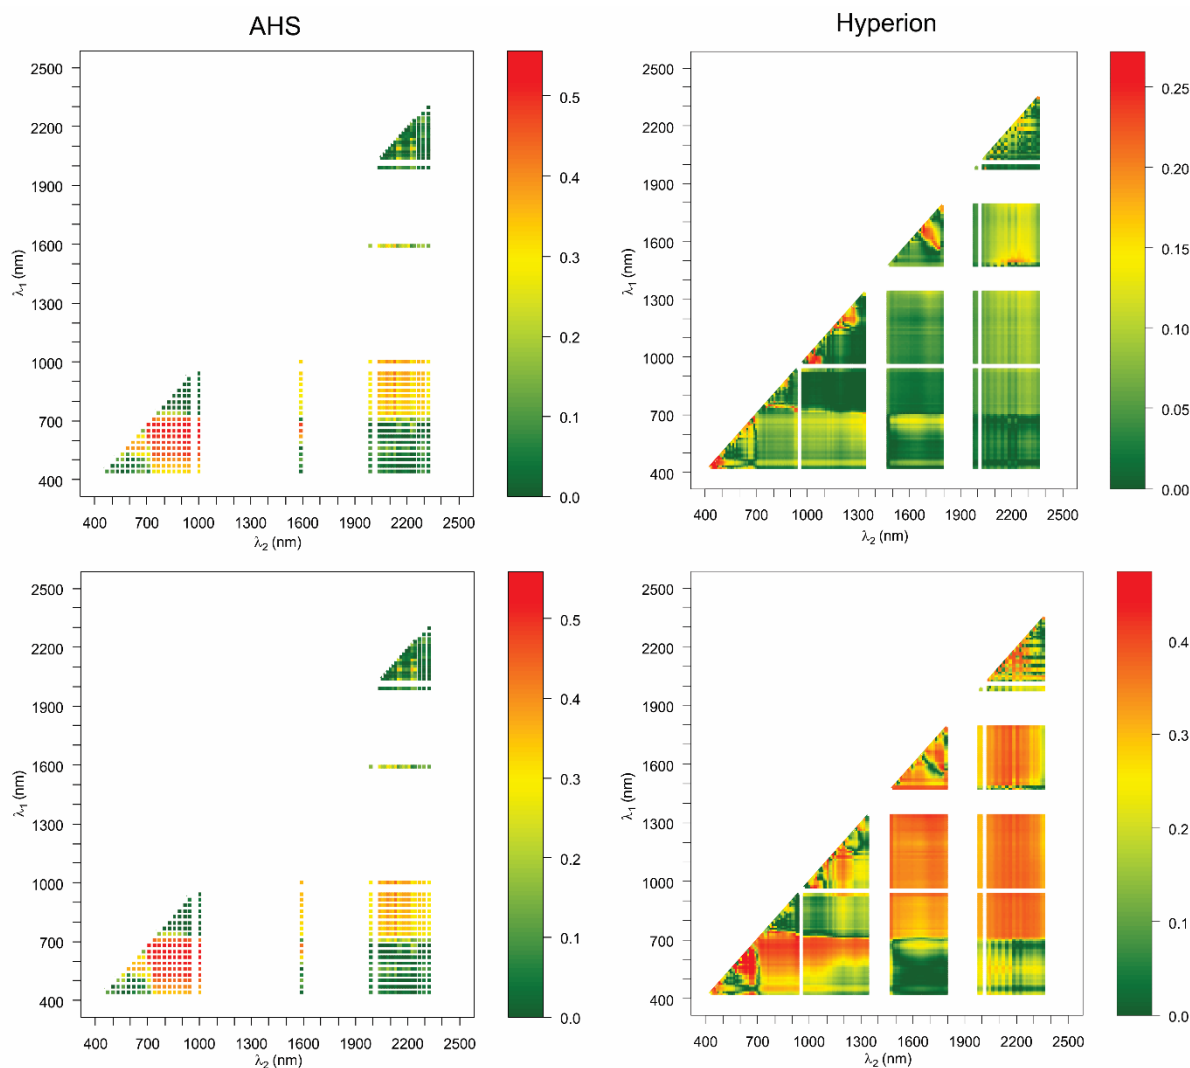


Figura 13. Coeficiente de determinación  $R^2$  entre los valores de TOC (arriba) y OC (abajo) y los índices espectrales  $SI_{\lambda_2-\lambda_1} = (\rho_{\lambda_2} - \rho_{\lambda_1})/(\rho_{\lambda_2} + \rho_{\lambda_1})$  obtenidos a partir de las imágenes AHS (izquierda) e Hyperion (derecha). Los valores de  $R^2$  de los gráficos son simétricos respecto a la línea 1:1 y, por tanto, se pueden intercambiar  $\lambda_1$  y  $\lambda_2$  (publicado en Peón *et al.* 2017b).

(Gitelson *et al.* 1996), y en la banda de referencia  $\lambda_2 = 1001$  nm (NIR) que se puede asociar al carbono orgánico (Vasques *et al.* 2009). Este índice corresponde al NDVI, que se basa en la reflectividad de una banda del rojo y en otra del NIR.

Los valores del coeficiente de determinación  $R^2$  entre TOC/OC y los índices espectrales para Hyperion fueron menores o ligeramente menores que los obtenidos para el AHS (Figura 13). Se obtuvieron valores de  $R^2$  más bajos para el TOC, con un valor máximo de 0.27 usando el índice  $SI_{1023-973}$  nm, basado en dos bandas del NIR. Los valores de  $R^2$  más altos se obtuvieron para el OC. Algunas regiones relativamente importantes para el OC fueron las de  $\lambda_1 = 539-610$  nm y  $\lambda_2 = 620-671$  nm ( $R^2 \geq 0.40$ ),  $\lambda_1 = 630-712$  nm y  $\lambda_2 = 732-1336$  nm ( $R^2 \geq 0.35$ ),  $\lambda_1 = 732-1336$  nm y  $\lambda_2 = 1477-2355$  nm ( $R^2 \geq 0.30$ ), y  $\lambda_1 = 1508-1790$  nm y  $\lambda_2 = 2032-2254$  nm

( $R^2 \geq 0.30$ ). El valor máximo de  $R^2 = 0.45$  se obtuvo usando el índice  $SI_{1033-973 \text{ nm}}$ . Los índices para Hyperion con las correlaciones más altas fueron consistentes para el TOC y el OC, con la mejor correlación usando las bandas  $\lambda_1 = 973 \text{ nm}$  y  $\lambda_2 = 1023-1033 \text{ nm}$ . Las longitudes de onda alrededor de  $\sim 960 \text{ nm}$  se podrían relacionar con los pigmentos orgánicos y las situadas entre  $\sim 1020-1030 \text{ nm}$  se pueden relacionar con el carbono orgánico (Vasques *et al.* 2009). Estas longitudes de onda que fueron relevantes para estimar el carbono usando los índices  $SI_{\lambda_2-\lambda_1}$  para Hyperion no están cubiertas por las bandas del AHS.

### 2.5.3. Obtención de los modelos para estimar el carbono del suelo usando el sensor AHS

En la Figura 14 se muestra el proceso realizado para estimar el carbono orgánico del suelo usando reflectividades e índices espectrales. En primer lugar, se correlacionó el contenido en carbono del subconjunto de 39 muestras con las reflectividades e índices espectrales usando

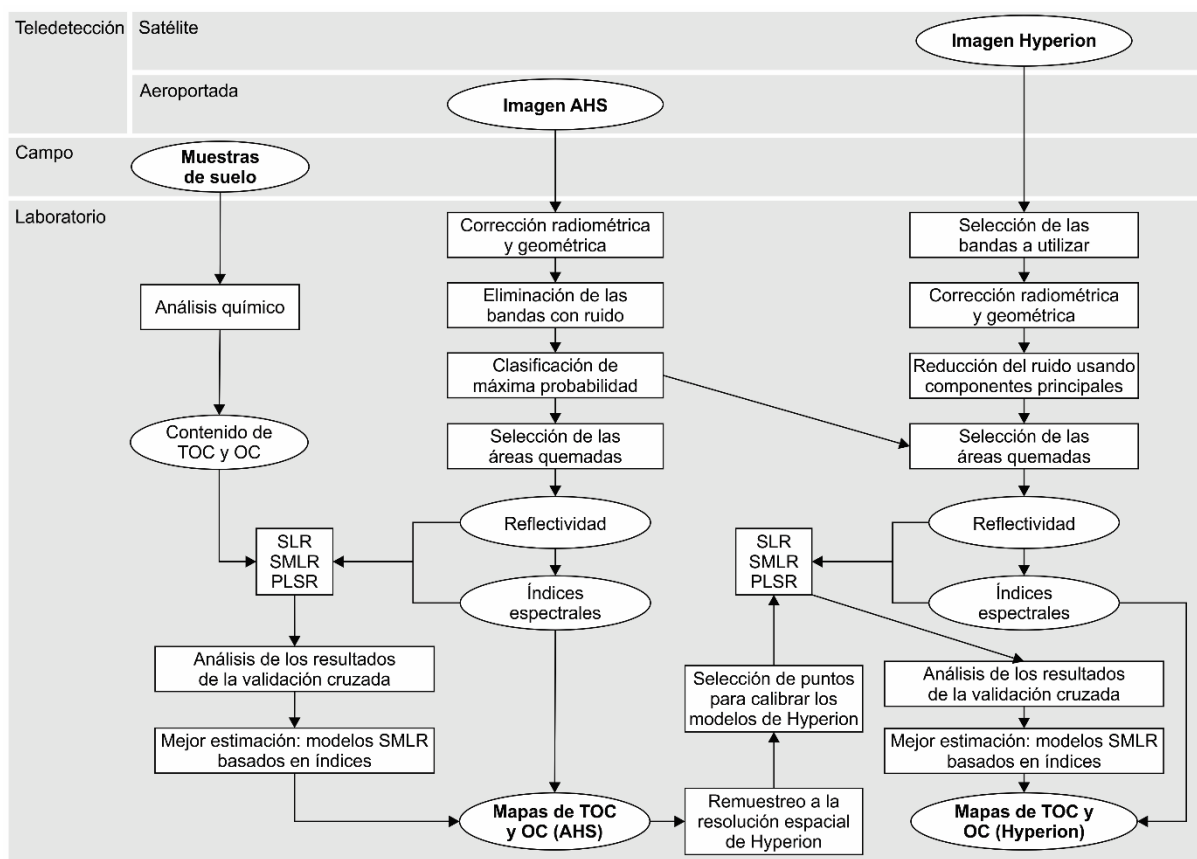


Figura 14. Diagrama de flujo para la estimación del carbono orgánico del suelo con los sensores AHS e Hyperion usando reflectividades e índices espectrales (adaptado de Peón *et al.* 2017b). SLR = regresión lineal simple (Simple Linear Regression); SMLR = regresión lineal múltiple paso a paso (Stepwise Multiple Linear Regression); PLSR = regresión de mínimos cuadrados parciales (Partial Least-Squares Regression).

regresión lineal simple (Simple Linear Regression, SLR). Posteriormente se obtuvieron modelos mejores usando regresión lineal múltiple paso a paso (Stepwise Multiple Linear Regression, SMLR). El conjunto óptimo de variables de cada modelo SMLR se determinó automáticamente usando un método de selección de variables que combina la selección hacia adelante (Forward Stepwise Regression) con la eliminación hacia atrás (Backward Stepwise Regression) (Venables y Ripley 2002). Todas las variables seleccionadas en los modelos fueron significativas, con un p-valor inferior a 0.05.

Se realizaron dos tipos de modelos SMLR, usando reflectividades y usando índices espectrales. Como el número de variables predictoras (38 bandas del AHS y 1406 índices) fue similar o mayor que el número de observaciones (39 muestras de suelo), solo se utilizaron en los modelos SMLR las bandas e índices más importantes. Las bandas más importantes fueron las que tuvieron un mayor coeficiente de determinación  $R^2$  en los modelos SLR. La identificación de los índices más importantes se realizó en dos pasos para evitar que en la lista de índices seleccionados para realizar los modelos SMLR aparecieran bandas duplicadas. En primer lugar, se identificó la longitud de onda de referencia ( $\lambda_2$ ) del índice con el mayor  $R^2$  en los modelos SLR. Posteriormente se seleccionaron solo los índices basados en esta longitud de onda de referencia, y finalmente se incluyeron en el análisis SMLR los que tuvieron el mayor  $R^2$ .

Para la estimación del carbono del suelo usando el sensor AHS se empleó también la técnica PLSR, siguiendo el mismo procedimiento que el realizado con los datos de espectroscopía (descrito en el apartado 2.2.1 de la tesis). Antes de realizar los modelos PLSR se centraron los espectros de reflectividad de la imagen AHS, dado que los modelos mejoraron tras aplicar esta técnica de preprocesamiento.

#### ***2.5.4. Obtención de los modelos para estimar el carbono del suelo usando el sensor Hyperion***

Para estimar el carbono del suelo usando el sensor Hyperion se siguió el mismo procedimiento que para el AHS, pero usando un conjunto de datos con un origen distinto (Figura 14). Para construir los modelos para Hyperion, dado que solo 6 de las 39 muestras estaban disponibles, se utilizaron como datos de carbono los obtenidos con los mejores modelos para el sensor AHS, que fueron los modelos SMLR basados en índices espectrales. Los mapas de carbono de 5 m de resolución espacial obtenidos usando AHS se remuestrearon a los 30 m de resolución

espacial de la imagen Hyperion. Los datos de 36 píxeles ( $6 \times 6$  píxeles) de 5 m de resolución espacial se promediaron para generar los datos con una resolución de 30 m. Se seleccionaron 200 puntos en los mapas del TOC y OC, en las áreas quemadas obtenidas de la clasificación de la imagen AHS, y a continuación se extrajeron los valores de TOC y OC en la localización de estos puntos. Los valores del TOC y OC usados para Hyperion, resumidos en la Tabla 10, mostraron una distribución similar a la de las 39 muestras utilizadas para AHS (Tabla 4). Los valores de carbono correspondientes a los 200 puntos se relacionaron con las reflectividades e índices espectrales obtenidos de la imagen Hyperion, usando SLR, SMLR y PLSR. El procedimiento para obtener estos modelos fue el mismo que el realizado para el AHS (descrito en el apartado 2.5.3).

Tabla 10. Estadísticos del conjunto de datos de carbono del suelo utilizados para construir los modelos para Hyperion (publicado en Peón *et al.* 2017b).  $n = 200$ . Los datos se han extraído de los mapas de carbono obtenidos con AHS usando los modelos SMLR basados en índices espectrales.

	TOC (%)	OC (%)
Mínimo	5.3	5.6
Máximo	51.6	37.4
Media	34.4	22.9
Desviación típica	10.6	5.9

### 2.5.5. Modelos para estimar el carbono del suelo usando AHS e Hyperion

Los indicadores de calidad de los modelos para estimar el carbono del suelo (TOC y OC) usando AHS e Hyperion y las distintas técnicas de regresión (SLR, SMLR y PLSR) se muestran en la Tabla 11. Al igual que en los modelos de espectroscopía, la calidad de estos modelos se evaluó usando el  $R^2_{cv}$ , el  $RMSE_{cv}$  y el RPD. En la Tabla 11 se incluyen también las ecuaciones de predicción de los modelos SLR para estimar el carbono usando las mejores bandas e índices del AHS e Hyperion. En general, se obtuvieron mejores modelos SLR para el sensor AHS (RPD medio = 1.34) que para Hyperion (RPD medio = 1.25), para el OC (RPD medio = 1.31) que para el TOC (RPD medio = 1.27), y para los índices espectrales (RPD medio = 1.35) que para las bandas individuales (RPD medio = 1.24). De acuerdo con la clasificación de Chang y Laird (2002), los modelos SLR tuvieron una baja capacidad de predicción, excepto los modelos para estimar el TOC y el OC usando el índice del AHS  $SI_{1001-679\text{ nm}}$ , que tuvieron una capacidad de predicción intermedia ( $R^2_{cv} = 0.52$  y  $RPD = 1.46$ ).

Tabla 11. Indicadores de calidad de los modelos de regresión para estimar el carbono del suelo usando los sensores AHS e Hyperion (publicado en Peón *et al.* 2017b).

Sensor	Propiedad del suelo	Técnica de regresión	Ecuación de predicción	n	R <sup>2</sup> <sub>cv</sub> <sup>a</sup>	RMSE <sub>cv</sub> <sup>a</sup> (%)	RPD <sup>a</sup>
AHS	TOC (%)	SLR-1 banda	TOC = 66 – 1008 × ρ <sub>679 nm</sub>	39	0.35	11.69	1.25
		SLR-1 índice	TOC = -101 + 186 × SI <sub>1001-679 nm</sub>	39	0.52	10.02	1.46
		SMLR-3 bandas		39	0.51	10.13	1.44
		SMLR-8 índices	Ver Tabla 12	39	0.62	9.05	1.62
		PLSR-3 componentes		39	0.49	10.39	1.41
	OC (%)	SLR-1 banda	OC = 43 – 640 × ρ <sub>679 nm</sub>	39	0.27	8.70	1.18
		SLR-1 índice	OC = -72 + 131 × SI <sub>1001-679 nm</sub>	39	0.52	7.02	1.46
		SMLR-3 bandas		39	0.52	7.06	1.46
		SMLR-2 índices	Ver Tabla 12	39	0.60	6.44	1.60
Hyperion	TOC (%)	SLR-1 banda	TOC = 58 – 356 × ρ <sub>610 nm</sub>	200	0.34	8.55	1.24
		SLR-1 índice	TOC = -46 + 2276 × SI <sub>1023-973 nm</sub>	200	0.23	9.26	1.14
		SMLR-15 bandas		200	0.44	7.91	1.33
		SMLR-18 índices	Ver Tabla 12	200	0.49	7.58	1.39
		PLSR-4 componentes		200	0.32	8.68	1.22
	OC (%)	SLR-1 banda	OC = 33 – 177 × ρ <sub>681 nm</sub>	200	0.40	4.59	1.29
		SLR-1 índice	OC = -20 + 1218 × SI <sub>1033-973 nm</sub>	200	0.43	4.48	1.32
		SMLR-10 bandas		200	0.54	4.02	1.48
		SMLR-20 índices	Ver Tabla 12	200	0.61	3.74	1.58
		PLSR-4 componentes		200	0.44	4.45	1.33

<sup>a</sup> La descripción de estos parámetros se puede consultar en el pie de la Tabla 5. SLR = regresión lineal simple (Simple Linear Regression); SMLR = regresión lineal múltiple paso a paso (Stepwise Multiple Linear Regression); PLSR = regresión de mínimos cuadrados parciales (Partial Least-Squares Regression); SI = índice espectral (Spectral Index).

Los resultados de la validación de los modelos SMLR fueron mejores que los de los modelos SLR, para ambas propiedades del suelo y ambos sensores (Tabla 11). En todos los casos los modelos SMLR basados en índices espectrales fueron mejores que los basados en reflectividades. Las ecuaciones de predicción de los modelos SMLR basados en índices se muestran en la Tabla 12. Los mejores modelos SMLR se obtuvieron para el AHS con índices basados en la banda de referencia a 1001 nm, usando ocho índices para el TOC (R<sup>2</sup><sub>cv</sub> = 0.62 y RMSE<sub>cv</sub> = 9.05 %) y dos índices para el OC (R<sup>2</sup><sub>cv</sub> = 0.60 y RMSE<sub>cv</sub> = 6.44 %). Ambos modelos, con un RPD = 1.60-1.62, tuvieron una capacidad de predicción intermedia de acuerdo con Chang y Laird (2002). La precisión de los modelos SMLR basados en índices fue ligeramente menor para Hyperion. El modelo SMLR para estimar el TOC usando índices basados en la banda de referencia a 1023 nm obtuvo un R<sup>2</sup><sub>cv</sub> = 0.49, RMSE<sub>cv</sub> = 7.58 %, y tuvo una capacidad de predicción baja-intermedia, con un RPD = 1.39. El modelo SMLR para estimar el OC, basado en índices con la banda de referencia a 1033 nm, tuvo una precisión mayor, con un R<sup>2</sup><sub>cv</sub> = 0.61, RMSE<sub>cv</sub> = 3.74 % y RPD = 1.58.



Tabla 12. Expresiones de los mejores modelos SMLR para estimar el carbono del suelo usando los sensores AHS e Hyperion. La ecuación de predicción de cada modelo es  $S = b_0 + b_1 \times SI_{\lambda_2-\lambda_1,1} + b_2 \times SI_{\lambda_2-\lambda_1,2} + \dots + b_n \times SI_{\lambda_2-\lambda_1,n}$ , donde S es la propiedad del suelo,  $b_0$  es el término independiente,  $b_1$ – $b_n$  son los coeficientes de regresión y  $SI_{\lambda_2-\lambda_1}$  son los índices espectrales, con la estructura  $SI_{\lambda_2-\lambda_1} = (\rho_{\lambda_2} - \rho_{\lambda_1})/(\rho_{\lambda_2} + \rho_{\lambda_1})$  (publicado en Peón *et al.* 2017b).

AHS				Hyperion			
TOC (%)		OC (%)		TOC (%)		OC (%)	
$b_{0-n}$	$SI_{\lambda_2-\lambda_1,1-n}$	$b_{0-n}$	$SI_{\lambda_2-\lambda_1,1-n}$	$b_{0-n}$	$SI_{\lambda_2-\lambda_1,1-n}$	$b_{0-n}$	$SI_{\lambda_2-\lambda_1,1-n}$
-192		-116		-29		-172	
1679	$SI_{1001-471 \text{ nm}}$	249	$SI_{1001-679 \text{ nm}}$	-1693	$SI_{1023-844 \text{ nm}}$	-2128	$SI_{1033-427 \text{ nm}}$
-3941	$SI_{1001-500 \text{ nm}}$	-82	$SI_{1001-2150 \text{ nm}}$	-24127	$SI_{1023-1064 \text{ nm}}$	-4832	$SI_{1033-457 \text{ nm}}$
3325	$SI_{1001-530 \text{ nm}}$			19806	$SI_{1023-1094 \text{ nm}}$	5509	$SI_{1033-468 \text{ nm}}$
-2432	$SI_{1001-591 \text{ nm}}$			-24888	$SI_{1023-1104 \text{ nm}}$	6087	$SI_{1033-539 \text{ nm}}$
1991	$SI_{1001-620 \text{ nm}}$			24104	$SI_{1023-1114 \text{ nm}}$	-8698	$SI_{1033-569 \text{ nm}}$
-494	$SI_{1001-709 \text{ nm}}$			-31871	$SI_{1023-1185 \text{ nm}}$	4859	$SI_{1033-590 \text{ nm}}$
276	$SI_{1001-2102 \text{ nm}}$			26902	$SI_{1023-1245 \text{ nm}}$	-1368	$SI_{1033-925 \text{ nm}}$
-198	$SI_{1001-2150 \text{ nm}}$			-10102	$SI_{1023-1316 \text{ nm}}$	-17970	$SI_{1033-983 \text{ nm}}$
				-12028	$SI_{1023-1498 \text{ nm}}$	12772	$SI_{1033-993 \text{ nm}}$
				-14115	$SI_{1023-1558 \text{ nm}}$	14470	$SI_{1033-1044 \text{ nm}}$
				18239	$SI_{1023-1588 \text{ nm}}$	8856	$SI_{1033-1266 \text{ nm}}$
				13523	$SI_{1023-1790 \text{ nm}}$	-11975	$SI_{1033-1276 \text{ nm}}$
				-9758	$SI_{1023-1982 \text{ nm}}$	-6386	$SI_{1033-1639 \text{ nm}}$
				7336	$SI_{1023-1992 \text{ nm}}$	9555	$SI_{1033-1679 \text{ nm}}$
				8275	$SI_{1023-2052 \text{ nm}}$	4928	$SI_{1033-2083 \text{ nm}}$
				9878	$SI_{1023-2103 \text{ nm}}$	-4845	$SI_{1033-2153 \text{ nm}}$
				-11850	$SI_{1023-2163 \text{ nm}}$	-6318	$SI_{1033-2163 \text{ nm}}$
				-3555	$SI_{1023-2355 \text{ nm}}$	-5679	$SI_{1033-2194 \text{ nm}}$
						4452	$SI_{1033-2214 \text{ nm}}$
						5356	$SI_{1033-2244 \text{ nm}}$

La estimación del carbono del suelo también se realizó usando la técnica PLSR. El número óptimo de componentes, tres en los modelos para el AHS y cuatro en los de Hyperion, se determinó mediante la validación cruzada dejando-uno-fuera, usando el AIC. En la Tabla 11 se muestran los indicadores de calidad obtenidos en la validación cruzada. Los modelos PLSR para el AHS tuvieron una capacidad de predicción intermedia, con un  $RPD = 1.40$ – $1.41$ , y un  $R^2_{cv} = 0.48$ – $0.49$ . Los resultados de los modelos PLSR para Hyperion fueron ligeramente peores, con un  $RPD = 1.22$ – $1.33$  y un  $R^2_{cv} = 0.32$ – $0.44$ .

La precisión de los modelos fue mayor usando el método SMLR que el PLSR. Los modelos SMLR basados en índices mostraron unos valores de  $R^2_{cv}$  y  $RPD$  superiores a los del PLSR, y un menor  $RMSE_{cv}$ . Si bien el método PLSR podría parecer muy adecuado para estimar el carbono debido a su capacidad para manejar la multicolinealidad que afecta a los espectros de reflectividad, los resultados obtenidos en la tesis mostraron que es posible utilizar técnicas más sencillas como el SMLR basado en índices y obtener resultados comparables o incluso mejores que con el PLSR. Estos resultados concuerdan con los obtenidos por Selige *et al.* (2006), quienes estimaron distintas propiedades del suelo (porcentaje de arena, arcilla, carbono

orgánico y nitrógeno total) usando datos del sensor hiperespectral HyMap y obtuvieron errores mayores con el método PLSR que con el SMLR. Cabe destacar que los modelos PLSR se podrían mejorar y tener unos errores comparables a los obtenidos con SMLR mediante el uso de métodos más complejos de pretratamiento de los espectros y técnicas para seleccionar las variables predictoras más importantes, ya que los modelos PLSR pueden mejorar notablemente al incluir en ellos solamente las variables informativas (Huang *et al.* 2012; Jin y Wang 2019). Sin embargo, en la tesis se ha descartado el uso de sofisticadas técnicas de pretratamiento de espectros y de selección de variables informativas, dado que uno de los objetivos principales de la misma era precisamente evaluar la posibilidad de estimar el carbono del suelo usando técnicas más sencillas que el PLSR.

Para evaluar la calidad de los mejores modelos obtenidos para Hyperion, que fueron los SMLR basados en índices, se realizó un análisis de propagación de errores además de la validación cruzada, dado que estos modelos se construyeron usando un conjunto de datos de carbono estimados a su vez usando los modelos para el AHS. Para analizar la propagación de errores se realizaron simulaciones estocásticas usando el método de Monte Carlo (Metropolis y Ulam 1949; Hammersley y Handscomb 1979). Se seleccionaron los mejores modelos para estimar el TOC y el OC con el sensor AHS, que fueron los SMLR basados en índices, y se consideró que los errores de estos modelos tenían una distribución normal (gaussiana) usando la prueba de Shapiro–Wilk (Shapiro y Wilk 1965). Posteriormente se aplicó el método de Monte Carlo con 10000 iteraciones para obtener resultados fiables.

Como cabía esperar, los valores del RPD obtenidos en las simulaciones fueron inferiores o ligeramente inferiores a los obtenidos en la validación cruzada. El modelo SMLR para estimar el TOC usando 18 índices de Hyperion mostró un RPD medio de 1.23 en las simulaciones y un RPD = 1.39 en la validación cruzada, y el modelo para el OC basado en 20 índices un RPD medio de 1.20 en las simulaciones y un RPD = 1.58 en la validación cruzada (Tabla 11). Los valores del RPD obtenidos para Hyperion en las simulaciones fueron también inferiores a los de la validación cruzada de los modelos basados en el AHS. Los resultados obtenidos tanto en la validación cruzada como en las simulaciones con el método de Monte Carlo indicaron que los modelos obtenidos para Hyperion tuvieron una menor capacidad de predicción que los del AHS, a pesar de utilizar un mayor número de índices. La obtención de peores resultados para Hyperion se podría atribuir a su menor relación señal-ruido y a su menor resolución espacial (Hyperion 30 m y AHS 5 m); y se descarta que sea debido a sus características espectrales

(número de bandas, localización y ancho de las bandas), dado que en la simulación realizada en la tesis (descrita en el apartado 2.3) se observó que tanto el AHS como Hyperion tenían unas características espectrales adecuadas para estimar el carbono del suelo.

### 2.5.6. Longitudes de onda importantes para la estimación del carbono

Las bandas más importantes en los modelos de regresión para estimar el TOC y el OC usando AHS e Hyperion se muestran en la Figura 15, en la que también se han incluido las 38 bandas del AHS y las 155 del Hyperion utilizadas en la tesis. En la Figura 15, en los modelos SLR y SMLR basados en índices  $SI_{\lambda_2-\lambda_1}$ , se ha representado tanto la longitud de onda efectiva ( $\lambda_1$ ) como la de referencia ( $\lambda_2$ ). En los modelos PLSR, al igual que en los realizados usando espectroscopía (descritos en el apartado 2.2.1), se consideraron como bandas más importantes aquellas que tenían unos coeficientes PLSR (b) superiores a la desviación típica de los mismos (Viscarra Rossel *et al.* 2008; Gomez *et al.* 2015), y unos valores del VIP superiores a 1 (Chong y Jun 2005).

La banda del AHS situada a 679 nm (rojo) y el índice  $SI_{1001-679\text{ nm}}$  fueron relevantes para la predicción del TOC y el OC, de acuerdo con los resultados mostrados en el apartado 2.5.2. Las estimaciones más precisas para el AHS se obtuvieron usando los modelos SMLR basados




Figura 15. Longitudes de onda importantes en los modelos de regresión para estimar el TOC y el OC usando datos de los sensores AHS e Hyperion (adaptado de Peón *et al.* 2017b). El ancho de cada banda representada en el gráfico corresponde a la anchura a media altura (Full Width at Half Maximum, FWHM). Las bandas del AHS (38) e Hyperion (155) utilizadas en la tesis se representan en color gris oscuro. HYP = Hyperion; comp. = componentes.

en índices con la longitud de onda de referencia a 1001 nm y las longitudes de onda efectiva principalmente en la región del rojo (620 y 679 nm) y en la del SWIR (2102 y 2150 nm), aunque para el TOC también fueron importantes otras longitudes de onda en el visible. Las regiones del rojo y del SWIR también fueron relevantes en los modelos PLSR para estimar el TOC y el OC. Varias longitudes de onda entre 2086–2326 nm fueron importantes en los modelos PLSR para el AHS, pero no en los SMLR basados en índices. Sin embargo, los resultados obtenidos usando ambas técnicas fueron consistentes, con las longitudes de onda más importantes en la región del rojo y del SWIR. La región del rojo también fue relevante para la estimación del carbono orgánico y la materia orgánica del suelo en estudios realizados anteriormente (Vinogradov 1981; Bartholomeus *et al.* 2008; Stevens *et al.* 2010), y también la región del SWIR, principalmente entre 2100–2500 nm (Henderson *et al.* 1992; Hummel *et al.* 2001). La banda del AHS a 679 nm se podría asociar con la absorción de la clorofila (Gitelson *et al.* 1996) y las bandas a 2102 y 2150 nm con la lignina y el C recalcitrante (Tabla 8) (Huang *et al.* 2008; Vasques *et al.* 2009).

En los modelos para estimar el TOC y el OC usando Hyperion fueron importantes las bandas de la región de rojo (610 nm y 681 nm) y los índices basados en bandas del NIR (SI<sub>1023–973 nm</sub> y SI<sub>1033–973 nm</sub>), tal y como se indica en el apartado 2.5.2. Los modelos más precisos para Hyperion fueron los SMLR basados en índices, con la banda de referencia a 1023/1033 nm y longitudes de onda efectivas a lo largo del VIS–NIR–SWIR, especialmente a partir de 983 nm. Las bandas del Hyperion en la región del visible entre 427–712 nm también fueron importantes para la predicción del TOC y el OC, de acuerdo a los resultados de los modelos PLSR. Estas bandas corresponden a la región con la mejor relación señal-ruido del sensor Hyperion (Pearlman *et al.* 2003). En general las regiones más importantes para estimar el carbono usando Hyperion son consistentes con los resultados de estudios previos, en los que también fue relevante la región del rojo (Vinogradov 1981; Bartholomeus *et al.* 2008; Stevens *et al.* 2010) y la del SWIR (Henderson *et al.* 1992; Hummel *et al.* 2001). Las longitudes de onda a ~960 nm, ~1020–1030 nm y ~2000–2200 nm podrían estar relacionadas con pigmentos orgánicos, C orgánico y grupos C–H/N–H, respectivamente (Vasques *et al.* 2009). Otras longitudes de onda importantes en los modelos se podrían relacionar también con compuestos orgánicos como el almidón, la lignina y la celulosa (Ben-Dor *et al.* 1997), pero la atribución a un único compuesto resulta complicada, dado que las bandas de absorción asociadas a estos compuestos están muy solapadas en la región entre 700–2500 nm (Kooistra *et al.* 2003).

A pesar de que el sensor Hyperion tiene más bandas que el AHS, y más estrechas, y de que éstas se sitúan en regiones del espectro que no cubre el sensor AHS y que podrían ser relevantes para estimar el carbono del suelo, las estimaciones fueron peores usando Hyperion que usando AHS. El mayor número de índices involucrados en los modelos SMLR para Hyperion (18–20 índices) en comparación con los del AHS (2–8 índices) también refleja la capacidad de predicción relativamente menor de los modelos para Hyperion. Estos resultados se atribuyeron a la menor relación señal-ruido y la menor resolución espacial del sensor Hyperion.

### ***2.5.7. Mapas del carbono orgánico del suelo***

Los mejores modelos de regresión para las dos propiedades del suelo (TOC y OC) y los dos sensores (AHS e Hyperion), que fueron los SMLR basados en índices, se aplicaron píxel a píxel a las imágenes corregidas de atmósfera y topografía (Figura 14). En la Figura 16 se muestran como ejemplo los mapas del carbono orgánico del suelo de una parcela situada en Combo (6°41'43.9"W, 43° 4'13.5"N). Esta parcela corresponde a una ladera quemada con una superficie de ~20 ha, situada en la zona de solape de las imágenes AHS e Hyperion (la localización de la parcela se muestra en la Figura 1). La altitud de la parcela varía a lo largo de un gradiente NW–SE, desde ~1230 m en la zona noroeste de la parcela hasta ~900 m en la del sureste. La estimación del carbono en la parcela se realizó a dos resoluciones espaciales, usando la imagen AHS de 5 m de resolución y la de Hyperion de 30 m. Los mapas obtenidos de la imagen AHS se suavizaron aplicando un filtro de media con un tamaño de ventana de 3×3 píxeles, para reducir el ruido residual y mostrar de forma más clara la distribución espacial del TOC y el OC.

El análisis estadístico de los mapas de la Figura 16 mostró que los valores de estos mapas estaban en los mismos rangos que los de los datos utilizados para construir los modelos, con unos valores medios del TOC = 35.7–38.0 % y del OC = 21.2–22.4 %, en los mapas obtenidos usando AHS e Hyperion, respectivamente. En general la estimación usando AHS e Hyperion fue consistente, a pesar de la notable diferencia en la resolución espacial de ambos sensores. En los mapas de la Figura 16 el contenido de TOC fue mayor que el de OC, como cabía esperar. La correlación entre el contenido de TOC y de OC fue alta, tanto en los mapas obtenidos usando AHS ( $R = 0.84$ ) como en los de Hyperion ( $R = 0.90$ ). La distribución espacial del TOC y el OC en la ladera parece estar relacionada con la altitud y la topografía,

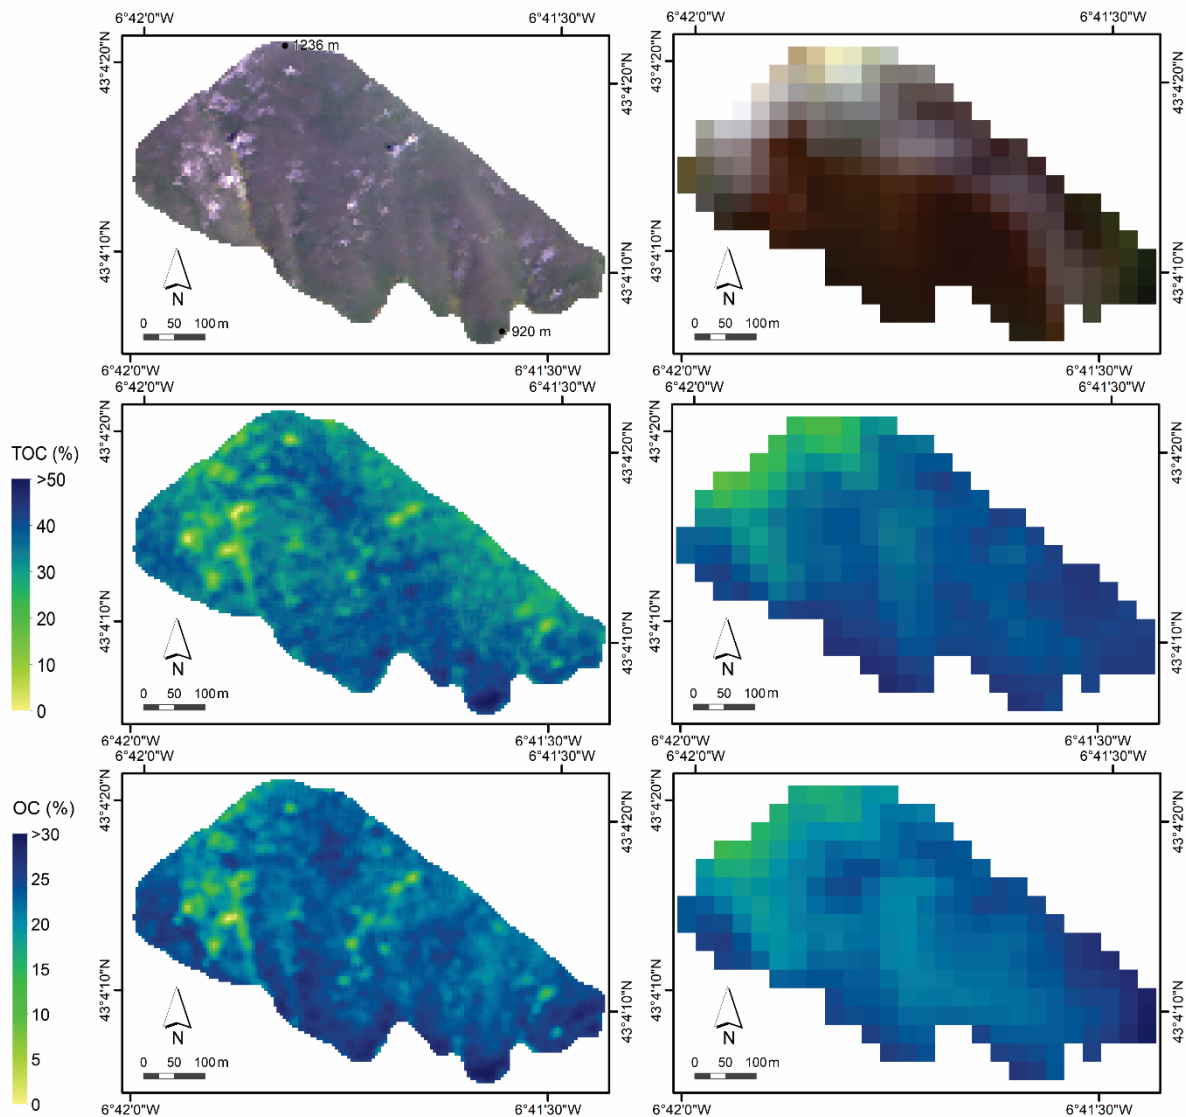


Figura 16. Composición en color real (arriba) y mapas del contenido de TOC (centro) y de OC (abajo) de una ladera localizada en Combo, en el centro del área de estudio (Figura 1). Los mapas se han obtenido usando los modelos SMLR basados en índices espectrales. Izquierda: imagen AHS (sensor aeroportado, resolución espacial de 5 m). Derecha: imagen Hyperion (satélite, resolución espacial de 30 m) (publicado en Peón *et al.* 2017b).

con un menor contenido de carbono en las zonas más altas y un mayor contenido en las zonas más bajas y deprimidas. Esta distribución se podría explicar por los procesos de transferencia local como la erosión, que favorece la acumulación del carbono del suelo en las zonas de menor altitud. En estudios previos se observó también que el relieve y la topografía estaban relacionados con la distribución espacial del carbono del suelo (De Gryze *et al.* 2008; Stevens *et al.* 2010; Schwanghart y Jarmer 2011; Hbirkou *et al.* 2012).

### **2.5.8. Comparación de los modelos SMLR basados en índices con otros modelos de carbono**

Los resultados de la validación de los mejores modelos para estimar el carbono usando AHS e Hyperion (modelos SMLR basados en índices) se compararon con los obtenidos en trabajos previos en los que se estimó el carbono y la materia orgánica del suelo usando datos hiperespectrales de sensores aeroportados o de satélite. Los indicadores de calidad de estos trabajos (RMSE,  $R^2$  y RPD) se muestran en la Tabla 2, en la que también se han incluido los indicadores de calidad obtenidos en la tesis para facilitar la comparación de los resultados. La comparación se realizó usando los valores de  $R^2$  y RPD, y no los valores de RMSE, ya que éstos no son comparables entre trabajos en los que se estiman propiedades del suelo ligeramente distintas, con distinto rango de variación y expresadas en distintas unidades.

En los trabajos previos en los que se estimó el carbono y la materia orgánica del suelo usando datos hiperespectrales de sensores aeroportados, la estimación se realizó utilizando entre 20 y 282 canales en el VIS–NIR–SWIR, con una resolución espacial entre 1 y 8 m. La predicción se realizó principalmente en zonas de suelo desnudo, usando la técnica de PLSR, y en la validación se obtuvo un  $R^2$  típicamente en el rango  $\sim 0.6-0.8$  y un RPD entre 1.4-1.9, lo que corresponde a modelos con una habilidad de predicción intermedia. Los resultados obtenidos en la tesis usando modelos SMLR basados en índices para el AHS ( $R^2 \geq 0.60$  y  $RPD \geq 1.60$ ) son comparables a los obtenidos en otros trabajos realizados anteriormente, lo que resulta muy satisfactorio, si consideramos que las áreas de estudio de estos trabajos previos tenían unas condiciones más favorables (principalmente zonas agrícolas y zonas de suelo desnudo) que las de la tesis (un entorno natural parcialmente cubierto de vegetación), y que la estimación del carbono del suelo no se había realizado anteriormente de forma satisfactoria en zonas con características similares a las de la tesis.

Bartholomeus *et al.* (2011) usaron datos AHS y la técnica de separación espectral residual para estimar el carbono del suelo en campos parcialmente cubiertos de maíz y obtuvieron en la validación resultados ligeramente peores ( $R^2 = 0.56$  y  $RPD = 1.50$ ) que los obtenidos en la tesis. El modelo para la predicción de materia orgánica de Franceschini *et al.* (2015) mostró resultados comparables ( $R^2 = 0.60$  y  $RPD = 1.60$ ) a los obtenidos en la tesis. Denis *et al.* (2014) obtuvieron los mejores resultados ( $R^2 = 0.96$  y  $RPD = 3.13$ ) corrigiendo el efecto de la sombra del suelo en la imagen de reflectividad mediante el uso de un factor de corrección calculado a partir de fotografías verticales del suelo tomadas en el campo. Stevens *et al.* (2012) usaron un

gran conjunto de datos con 400 muestras y obtuvieron buenos resultados ( $R^2 = 0.79$  y  $RPD = 2.33$ ) realizando modelos locales para las distintas regiones y tipos de texturas de suelo presentes en el área de estudio. Los modelos de predicción de carbono del suelo de Hbirkou *et al.* (2012) fueron calibrados usando un conjunto de datos relativamente grande compuesto por 204 muestras y obtuvieron resultados satisfactorios en la validación ( $R^2 = 0.83$  y  $RPD = 2.45$ ). Estos autores también sugirieron el uso de modelos específicos para distintas condiciones superficiales, con el objeto de mejorar la precisión de las estimaciones.

El carbono orgánico del suelo apenas ha sido estimado usando datos hiperespectrales de satélite y para ello solo se ha utilizado el sensor Hyperion (Tabla 2). Los indicadores de calidad de los modelos SMLR basados en índices para estimar el carbono usando Hyperion ( $R^2 = 0.49$ - $0.61$  y  $RPD = 1.39$ - $1.58$ ) fueron comparables a los obtenidos en áreas agrícolas y de suelo desnudo (Gomez *et al.* 2008; Lu *et al.* 2013; Zhang *et al.* 2013). Los modelos PLSR obtenidos en estos estudios también mostraron una habilidad de predicción intermedia, con un  $R^2 = 0.48$ - $0.74$  y un  $RPD = 1.43$ - $1.91$ . En la validación de los trabajos previos en los que se estimó el carbono del suelo en zonas cubiertas de vegetación se observaron resultados heterogéneos. Los resultados de esta tesis fueron mejores que los obtenidos por Jaber *et al.* (2011), quienes usaron un gran conjunto de datos con 227 muestras para modelizar el carbono orgánico del suelo en bosques, pastos y campos agrícolas, usando SMLR y redes neuronales artificiales. Sus resultados utilizando SMLR y redes neuronales artificiales fueron significativamente mejores que los obtenidos usando solo SMLR o PLSR, pero sus modelos mostraron una baja habilidad de predicción, con  $RPD = 0.68$ . Castaldi *et al.* (2014) usaron datos Hyperion para estimar la materia orgánica en campos de maíz y no encontraron diferencias significativas en los resultados de la validación obtenida en condiciones de suelo desnudo y en condiciones de suelo cubierto por vegetación. Obtuvieron modelos PLSR con baja habilidad de predicción ( $RPD = 1.02$ ) en condiciones de vegetación, usando un conjunto de datos de calibración de materia orgánica en el rango 1.1-2.7 %. Sin embargo, los modelos mejoraron significativamente usando la técnica de mínimos cuadrados ordinarios (Ordinary Least Squares, OLS) con los vectores propios de la fracción de mínimo ruido (Minimum Noise Fraction, MNF) en vez de los espectros de reflectividad ( $RPD = 2.93$ ).

Los resultados obtenidos en las simulaciones de Monte Carlo realizadas para analizar la propagación de errores en los modelos SMLR basados en índices para el sensor Hyperion ( $RPD$  medio = 1.20-1.23) fueron ligeramente peores que los obtenidos en la validación cruzada



de estos modelos (RPD = 1.39-1.58), pero comparables a los observados en los estudios previos que se muestran en la Tabla 2.

En base a los resultados obtenidos en los estudios previos para la estimación del carbono orgánico del suelo usando datos hiperespectrales de satélite o sensores aeroportados (Tabla 2), es esperable obtener mejores estimaciones utilizando grandes conjuntos de datos que permitan la calibración de modelos locales para las distintas regiones y tipos de texturas de suelo presentes en el área de estudio. La predicción podría mejorar también con la aplicación de métodos para reducir las sombras relativas del suelo, así como con el uso de técnicas de modelización más sofisticadas, como los splines de regresión adaptativa multivariante (Multivariate Adaptive Regression Splines, MARS) o las redes neuronales artificiales, que se emplean actualmente para estimar el carbono del suelo usando espectroscopía de laboratorio (Viscarra Rossel *et al.* 2006b). El uso de la transformación MNF antes de la modelización podría separar efectivamente el ruido en los espectros de reflectividad y mejorar la estimación. La predicción del carbono orgánico del suelo en áreas parcialmente cubiertas de vegetación podría mejorar también con la aplicación de técnicas de separación espectral (spectral unmixing).

Sin embargo, el uso de técnicas de modelización complejas que requieren la toma de un gran conjunto de datos de campo contrasta con la idea de una cartografía operativa del suelo. Las campañas para la toma de muestras de suelo son costosas y requieren mucho tiempo. El uso de datos históricos para la calibración de los modelos podría ser muy beneficioso para la cartografía operativa de propiedades del suelo (Gomez *et al.* 2016). Los esfuerzos también se deben dirigir hacia el desarrollo de técnicas simples para estimar el carbono del suelo, como el uso de índices espectrales en combinación con SMLR. La identificación de regiones espectrales importantes para la predicción del carbono podría ayudar también a diseñar nuevos índices con gran potencial para ser transferidos a futuros sensores hiperespectrales. En este sentido, se prevé el lanzamiento de nuevos satélites con sensores hiperespectrales en el VIS–NIR–SWIR: PRISMA de Italia en marzo de 2019 (Meini *et al.* 2015), HISUI de Japón a finales de 2019 (Tanii *et al.* 2014), HYPXIM de Francia (Michel *et al.* 2011) y EnMAP de Alemania en 2020 (Guanter *et al.* 2015), SHALOM de Italia e Israel en 2021 (Sagi 2015) y también HypSIRI de USA en ~2022 (Lee *et al.* 2015). Está previsto que estos sensores hiperespectrales, con una resolución espacial en el rango ~8-30 m, proporcionen una mayor relación señal-ruido que los sensores actuales, especialmente en la región del SWIR, lo que

podría favorecer la generación de cartografía cuantitativa de carbono del suelo de forma operacional, a bajo coste y con cobertura global. El carbono orgánico del suelo podría estimarse utilizando los futuros sensores PRISMA, EnMAP y HypSIRI con una precisión intermedia (RMSE alrededor de 0.2 % y  $R^2$  en el rango ~0.5-0.7), de acuerdo a las pruebas realizadas por Castaldi *et al.* (2016) usando datos simulados.

## Capítulo III. Conclusiones

### 3.1. Conclusiones

Las principales conclusiones de esta tesis son:

1. La espectroscopía en la región espectral del óptico (VIS–NIR–SWIR; 400–2500 nm) y las técnicas estadísticas multivariantes son adecuadas para estimar de forma precisa en el laboratorio el carbono orgánico de muestras puntuales de suelos quemados. En la validación de los modelos de regresión de mínimos cuadrados parciales (PLSR) para estimar el carbono orgánico del suelo se obtuvo un  $R^2 = 0.78–0.88$  y un RMSE = 3.5–7.0 %. Se obtuvieron mejores resultados para el carbono oxidable (OC) que para el carbono orgánico total (TOC).
2. De todas las técnicas probadas en la tesis para pretratar los espectros de laboratorio (primera y segunda derivada, transformación  $\log(1/\text{reflectividad})$ , filtro de suavizado de Savitzky-Golay, centrado de los espectros y distintas combinaciones de estas técnicas), la mejor técnica fue la transformación  $\log(1/\text{reflectividad})$  en todos los casos.
3. Las regiones del espectro óptico más importantes para la predicción del carbono orgánico del suelo usando espectroscopía de laboratorio fueron el visible (VIS; 400–700 nm) y el infrarrojo medio de onda corta (SWIR), principalmente entre 2000 y 2450 nm. Estas regiones se identificaron usando los coeficientes de regresión PLSR y la importancia de la variable en la proyección (VIP).
4. El uso de la espectroscopía ha sido fundamental en la tesis, dado que ha permitido establecer un puente entre los datos de laboratorio y los de teledetección. Se realizaron simulaciones usando datos de espectroscopía para determinar los sensores de teledetección más adecuados para estimar el carbono orgánico del suelo. Se evaluaron las características espectrales (número de bandas, localización y ancho de banda) de cinco sensores aeroportados o desde satélite para estimar el carbono orgánico del suelo, tres de estos sensores hiperespectrales (CASI, AHS e Hyperion) y dos multiespectrales (Landsat-TM5 y MODIS). El sensor con mayor potencial para estimar el carbono del suelo fue el AHS.

5. La estimación del carbono orgánico del suelo usando teledetección no solo se podría realizar usando sensores hiperespectrales (los más afines a los de espectroscopía en lo que respecta al número de bandas), sino también multiespectrales, cuya disponibilidad de imágenes es mucho mayor. Las simulaciones mostraron que las características espectrales de los tres sensores hiperespectrales (CASI, AHS e Hyperion) y las del multiespectral MODIS son adecuadas para estimar el carbono orgánico del suelo ( $R^2 = 0.75-0.89$  y  $RMSE = 3.5-7.4 \%$ ), a pesar de la notable diferencia en el número de bandas de estos sensores. Los resultados para Landsat-TM5 fueron moderadamente satisfactorios ( $R^2 = 0.62-0.75$ ), pero mostraron un error un  $\sim 30-45 \%$  superior al de los sensores hiperespectrales y MODIS.
6. Para estimar el carbono orgánico del suelo usando sensores de teledetección en la región del óptico, fue más importante la localización de las bandas en el espectro que el número de bandas o el ancho de las mismas. La baja precisión obtenida en algunos trabajos en los que se estima el carbono orgánico del suelo usando teledetección no está necesariamente relacionada con un bajo número de bandas del sensor, ya que en esta tesis se obtuvieron precisiones similares usando solo las 20 bandas de MODIS y usando las más de 2000 bandas de los espectros de laboratorio. La baja precisión obtenida en ocasiones en la estimación del carbono del suelo usando teledetección se podría deber fundamentalmente a una corrección atmosférica inadecuada, una baja relación señal-ruido del sensor o a la mezcla espectral.
7. La transferencia de los modelos de predicción de carbono del suelo obtenidos en el laboratorio a la imagen AHS fue moderadamente satisfactoria y se obtuvieron estimaciones de carbono del suelo a escala de teledetección, con un  $R^2 = 0.72-0.73$  y un  $RMSE = 5.1-7.8 \%$  en la validación. Estos resultados fueron comparables a los obtenidos en estudios previos de otros autores realizados en zonas agrícolas y comparables incluso a los obtenidos en el laboratorio. Sin embargo, este método tiene algunas limitaciones y puede no ser extrapolable a otras zonas de estudio, dado que requiere disponer de varias muestras de suelo del área de estudio para normalizar los modelos y tener en cuenta las diferencias entre los espectros de laboratorio y los de la imagen.

8. Es posible estimar el carbono orgánico del suelo a escala de teledetección usando algoritmos basados en índices de diferencia normalizada y modelos de regresión lineal múltiple. Los algoritmos desarrollados en la tesis fueron más sencillos y más precisos que el método de regresión de mínimos cuadrados parciales (PLSR) que se utiliza habitualmente, incluso en zonas más desfavorables. Estos algoritmos se probaron usando imágenes de AHS e Hyperion de las zonas forestales quemadas del área de estudio, con unas condiciones más desfavorables que las de los campos agrícolas en los que se prueban habitualmente, y se obtuvieron mejores resultados que con el método PLSR. Se obtuvo un  $R^2 = 0.49-0.62$  y un  $RMSE = 3.7-9.1 \%$  en la validación de los algoritmos basados en índices, frente a un  $R^2 = 0.32-0.49$  y un  $RMSE = 4.5-10.4 \%$  usando el PLSR. Los algoritmos basados en índices utilizaron además un menor número de bandas.
9. A pesar de la notable diferencia en la resolución espacial y espectral de las imágenes de AHS (5 m y 38 bandas) e Hyperion (30 m y 155 bandas), la estimación del carbono orgánico del suelo basada en índices fue consistente para ambos sensores. Se obtuvieron resultados ligeramente peores usando Hyperion que con AHS, lo que se atribuyó a su menor relación señal-ruido.
10. La estructura de los índices de diferencia normalizada se reveló útil para estimar el carbono orgánico del suelo a escala de teledetección en zonas forestales quemadas. Estos índices son simples y fáciles de transferir entre distintos sensores. Los algoritmos para estimar el carbono orgánico del suelo se podrían transferir a otros sensores hiperespectrales, entre los que se incluyen los futuros sensores hiperespectrales con una relación señal-ruido mejorada. Incluso se podrían transferir también a los actuales o futuros sensores multiespectrales con bandas en regiones importantes para estimar el carbono, lo que incrementaría la aplicabilidad y el alcance de estas técnicas de estimación del carbono. Si bien el uso operativo de estas técnicas aún es un reto en la actualidad, los resultados obtenidos en esta tesis muestran el potencial de los sensores hiperespectrales para estimar el carbono orgánico del suelo.

### 3.2. Conclusions

The main conclusions of this thesis are:

1. Spectroscopy in the optical region of the spectrum (VIS–NIR–SWIR; 400–2500 nm) and multivariate statistical techniques are suitable to estimate accurately in the laboratory the organic carbon content in point samples of burned soils. The validation of the partial least squares regression (PLSR) models for estimating soil organic carbon produced  $R^2 = 0.78–0.88$  and  $RMSE = 3.5–7.0$  %. Better results were obtained for oxidizable carbon (OC) than for total organic carbon (TOC).
2. Among all the techniques tested in this thesis for preprocessing the laboratory spectra (first and second derivative, transformation  $\log(1/\text{reflectance})$ , Savitzky-Golay smoothing, mean centre, and different combinations of these techniques), the best technique was the transformation  $\log(1/\text{reflectance})$  in all cases.
3. The most important wavelengths to estimate soil organic carbon using spectroscopy were the visible region (VIS; 400–700 nm) and the short-wave infrared (SWIR), mainly between 2000 and 2450 nm. These regions were identified using the PLSR regression coefficients and the variable importance for projection (VIP).
4. The use of spectroscopy has been essential in this thesis, as it has allowed us to build a bridge between laboratory and remote sensing data. Simulations based on spectroscopy data were performed to identify the most suitable remote sensing sensors to estimate soil organic carbon. The spectral characteristics (number of bands, location and bandwidth) of five airborne or satellite sensors were evaluated to estimate soil organic carbon, three of them were hyperspectral (CASI, AHS and Hyperion) and two multispectral (Landsat-TM5 and MODIS). AHS was the sensor with the greatest potential to estimate soil carbon.
5. The estimation of soil organic carbon using remote sensing may not only be performed using hyperspectral sensors (the remote sensing sensors with the number of bands closest to spectroscopy), but also multispectral sensors, which have a greater availability of images. The simulations showed that the spectral characteristics of the three hyperspectral sensors (CASI, AHS and Hyperion) and the multispectral MODIS are suitable for estimating soil organic carbon ( $R^2 = 0.75–0.89$  y  $RMSE = 3.5–7.4$  %),

despite the great difference in the number of bands of these sensors. The results for Landsat-TM5 were moderately satisfactory ( $R^2 = 0.62\text{--}0.75$ ), but with an error  $\sim 30\text{--}45\%$  greater than that obtained for the hyperspectral sensors and MODIS.

6. The location of the bands through the spectrum was more important than the number of bands or bandwidth to estimate soil organic carbon using optical remote sensing sensors. The low accuracy obtained in a number of studies in which soil organic carbon was estimated using remote sensing is not necessarily related to a low number of sensor bands, as in this study similar accuracies were obtained using MODIS bands (20) and all the bands of the laboratory spectra (more than 2000). The low accuracy obtained in the estimation of soil carbon using remote sensing may be mainly due to an inadequate atmospheric correction, a low signal-to-noise ratio of the sensor or to the spectral mixing.
7. The transfer of the soil carbon prediction models obtained in the laboratory to the AHS image was moderately satisfactory and soil carbon estimates were obtained at the remote sensing scale, with  $R^2 = 0.72\text{--}0.73$  and  $\text{RMSE} = 5.1\text{--}7.8\%$  in the validation. These results were comparable to those obtained in previous studies that have been carried out by other researchers in agricultural areas and comparable even to those obtained in the laboratory. However, this method has some limitations and may not be extrapolated to other study areas, as it requires several soil samples collected in the study area to normalize the models and take into account the differences between the laboratory and image spectra.
8. It is possible to estimate soil organic carbon at a remote sensing scale using algorithms based on normalized difference indices and multiple linear regression models. The algorithms developed in this thesis were simpler and more accurate than the commonly used partial least squares regression (PLSR) method, even in more unfavourable areas. These algorithms were tested using AHS and Hyperion images of burned forest in the study area, with more unfavourable conditions than those of the agricultural areas in which they are usually tested, and performed better than the PLSR method. An  $R^2 = 0.49\text{--}0.62$  and  $\text{RMSE} = 3.7\text{--}9.1\%$  were obtained in the validation algorithms based on indices, and  $R^2 = 0.32\text{--}0.49$  and  $\text{RMSE} = 4.5\text{--}10.4\%$  using PLSR. In addition, algorithms based on indices used fewer bands.

9. Despite the noticeable difference in the spatial and spectral resolution of the AHS (5 m and 38 bands) and Hyperion images (30 m and 155 bands), the soil organic carbon estimation based on spectral indices was consistent for both sensors. Slightly worse results were obtained using Hyperion than AHS, which was attributed to the lower signal-to-noise ratio of Hyperion.
  
10. The structure of the normalized difference indices proved to be useful for estimating soil organic carbon at a remote sensing scale in burned forest areas. These indices are simple and easy to transfer among different sensors. Algorithms for estimating soil organic carbon may be transferred to other hyperspectral sensors, including future hyperspectral sensors with an improved signal-to-noise ratio. They could even be transferred to current or future multispectral sensors with bands in important regions to estimate soil organic carbon, which would increase the applicability and scope of these techniques. While the operational use of these techniques is still a challenge today, the results obtained in this thesis show the potential of hyperspectral sensors to estimate soil organic carbon.



## **Publicaciones**

### **Publicación 1. Evaluation of the spectral characteristics of five hyperspectral and multispectral sensors for soil organic carbon estimation in burned areas**

Peón, J., Fernández, S., Recondo, C. y Calleja, J.F. (2017a) Evaluation of the spectral characteristics of five hyperspectral and multispectral sensors for soil organic carbon estimation in burned areas. *International Journal of Wildland Fire* **26**, 230-239. DOI:10.1071/WF16122



Este capítulo (p. 85–94) se corresponde con el artículo:

Peón, J., Fernández, S., Recondo, C. y Calleja, J.F. (2017a) Evaluation of the spectral characteristics of five hyperspectral and multispectral sensors for soil organic carbon estimation in burned areas. *International Journal of Wildland Fire* **26**, 230-239. DOI:10.1071/WF16122

Debido a la política de autoarchivo de la publicación la versión de la editorial está disponible, únicamente para usuarios con suscripción de pago a la revista, en el siguiente enlace:

<http://dx.doi.org/10.1071/WF16122>

**Publicación 2. Spatial modelling of organic carbon in burned mountain soils using hyperspectral images, field datasets, and NIR spectroscopy (Cantabrian Range; NW Spain)**

Fernández, S., Peón, J., Recondo, C., Calleja, J.F. y Guerrero, C. (2016) Spatial modelling of organic carbon in burned mountain soils using hyperspectral images, field datasets, and NIR spectroscopy (Cantabrian Range; NW Spain). *Land Degradation & Development* **27**, 1479-1488. DOI:10.1002/ldr.2452



Este capítulo (p. 97–106) se corresponde con el artículo:

Fernández, S., Peón, J., Recondo, C., Calleja, J.F. y Guerrero, C. (2016) Spatial modelling of organic carbon in burned mountain soils using hyperspectral images, field datasets, and NIR spectroscopy (Cantabrian Range; NW Spain). *Land Degradation & Development* **27**, 1479-1488. DOI:10.1002/ldr.2452

Debido a la política de autoarchivo de la publicación la versión de la editorial está disponible, únicamente para usuarios con suscripción de pago a la revista, en el siguiente enlace:

<http://dx.doi.org/10.1002/ldr.2452>

**Publicación 3. Prediction of topsoil organic carbon using airborne and satellite hyperspectral imagery**




Peón, J., Recondo, C., Fernández, S., Calleja, J.F., De Miguel, E. y Carretero, L. (2017b) Prediction of topsoil organic carbon using airborne and satellite hyperspectral imagery. *Remote Sensing* **9**, 1211. DOI:10.3390/rs9121211





Article

# Prediction of Topsoil Organic Carbon Using Airborne and Satellite Hyperspectral Imagery

Juanjo Peón <sup>1,\*</sup> , Carmen Recondo <sup>1,2</sup> , Susana Fernández <sup>3,4</sup>, Javier F. Calleja <sup>5</sup> ,  
Eduardo De Miguel <sup>6</sup> and Laura Carretero <sup>6</sup>

<sup>1</sup> Remote Sensing Applications Research Group (RSApps), Area of Cartographic, Geodesic and Photogrammetric Engineering, Department of Mining Exploitation and Prospecting, University of Oviedo, Gonzalo Gutiérrez Quirós s/n, 33600 Mieres, Asturias, Spain; mdrecondo@uniovi.es

<sup>2</sup> Institute of Natural Resources and Territorial Planning (INDUROT), University of Oviedo, Gonzalo Gutiérrez Quirós s/n, 33600 Mieres, Asturias, Spain

<sup>3</sup> Department of Geology, University of Oviedo, Jesús Arias de Velasco s/n, 33005 Oviedo, Asturias, Spain; fernandezsusana@uniovi.es

<sup>4</sup> GIS-Forest Group, Department of Organisms and Systems Biology, University of Oviedo, Gonzalo Gutiérrez Quirós s/n, 33600 Mieres, Asturias, Spain

<sup>5</sup> Remote Sensing Applications Research Group (RSApps), Department of Physics, Polytechnic School of Mieres, University of Oviedo, Gonzalo Gutiérrez Quirós s/n, 33600 Mieres, Asturias, Spain; jfcalleja@uniovi.es

<sup>6</sup> National Institute for Aerospace Technology (INTA), Carretera Torrejón a Ajalvir, km 4, 28850 Torrejón de Ardoz, Madrid, Spain; demiguel@inta.es (E.D.M.); carreteroml@inta.es (L.C.)

\* Correspondence: juanjopeon@gmail.com; Tel.: +34-985-458011

Received: 25 July 2017; Accepted: 21 November 2017; Published: 24 November 2017

**Abstract:** The Airborne Hyperspectral Scanner (AHS) and the Hyperion satellite hyperspectral sensors were evaluated for their ability to predict topsoil organic carbon (C) in burned mountain areas of northwestern Spain slightly covered by heather vegetation. Predictive models that estimated total organic C (TOC) and oxidizable organic C (OC) content were calibrated using two datasets: a ground observation dataset with 39 topsoil samples collected in the field (for models built using AHS data), and a dataset with 200 TOC/OC observations predicted by AHS (for models built using Hyperion data). For both datasets, the prediction was performed by stepwise multiple linear regression (SMLR) using reflectances and spectral indices (SI) obtained from the images, and by the widely-used partial least squares regression (PLSR) method. SMLR provided a performance comparable to or even better than PLSR, while using a lower number of channels. SMLR models for the AHS were based on a maximum of eight indices, and showed a coefficient of determination in the leave-one-out cross-validation  $R^2 = 0.60\text{--}0.62$ , while models for the Hyperion sensor showed  $R^2 = 0.49\text{--}0.61$ , using a maximum of 20 indices. Although slightly worse models were obtained for the Hyperion sensor, which was attributed to its lower signal-to-noise ratio (SNR), the prediction of TOC/OC was consistent across both sensors. The relevant wavelengths for TOC/OC predictions were the red region of the spectrum (600–700 nm), and the short wave infrared region between ~2000–2250 nm. The use of SMLR and spectral indices based on reference channels at ~1000 nm was suitable to quantify topsoil C, and provided an alternative to the more complex PLSR method.

**Keywords:** topsoil organic carbon mapping; imaging spectroscopy; AHS; Hyperion; spectral indices

## 1. Introduction

Soil organic carbon (SOC) is one of the Earth's main carbon (C) reservoirs, with a predicted amount greater than 1500 Pg C to 1-m depth [1,2]. Small changes in the SOC pool could have a

significant impact on the atmospheric CO<sub>2</sub> concentration and affect the climate [3]. The measurement of these pools at the range of spatial and temporal scales still remains a challenge [4]. Rapid and accurate methods are needed for improving the inventory, spatial distribution, and temporal dynamics of SOC [5,6].

Conventional methods for mapping SOC stocks involve the collection and analysis of point soil samples, calibration of a spatial prediction function, and interpolation of the function over the whole study area [7]. These methods are expensive and time-consuming because of the large number of samples required to capture the high spatial variability of SOC [8].

Laboratory-based measurements of soil C using standard methods, such as dry combustion [9] and the Walkley–Black method [10], also involves intensive and costly procedures. Soil diffuse reflectance spectroscopy in the visible (VIS, 400–700 nm), near infrared (NIR, 700–1300 nm), and short-wave infrared (SWIR, 1300–2500 nm) has been demonstrated to be an alternative to traditional methods for SOC prediction. Currently, lab spectroscopy is well established as an accurate, rapid, and non-destructive technique to predict a wide range of soil properties [11], including organic C [12–15] and total C [16–18].

Lab spectroscopy can be extended to a regional scale using airborne and satellite hyperspectral sensors. However, the use of hyperspectral sensors at a remote sensing scale has several limitations, such as atmospheric absorptions, illumination variations, the low signal-to-noise ratios of the sensors, and spectral mixing [19,20]. Due to these limitations, relatively few studies have used data from airborne and satellite hyperspectral sensors to estimate SOC and organic matter, either at the within-field scale or at the regional scale. Several hyperspectral airborne sensors were tested to predict SOC and organic matter over agricultural fields or semi-arid areas, including HyMap [21–26], Airborne Hyperspectral Scanner (AHS) [8,27–30], Compact Airborne Spectrographic Imager (CASI) [31,32], Airborne Visible and Near-Infrared (AVNIR) [33], DAIS-7915 [34], and HyperSpecTIR [35]. However, very few studies used airborne hyperspectral data to estimate SOC and organic matter over areas partially covered by vegetation, in either agricultural areas [36,37] or burned areas with a partial vegetation cover resulting from post-fire regeneration [38]. Satellite hyperspectral data was seldom used to estimate SOC, and only one satellite sensor, Hyperion, was used to predict SOC and organic matter over agricultural fields and bare soils [39–41]. Hyperion data was also used to estimate SOC and organic matter over maize crops [42], and over forests, pastures, and agricultural fields with inaccurate results [43].

The prediction of SOC using spectroscopy is usually based on several multivariate statistical techniques or data mining algorithms, such as multiple linear regression, stepwise multiple linear regression [44,45], principal component regression [46,47], regression trees [48], support vector machine regression [18], and artificial neural networks [49]. Partial least squares regression (PLSR) is one the most widely-used techniques, mainly because it handles multicollinearity in the reflectance spectra, and it is robust in terms of data noise [11]. However, an important drawback is that PLSR does not provide a quantitative explanation for the relationship between predictor variables and response variables [50], and it is complex to transfer models from one sensor to another [51]. Linear regression methods using spectral indices are less sophisticated than PLSR, easier to transfer among sensors, and based on the physical analysis of spectral reflectance, so they are used as an alternative modeling method to PLSR [50,51].

So far, the estimation of SOC using airborne and satellite hyperspectral sensors was mainly restricted to small agricultural or bare soil areas, and it still remains in the testing phases. Furthermore, the calibration technique used for SOC prediction in most of the previous studies was the PLSR method, which has several drawbacks related to the physical interpretation of the results and the complexity of transferring the models from one sensor to another.

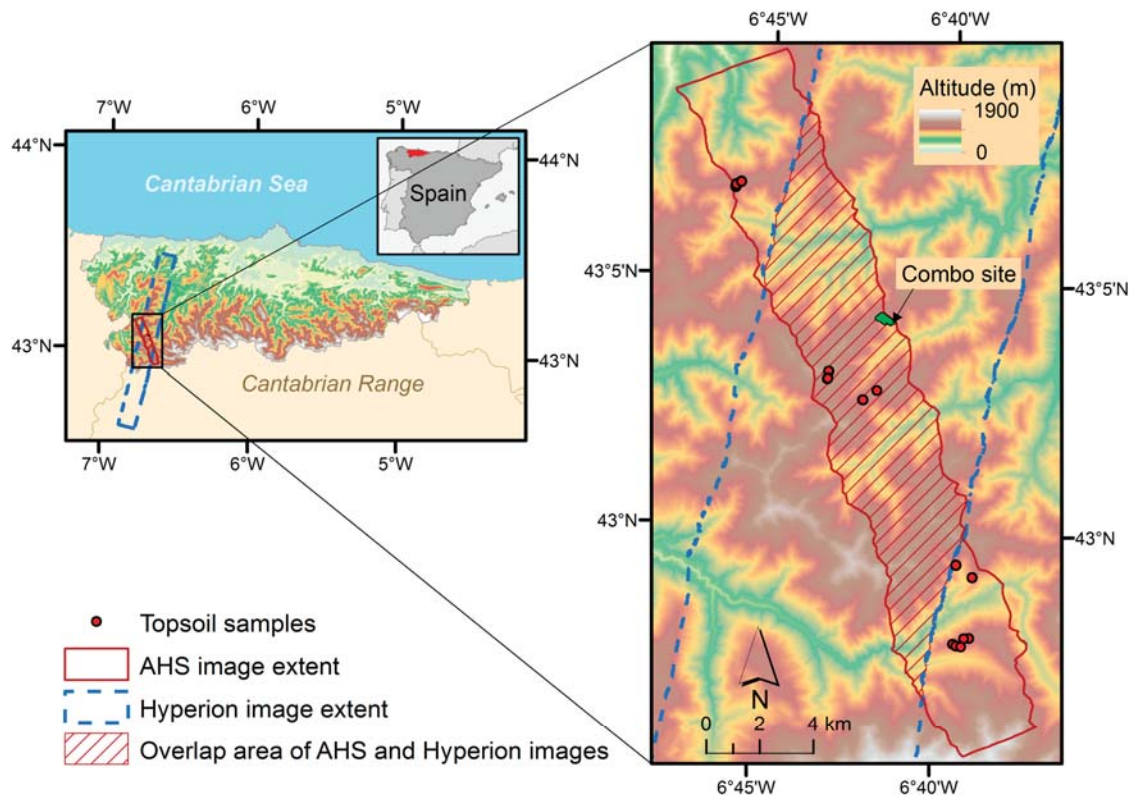
The aim of this work was to assess the capability of two hyperspectral sensors, the Airborne Hyperspectral Scanner (AHS) and the Hyperion satellite hyperspectral sensor, to estimate SOC in burned mountain areas that are slightly covered by vegetation as a result of post-fire regeneration.

The SOC estimation was carried out using simple and multiple linear regression techniques based on image reflectance values and spectral indices (SI), which are less sophisticated than the widely-used PLSR method, and have greater potential to be transferred among sensors. Comparison of prediction performance with PLSR results allowed us to evaluate whether the proposed regression models provide an acceptable accuracy.

## 2. Materials and Methods

### 2.1. Study Area

The study area is located on the western side of the Cantabrian Range (NW of Spain), and consists of a NW–SE rectangle of approximately 60 km<sup>2</sup>, which corresponds to the AHS image extent (Figure 1). The area corresponds to a mountain region with an altitude range from 400 to 1700 m above sea level, and an average slope of ~25°. The climate is Atlantic, with an average annual air temperature of 8 °C and an average annual precipitation of 1500 mm. The bedrock is very homogeneous, and is mainly composed of quartzite, sandstone, and slate. The soils are classified as Lithosols, Histosols, and Regosols, according to the World Reference Base [52], and are sandy, shallow, and stony. We chose this region because it has been affected by frequent wildfires [53], and soil in this area contains high amounts of organic matter [54], which makes it well-suited for the study. As a result of the degradation caused by the repeated burning of this region, the landscape is dominated by extensive areas of heath formations, and deciduous forests, to a lesser extent [55]. The abundance of heaths within the burned slopes located in the study area varies along a N–S gradient, with higher abundance in the northern areas. The wildfire incidence map obtained with Landsat [56] data showed regions of the study area affected by up to four wildfires from 1984 to 2011. The last wildfires in the study area were recorded in 2005 (center of the study area), 2006 (south), and 2011 (north and center-south).



**Figure 1.** Location of the study area in NW Spain and extent of the Airborne Hyperspectral Scanner (AHS) and Hyperion images.

## 2.2. Airborne Hyperspectral Data

A hyperspectral image was acquired over the study area by an Airborne Hyperspectral Scanner (AHS) mounted on a CASA 212–200 airplane (Figure 1). The image was collected on 10 October 2011 at 11:05 UTC, in a flight campaign conducted by the Spanish National Institute for Aerospace Technology (INTA). Weather conditions were favorable during the flight, with clear sky and light wind from the east. The AHS is a whiskbroom line scanner with a field of view (FOV) of 90° and 750 pixels in the across-track direction. The instantaneous FOV (IFOV) is 2.5 mrad, which results in a spatial resolution of 5 m for a flight height of ~1860 m above ground level. The AHS sensor has 80 channels from 443 to 12,952 nm. In this paper, only 63 channels in the reflective part of the electromagnetic spectrum were used: 20 channels between 443–1001 nm (VIS–NIR), with a full width at half maximum (FWHM) of 27–29 nm, and a mean signal-to-noise ratio (SNR) of 473:1, 1 channel at 1590 nm (SWIR) with a FWHM of 85 nm and a SNR of 207:1, and 42 between 1924–2553 nm (SWIR) with a FWHM of 14–18 nm and a mean SNR of 18:1.

The AHS image was geometrically and radiometrically corrected by INTA. The geometric correction was performed using the direct georeferencing code PARGE [57], and a 5-m resolution digital elevation model (DEM) provided by the Spanish National Geographic Institute (IGN). Data were projected to Universal Transverse Mercator (UTM), World Geodetic System (WGS) 84 datum and zone 30 N. The image was atmospherically and topographically corrected using ATCOR4 [58] to obtain the hemispherical-directional reflectance factor (HDRF). Spectral channels with a low SNR (SNR <10) and those located at wavelengths with strong atmospheric water vapor absorption were removed. Consequently, work was carried out with 38 AHS channels, 19 in the VIS–NIR and 19 in the SWIR.

A pixel-based supervised classification was performed on the AHS image to distinguish the burned areas, as well as the other land cover classes in the scene. The following classes were used in a true-color composite of the AHS image (bands at 650, 560 and 443 nm in the red, green and blue channels): rock, forest, herbaceous, and burned areas. This study comprises only the burned regions, which covered an area of ~8 km<sup>2</sup>. A maximum likelihood classifier [59] was calibrated using a set of training sites located in the scene. The number of training sites of each class ranged between 13 and 21. A land cover map based on field data (scale 1:25,000) was used to determine the training sites. The overall accuracy of the classification was 93.5%.

## 2.3. Satellite Hyperspectral Data

The Hyperion sensor on board the Earth Observing-1 (EO-1) satellite acquired a hyperspectral image of the study area on 30 September 2014 at 9:51 UTC, in response to a data acquisition request submitted using the National Aeronautics and Space Administration (NASA) experimental system SensorWeb. Hyperion has two pushbroom spectrometers, one in the VIS–NIR spectral region, and another in the SWIR spectral region. It collects 242 contiguous channels in the spectral range from 360 nm to 2580 nm, with a FWHM of 10–12 nm and a spatial resolution of 30 m. The Hyperion SNR decreases as the wavelength increases: 161:1 at 550 nm, 147:1 at 700 nm, 110:1 at 1125 nm, and 40:1 at 2125 nm [60]. A FOV of 0.63° at the EO-1 orbit of 705 km achieves a 7.5-km swath width. The ~100-km length Hyperion image of the study area (Figure 1) was downloaded at no cost from the United States Geological Survey (USGS) EarthExplorer platform. It was provided at a processing level 1T (L1T), with radiometric and geometric correction using ground control points, and georeferenced to the coordinate system UTM-WGS84-29N. The image was transformed to the coordinate system UTM-WGS84-30N. Channels that were not calibrated, located in strong atmospheric water vapor absorption regions, or in the overlapping region between both spectrometers, were removed. Unstable channels with a low SNR were also discarded. A total of 155 channels, which corresponded to the set of stable channels selected by Datt et al. [61], remained for further analysis.

Atmospheric/topographic correction and conversion of at-sensor radiance to surface reflectance was carried out using ATCOR4 [58], which is based on the MODTRAN5 radiative transfer code. A DEM with a spatial resolution of 5 m provided by IGN was resampled to the Hyperion resolution of

30 m and used for the illumination correction. The rural aerosol model was selected for the atmospheric correction. Visibility and water vapor maps were derived from the image. The water vapor retrieval was performed using the water absorption feature at 1130 nm.

The image was also corrected for the bidirectional reflectance distribution function (BRDF) effects, which can be especially strong in rugged terrain zones similar to the study area. Several configurations of BRDF correction input parameters were tested in ATCOR4. The reflectance values obtained using the different configurations were compared with the reference reflectance values provided by a Moderate Resolution Imaging Spectroradiometer (MODIS) image, which was collected one hour and 20 min after the Hyperion acquisition time. We selected the MODIS surface reflectance product with the best spatial resolution, 250 m (MOD09GQ). The comparison between MODIS and Hyperion reflectance values corrected with the different configurations was carried out in 12 regions of the scene: six in slopes facing the sun, and six away from the sun. The BRDF corrected image, whose reflectance values were more similar to the MODIS values in these regions, was chosen as the best correction result. The best BRDF correction involved a separate treatment for non-vegetation and vegetation areas of the image.

After visual inspection of the corrected image, several channels were found to be affected by residual noise or light vertical striping. Noise and striping were reduced by using a principal component transformation [59]. This transformation was applied to convert the corrected image to a set of 155 linearly uncorrelated bands or principal components. The first principal components contained the largest amount of image variance, while the last components contained less information and more noise. An inverse rotation was applied to transform the principal components back into the original image space, but using only the first four components, which were not affected by noise, and contained 98.6% of the image variance. As a result, a 155-channel noise-reduced image was obtained and used for further analysis.

#### 2.4. Field Data

Thirty-nine topsoil (0–5 cm) samples were taken in burned slopes in the summer of 2013 (Figure 1). In order to represent the N–S gradient in the abundance of heaths, soil samples were taken in three regions located in the north, center, and south of the study area. The location of the sampling points was recorded by a handheld global positioning system (GPS) device with an accuracy of 3–5 m (95% typical). The sampling strategy was designed originally for the 5-m resolution AHS image, and all of the samples were taken within the limits of this image in burned areas partially covered by heather. However, only 14 out of the 39 soil samples were located within limits of the Hyperion image, and only six were available if we consider that several 30-m Hyperion pixels contained more than one soil sample. Soil samples were air-dried, sieved (<2 mm), and homogenized in the lab. Total organic C (TOC) was analyzed by dry combustion at 950 °C using a Vario C-N Analyzer (Elementar Analysensysteme GmbH, Langenselbold, Germany). In our study area, TOC is equivalent to total C, as the soil parent material is non-calcareous [54]. Oxidizable C (OC) was determined using the Walkley–Black method [10].

#### 2.5. Spectral Indices

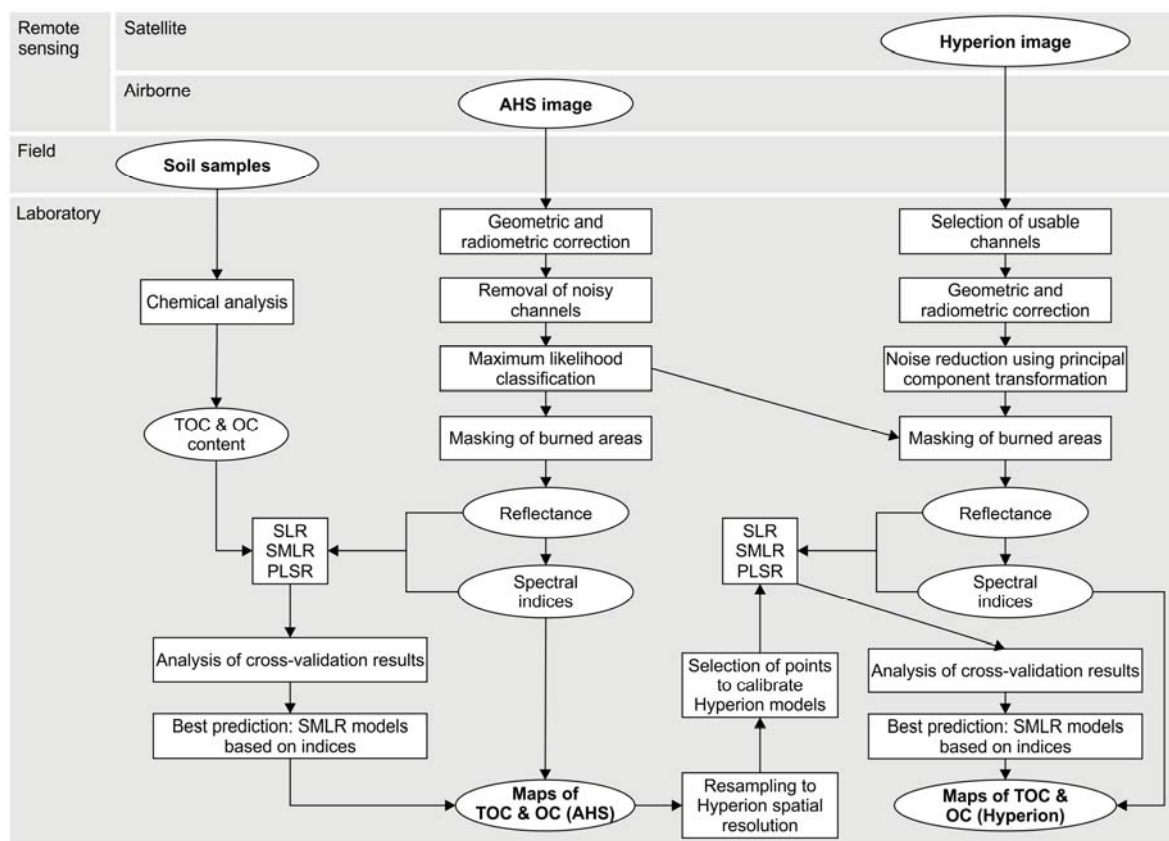
A wide range of spectral indices has been developed with the aim of estimating several biophysical parameters using remote sensing data [62]. The normalized difference vegetation index (NDVI) [63] is one of the most used vegetation indices because of its simplicity and effectiveness in quantifying green vegetation and discriminating different land covers. The NDVI is based on the reflectance measured in a red ( $q_{\text{red}}$ ) and a NIR channel ( $q_{\text{NIR}}$ ):  $\text{NDVI} = (q_{\text{NIR}} - q_{\text{red}}) / (q_{\text{NIR}} + q_{\text{red}})$ . Due to its simple structure, it is easy to transfer this index among sensors. An important factor that allows the transfer of spectral indices between sensors is that these indices are relative values, and thus the differences in absolute reflectances between sensors are ruled out. After all, the reflectance is sensitive to the sensors' characteristics and atmospheric correction. Several biochemical constituents present in the vegetation and soil, such as chlorophyll, cellulose, and lignin, influence the reflectance in the VIS–NIR–SWIR regions [51,64]. These constituents are related to SOC [65], and several authors

have identified wavelengths and spectral indices sensitive to SOC using lab and field VIS–NIR–SWIR reflectance spectra [51,66].

The most widely-used spectral indices are usually based on band differences, normalized differences, and band ratios. The normalized difference structure is well suited for vegetation studies [62] and was selected in this work, considering that the burned regions of the study area were partially covered by heather. The structure of the selected spectral index (SI) is the same as the NDVI:  $SI_{\lambda_2-\lambda_1} = (\rho_{\lambda_2} - \rho_{\lambda_1}) / (\rho_{\lambda_2} + \rho_{\lambda_1})$ , where  $\rho_{\lambda_1}$  and  $\rho_{\lambda_2}$  are the reflectance values at the effective ( $\lambda_1$ ) and reference ( $\lambda_2$ ) wavelengths. The values of this index range from  $-1$  to  $1$ . Indices with this structure were calculated from the reflectance values of the AHS and Hyperion images, using all possible two-band combinations (1406 indices for AHS, and 23,870 for Hyperion).

### 2.6. SOC Modelling Using Airborne Hyperspectral Data

The overall process of SOC estimation (TOC and OC) is shown in the flowchart in Figure 2. Reflectances and spectral indices from the AHS images were extracted for the location of the 39 soil samples and related to the TOC and OC values obtained in the chemical analysis. Reflectances and spectral indices were correlated to TOC and OC values using simple linear regression (SLR). A correlogram showing the Pearson correlation coefficient (R) versus the wavelengths was generated for both soil properties in order to identify the best AHS channels for estimating TOC and OC. For the identification of the best spectral indices, two-dimensional (2-D) correlograms were created.



**Figure 2.** Flowchart of soil organic carbon (SOC) estimations (TOC and OC) using AHS and Hyperion hyperspectral data. TOC = total organic carbon; OC = oxidizable organic carbon; SLR = simple linear regression; SMLR = stepwise multiple linear regression; PLSR = partial least squares regression.

TOC and OC predictions were also performed using stepwise multiple linear regression (SMLR). The optimum set of variables of each model was determined automatically using a combined forward

and backward selection method [67]. Only variables that remained significant at p-values lower than 0.05 were retained in the models. Two types of SMLR models were performed, using the reflectance of each AHS channel and spectral indices. As the number of variables (38 AHS channels and 1406 spectral indices) was similar to or greater than the number of observations (39 soil samples), only the most reliable channels and indices were selected for the SMLR analysis. The most reliable channels were those with the highest coefficients of determination ( $R^2$ ) obtained in the SLR models. The identification of the most reliable indices was performed in two steps to avoid duplicate AHS channels in the list of indices selected for SMLR. First, the reference wavelength ( $\lambda_2$ ) of the index with the highest  $R^2$  in the SLR was identified. Then, only the indices based on this reference wavelength were selected, and those with the highest  $R^2$  were included in the SMLR analysis.

In addition, the PLSR method [68,69] was used to establish relationships between the AHS reflectance values and both soil properties, TOC and OC. AHS reflectance spectra were mean centered before the PLSR modeling, as this preprocessing technique improved the correlation with the soil properties. The optimum number of PLSR factors or latent variables was determined by leave-one-out cross-validation and defined by the Akaike Information Criterion (AIC), which is based on a compromise between model accuracy and complexity [70,71]. The PLSR coefficients (b) [69] and the variable importance for projection (VIP) [68] were used to identify the most important wavelengths in the PLSR models. Wavelengths with higher b and VIP are considered more relevant [68]. The thresholds for b were based on their standard deviations [72], and the thresholds for VIP were set to 1, following the recommendations by Chong and Jun [73].

The performance of the SLR, SMLR, and PLSR models was assessed using three metrics obtained in the leave-one-out cross-validation: the coefficient of determination ( $R^2_{cv}$ ), the root mean square error ( $RMSE_{cv}$ ), and the ratio of performance to deviation (RPD), which is the ratio between the standard deviation of the calibration set against the  $RMSE_{cv}$ . The model having the highest RPD is considered the best model. The prediction ability of the models was classified by Chang and Laird [74] in three classes: category A ( $RPD > 2$ ), B ( $2 > RPD > 1.4$ ), and C ( $RPD < 1.4$ ), which correspond to models with good, intermediate, and low prediction abilities, respectively.

TOC and OC SMLR models with the highest RPD were applied pixel by pixel to the AHS image, in order to generate 5-m resolution maps of the burned regions located in the study area.

### 2.7. SOC Modelling Using Satellite Hyperspectral Data

The same process used to estimate TOC and OC with AHS data was followed for the estimation with Hyperion data, but using a different calibration dataset. As only six out of the 39 soil samples were available for the Hyperion image, the reference TOC and OC values that were required to calibrate the models were obtained from the maps based on AHS data. The 5-m resolution maps of TOC and OC obtained using the best SMLR models for AHS, which were those based on spectral indices, were resampled to the 30-m resolution of the Hyperion image. Data of 36 pixels ( $6 \times 6$  pixels) with a spatial resolution of 5 m were aggregated and averaged to generate data with a spatial resolution of 30 m. Two hundred points were selected in both TOC and OC maps, in burned areas delimited by the classification of the AHS image. TOC and OC values were extracted for the location of these points and related to the reflectances and spectral indices obtained from the Hyperion image. Then, SLR, SMLR, and PLSR models were calibrated following the process described in Section 2.6. The performance of the models was also assessed using the  $R^2_{cv}$ ,  $RMSE_{cv}$ , and RPD values. In addition, a stochastic simulation using the Monte Carlo method [75,76] was performed to analyze the error propagation in the best TOC and OC models for Hyperion. In the simulation, normal distribution of the errors was assumed using the Shapiro–Wilk test [77], and the number of iterations was set to 10,000 to obtain reliable results. The TOC and OC SMLR models with the highest RPD values were applied to the Hyperion image to generate 30-m resolution maps of the burned regions located in the study area.

### 3. Results

#### 3.1. Descriptive Statistics of SOC

Summary statistics of SOC are shown in Table 1. The results of the chemical analysis of the 39 soil samples showed that the study area was heterogeneous, with large variations in both TOC and OC, which is in good agreement with the results obtained in previous studies in this region [54,78]. TOC and OC maximum values were relatively high (greater than 35%) and related to the high amount of organic matter accumulated in the existing paleo surfaces. The minimum values of TOC (4.3%) and OC (2.7%) occurred in soils located in burned slopes, which are characterized by very thin organic horizons as a result of the frequent fires [79]. Higher TOC and OC values were obtained in the north and center of the study area, and lower values were obtained in the south. A high positive correlation was found between TOC and OC ( $R = 0.97$ ). The distribution of TOC and OC values in the dataset used for Hyperion was similar to the distribution observed in the ground observation dataset.


**Table 1.** Descriptive statistics of soil organic carbon (SOC).

	Ground Observation Dataset Used for AHS ( $n = 39$ )		Dataset Predicted by AHS Used for Hyperion ( $n = 200$ )	
	TOC (%)	OC (%)	TOC (%)	OC (%)
<b>Minimum</b>	4.3	2.7	5.3	5.6
<b>Maximum</b>	51.7	37.9	51.6	37.4
<b>Mean</b>	33.3	22.5	34.4	22.9
<b>Standard deviation</b>	14.6	10.3	10.6	5.9

AHS = Airborne Hyperspectral Scanner;  $n$  = number of samples; TOC = total organic carbon; OC = oxidizable organic carbon.

#### 3.2. Correlation between SOC and Reflectances/Spectral Indices

The correlation coefficient  $R$  was calculated at each wavelength between soil properties, TOC and OC, and reflectances from the AHS and Hyperion images (Figure 3). A relatively high negative correlation was observed in several wavelengths of the spectrum, with  $R$  between  $-0.5$  and  $-0.65$ , approximately. Darker soils, with lower reflectance, usually have higher organic matter content [80,81], which explains the negative correlation observed in Figure 3.



**Figure 3.** Pearson correlation coefficient between the TOC and OC content and the reflectance values from the AHS and Hyperion images.

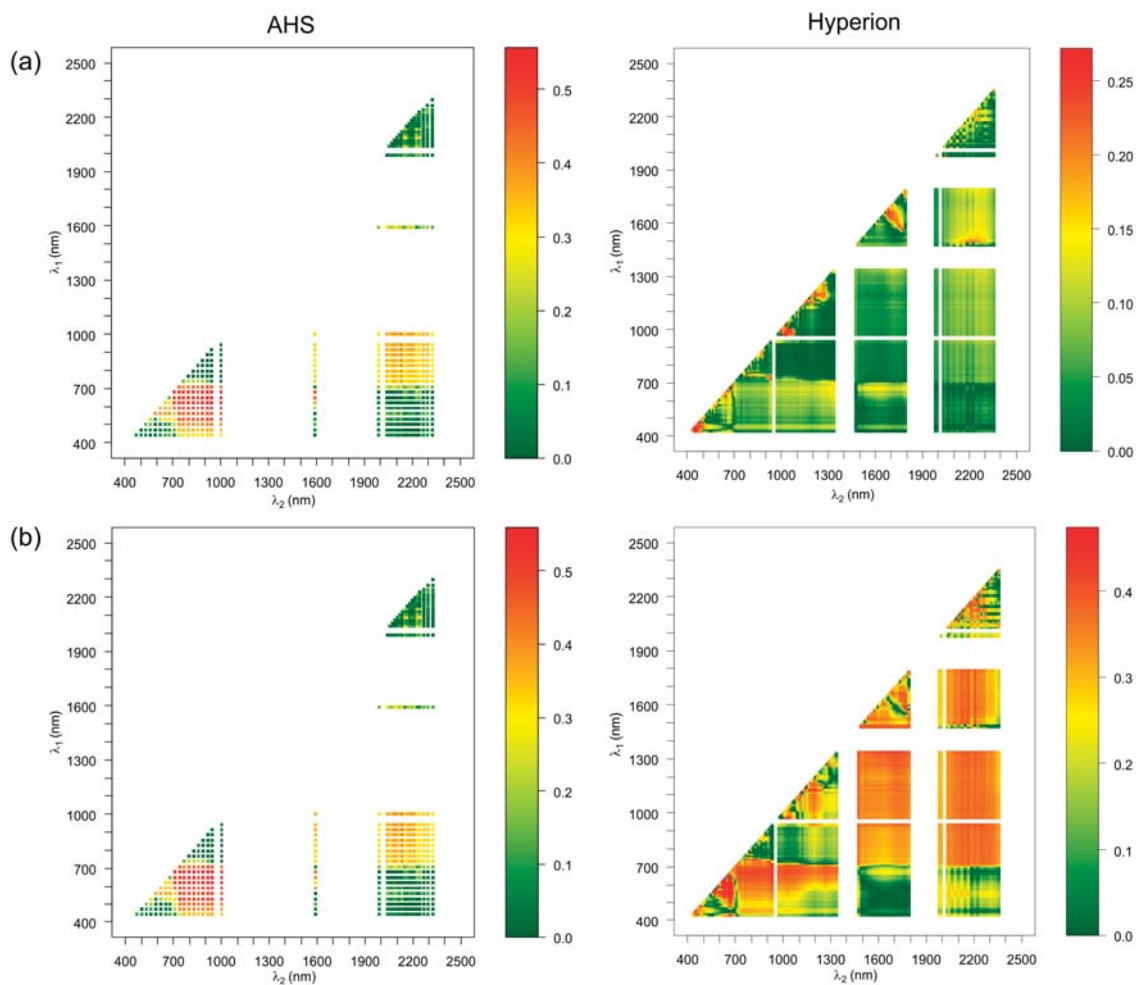


In general, the spectral regions with high correlation in Figure 3 were quite similar. The highest correlations for both soil properties and both sensors were found in the red region of the spectrum, with the maximum absolute correlation at the wavelengths at 610 and 679–681 nm. These results are consistent with those of Stevens et al. [8], who also used AHS data to estimate SOC and found an absorption feature around 600–750 nm possibly related to SOC. Bartholomeus et al. [51] estimated SOC using laboratory reflectance spectra in the VIS–NIR–SWIR, and also found the red region to be important for SOC prediction, with the highest correlation observed at ~600 nm using reflectance values, and between 640–690 nm using the inverse of the reflectance values. Vinogradov [82] also found the highest correlation between SOC and radiance in the red region of the spectrum (600–700 nm).

TOC and OC also showed high correlation in the SWIR region. Several wavelengths between ~2100–2500 nm are known to be sensitive to soil organic matter content [83,84], which can explain the relatively high correlations found in this region. The high correlation in the SWIR region is in accordance with the results obtained in a previous study in the same area by Fernández et al. [38] using laboratory reflectance spectra. They found the SWIR, mainly between ~2100–2350 nm, to be the most significant region for SOC prediction, with the most important wavelength at 2212 nm. The correlation between SOC and AHS reflectances showed chaotic features in the 2038–2326 nm region (Figure 3). These features were attributed to noise, considering that the AHS channels located in this region are characterized by a low SNR (mean SNR = 18). A similar pattern was observed at these wavelengths in previous studies based on AHS data [8]. In contrast, the correlation for the Hyperion sensor was smoother at these wavelengths, despite the low SNR of Hyperion in the SWIR (SNR = 40 at 2125 nm). The smoothed correlograms obtained for the Hyperion image could be related to the noise reduction method based on principal components that was applied to the Hyperion image, which was more effective than the method used in the AHS image, based on the elimination of the channels with lower SNR.

In order to identify the most important wavelengths to estimate SOC using spectral indices  $SI_{\lambda_2-\lambda_1}$ , all possible pair combinations of AHS/Hyperion channels in the VIS–NIR–SWIR region were evaluated. Spectral indices derived from the AHS and Hyperion images were correlated to SOC values using SLR. The coefficient of determination  $R^2$  between TOC/OC and spectral indices is shown in Figure 4. The results for the spectral indices based on AHS channels were very similar for TOC and OC. A significant region with  $R^2 \gtrsim 0.5$  was found with combinations of AHS channels in the range  $\lambda_1 = 591\text{--}679$  nm and  $\lambda_2 = 709\text{--}1001$  nm. It is noteworthy that  $\lambda_1$  and  $\lambda_2$  can be used interchangeably, as the  $R^2$  values in each graph of Figure 4 are symmetric with respect to the 1:1 line. A maximum  $R^2$  of 0.56 was obtained for both TOC and OC, with the AHS spectral index  $SI_{1001-679\text{ nm}}$ , which is based on the effective band  $\lambda_1 = 679$  nm (red) related to chlorophyll absorption [85], and the reference band  $\lambda_2 = 1001$  nm (NIR) that can be associated with organic C [48]. This spectral index corresponds to the NDVI, which is based on the reflectance at a red and a NIR wavelength.

The analysis of the coefficient of determination  $R^2$  between TOC/OC and spectral indices from Hyperion showed lower or slightly lower  $R^2$  values than those obtained for AHS (Figure 4). The lower  $R^2$  values were obtained for TOC, with a maximum value of 0.27 using the spectral index  $SI_{1023-973\text{ nm}}$ , which is based on two NIR channels. Higher  $R^2$  values were found for OC. Relatively important regions for OC were  $\lambda_1 = 539\text{--}610$  nm and  $\lambda_2 = 620\text{--}671$  nm ( $R^2 \gtrsim 0.40$ ),  $\lambda_1 = 630\text{--}712$  nm and  $\lambda_2 = 732\text{--}1336$  nm ( $R^2 \gtrsim 0.35$ ),  $\lambda_1 = 732\text{--}1336$  nm and  $\lambda_2 = 1477\text{--}2355$  nm ( $R^2 \gtrsim 0.30$ ), and  $\lambda_1 = 1508\text{--}1790$  nm and  $\lambda_2 = 2032\text{--}2254$  nm ( $R^2 \gtrsim 0.30$ ). A maximum  $R^2$  of 0.45 was obtained for the spectral index  $SI_{1033-973\text{ nm}}$ . The Hyperion spectral indices with the highest correlation were consistent for TOC and OC, with  $\lambda_1 = 973$  nm and  $\lambda_2 = 1023\text{--}1033$  nm as the best band combinations. Wavelengths at ~960 nm could be related to organic pigments, and those at ~1020–1030 nm could be related to organic C [48]. These wavelengths, which were found to be relevant for SOC estimations using Hyperion indices  $SI_{\lambda_2-\lambda_1}$ , are not covered by the AHS sensor.



**Figure 4.** Coefficient of determination  $R^2$  between the TOC (a)/OC content (b) and the spectral indices  $SI_{\lambda_2-\lambda_1} = (\rho_{\lambda_2} - \rho_{\lambda_1}) / (\rho_{\lambda_2} + \rho_{\lambda_1})$ , based on AHS (left) and Hyperion (right) reflectance values.  $R^2$  values in the graphs are symmetric with respect to the 1:1 line, and therefore  $\lambda_1$  and  $\lambda_2$  can be used interchangeably.

### 3.3. SOC Predictive Models

Several regression techniques (SLR, SMLR, and PLSR) were used to calibrate models for the estimation of TOC and OC via AHS/Hyperion reflectances and spectral indices  $SI_{\lambda_2-\lambda_1}$ . Summary statistics of the leave-one-out cross-validation of the models for all soil properties, sensors, and regression techniques are gathered in Table 2. The best AHS/Hyperion channels and spectral indices for the estimation of both soil properties were identified and used to calibrate SLR models. The prediction equations of these models are listed in Table 2. In general, better SLR models were obtained for: the AHS sensor (mean RPD = 1.34) than for the Hyperion sensor (mean RPD = 1.25), OC (mean RPD = 1.31) than for TOC (mean RPD = 1.27), and spectral indices (mean RPD = 1.35) than for individual channels (mean RPD = 1.24). According to the model classification by Chang and Laird [74] based on RPD values, the SLR models had low prediction ability, except for the SLR models for TOC/OC estimation using the AHS spectral index  $SI_{1001-679 \text{ nm}}$ , which showed an intermediate prediction ability ( $R^2_{cv} = 0.52$  and RPD = 1.46).

**Table 2.** Leave-one-out cross-validation statistics of the regression models for soil organic C prediction using AHS and Hyperion data.

Sensor	Soil Property	Regression Technique	Prediction Equation	<i>n</i>	R <sup>2</sup> <sub>cv</sub>	RMSE <sub>cv</sub> (%)	RPD		
AHS	TOC (%)	SLR-1 channel	TOC = 66 – 1008 × $q_{679\text{ nm}}$	39	0.35	11.69	1.25		
		SLR-1 index	TOC = –101 + 186 × SI <sub>1001–679 nm</sub>	39	0.52	10.02	1.46		
		SMLR-3 channels		39	0.51	10.13	1.44		
		SMLR-8 indices	See Table 3	39	0.62	9.05	1.62		
		PLSR-3 factors		39	0.49	10.39	1.41		
		OC (%)	SLR-1 channel	OC = 43 – 640 × $q_{679\text{ nm}}$	39	0.27	8.70	1.18	
	OC (%)	SLR-1 index	OC = –72 + 131 × SI <sub>1001–679 nm</sub>	39	0.52	7.02	1.46		
		SMLR-3 channels		39	0.52	7.06	1.46		
		SMLR-2 indices	See Table 3	39	0.60	6.44	1.60		
		PLSR-3 factors		39	0.48	7.34	1.40		
		Hyperion	TOC (%)	SLR-1 channel	TOC = 58 – 356 × $q_{610\text{ nm}}$	200	0.34	8.55	1.24
				SLR-1 index	TOC = –46 + 2276 × SI <sub>1023–973 nm</sub>	200	0.23	9.26	1.14
SMLR-15 channels				200	0.44	7.91	1.33		
SMLR-18 indices	See Table 3			200	0.49	7.58	1.39		
PLSR-4 factors				200	0.32	8.68	1.22		
OC (%)	SLR-1 channel			OC = 33 – 177 × $q_{681\text{ nm}}$	200	0.40	4.59	1.29	
OC (%)	SLR-1 index		OC = –20 + 1218 × SI <sub>1033–973 nm</sub>	200	0.43	4.48	1.32		
	SMLR-10 channels			200	0.54	4.02	1.48		
	SMLR-20 indices		See Table 3	200	0.61	3.74	1.58		
	PLSR-4 factors			200	0.44	4.45	1.33		

RMSE<sub>cv</sub> = root mean square error of cross-validation; RPD = ratio of performance to deviation; SLR = simple linear regression; SMLR = stepwise multiple linear regression; PLSR = partial least squares regression; SI = spectral index.

SMLR models were calibrated in order to improve the estimation of TOC and OC based on SLR. Two types of SMLR models were performed using reflectances of the AHS/Hyperion channels and spectral indices. The cross-validation statistics of the SMLR models are shown in Table 2. Models based on SMLR performed better than those based on SLR, for both soil properties and for both sensors. In all cases, the SMLR models based on spectral indices showed better results than the models based on reflectances. The most reliable SMLR models were obtained for AHS with spectral indices based on the reference channel at 1001 nm, using eight indices for TOC ( $R^2_{cv} = 0.62$  and  $RMSE_{cv} = 9.05\%$ ), and two indices for OC ( $R^2_{cv} = 0.60$  and  $RMSE_{cv} = 6.44\%$ ). Both models showed a relatively good performance, with the  $RPD \geq 1.60$ , which corresponds to models with an intermediate prediction ability, according to Chang and Laird [74]. The performance of the SMLR models based on indices was slightly lower for Hyperion. The model for Hyperion to estimate TOC was based on indices with the reference channel at 1023 nm, and showed  $R^2_{cv} = 0.49$ ,  $RMSE_{cv} = 7.58\%$ , and a low/intermediate prediction ability, with the  $RPD = 1.39$ . A slightly lower RPD value was obtained in the Monte Carlo simulation performed to analyze the error propagation in this model (mean  $RPD = 1.23$ ). The SMLR model for OC, based on indices with the reference channel at 1033 nm, was more reliable, showing an  $R^2_{cv} = 0.61$ ,  $RMSE_{cv} = 3.74\%$ , and  $RPD = 1.58$ . A lower RPD value was also obtained in the Monte Carlo simulation performed for this model (mean  $RPD = 1.20$ ). The prediction equations of the SMLR models based on indices are shown in Table 3.

The estimation of TOC and OC was also performed with the PLSR method. AHS/Hyperion reflectance spectra were mean centered before the PLSR modeling, as this preprocessing technique improved the RPD. The optimum number of factors—three for AHS and four for Hyperion models—was determined by leave-one-out cross-validation, using the AIC. The cross-validation statistics and the number of factors of the PLSR models are shown in Table 2. The validation of the PLSR models for AHS showed the  $RPD = 1.40$ – $1.41$ , which fall within the intermediate class of RPD, and  $R^2_{cv} = 0.48$ – $0.49$ . Slightly lower values were obtained for the PLSR models for Hyperion, with  $R^2_{cv} = 0.32$ – $0.44$  and  $RPD = 1.22$ – $1.33$ .

The accuracy of the regression models was higher using SMLR than PLSR. The SMLR models based on spectral indices showed higher  $R^2_{cv}$  and RPD values than PLSR, and also lower  $RMSE_{cv}$ . This result is unexpected, since it is supposed that PLSR performs better than SMLR, considering that hyperspectral reflectance spectra are usually affected by multicollinearity, and PLSR is able to handle


it. The PLSR results might be improved to obtain similar values to SMLR by applying further spectra preprocessing techniques, which usually increase the RPD. However, the use of more sophisticated preprocessing techniques was discarded in this work, in which the PLSR models were only included as a reference. SMLR was also found to perform better than PLSR in previous studies that used hyperspectral data to estimate soil properties [22]. These authors pointed out that a large calibration dataset would be required for further research on this issue.

**Table 3.** Expressions of the best SMLR models for soil organic C estimation using AHS and Hyperion data. The prediction equation of each model is  $S = b_0 + b_1 \times SI_{\lambda_2-\lambda_1,1} + b_2 \times SI_{\lambda_2-\lambda_1,2} + \dots + b_n \times SI_{\lambda_2-\lambda_1,n}$ , where S is the soil property,  $b_0$  is the intercept,  $b_1$ – $b_n$  are the regression coefficients, and  $SI_{\lambda_2-\lambda_1}$  are the spectral indices, with the structure  $SI_{\lambda_2-\lambda_1} = (\rho_{\lambda_2} - \rho_{\lambda_1}) / (\rho_{\lambda_2} + \rho_{\lambda_1})$ .

AHS				Hyperion			
TOC (%)		OC (%)		TOC (%)		OC (%)	
$b_{0-n}$	$SI_{\lambda_2-\lambda_1,1-n}$	$b_{0-n}$	$SI_{\lambda_2-\lambda_1,1-n}$	$b_{0-n}$	$SI_{\lambda_2-\lambda_1,1-n}$	$b_{0-n}$	$SI_{\lambda_2-\lambda_1,1-n}$
–192		–116		–29		–172	
1679	$SI_{1001-471\text{ nm}}$	249	$SI_{1001-679\text{ nm}}$	–1693	$SI_{1023-844\text{ nm}}$	–2128	$SI_{1033-427\text{ nm}}$
–3941	$SI_{1001-500\text{ nm}}$	–82	$SI_{1001-2150\text{ nm}}$	–24,127	$SI_{1023-1064\text{ nm}}$	–4832	$SI_{1033-457\text{ nm}}$
3325	$SI_{1001-530\text{ nm}}$			19,806	$SI_{1023-1094\text{ nm}}$	5509	$SI_{1033-468\text{ nm}}$
–2432	$SI_{1001-591\text{ nm}}$			–24,888	$SI_{1023-1104\text{ nm}}$	6087	$SI_{1033-539\text{ nm}}$
1991	$SI_{1001-620\text{ nm}}$			24,104	$SI_{1023-1114\text{ nm}}$	–8698	$SI_{1033-569\text{ nm}}$
–494	$SI_{1001-709\text{ nm}}$			–31,871	$SI_{1023-1185\text{ nm}}$	4859	$SI_{1033-590\text{ nm}}$
276	$SI_{1001-2102\text{ nm}}$			26,902	$SI_{1023-1245\text{ nm}}$	–1368	$SI_{1033-925\text{ nm}}$
–198	$SI_{1001-2150\text{ nm}}$			–10,102	$SI_{1023-1316\text{ nm}}$	–17,970	$SI_{1033-983\text{ nm}}$
				–12,028	$SI_{1023-1498\text{ nm}}$	12772	$SI_{1033-993\text{ nm}}$
				–14,115	$SI_{1023-1558\text{ nm}}$	14470	$SI_{1033-1044\text{ nm}}$
				18,239	$SI_{1023-1588\text{ nm}}$	8856	$SI_{1033-1266\text{ nm}}$
				13,523	$SI_{1023-1790\text{ nm}}$	–11,975	$SI_{1033-1276\text{ nm}}$
				–9758	$SI_{1023-1982\text{ nm}}$	–6386	$SI_{1033-1639\text{ nm}}$
				7336	$SI_{1023-1992\text{ nm}}$	9555	$SI_{1033-1679\text{ nm}}$
				8275	$SI_{1023-2052\text{ nm}}$	4928	$SI_{1033-2083\text{ nm}}$
				9878	$SI_{1023-2103\text{ nm}}$	–4845	$SI_{1033-2153\text{ nm}}$
				–11,850	$SI_{1023-2163\text{ nm}}$	–6318	$SI_{1033-2163\text{ nm}}$
				–3555	$SI_{1023-2355\text{ nm}}$	–5679	$SI_{1033-2194\text{ nm}}$
						4452	$SI_{1033-2214\text{ nm}}$
						5356	$SI_{1033-2244\text{ nm}}$

### 3.4. Relevant Wavelengths for SOC Prediction

The most important wavelengths in the regression models for TOC/OC prediction using AHS and Hyperion data are shown in Figure 5, in which the AHS and Hyperion channels used in this work were also included. In the SLR and SMLR models based on indices  $SI_{\lambda_2-\lambda_1}$ , both  $\lambda_1$  and  $\lambda_2$  wavelengths were represented in Figure 5. The most important wavelengths in the PLSR models were those with both PLSR coefficients (b) greater than their standard deviations, and VIP values greater than 1.



**Figure 5.** Important wavelengths in the regression models for TOC/OC estimation using AHS and Hyperion data. The width of each channel corresponds to the full width at half maximum (FWHM). AHS and Hyperion channels used in this study are represented in dark grey. HYP = Hyperion, VIS = visible; NIR = near infrared; SWIR = short-wave infrared.

The AHS channel at 679 nm (red) and the AHS spectral index  $SI_{1001-679\text{ nm}}$  were relevant for TOC and OC prediction, according to the results shown in Section 3.2. The most accurate TOC/OC predictions for AHS were obtained using SMLR models based on indices with the reference wavelength at 1001 nm, and effective wavelengths mainly in the red (620 and 679 nm) and SWIR regions (2102 and 2150 nm), although other wavelengths in the VIS region were also relevant for TOC. The red and SWIR regions were also important in the PLSR models for TOC/OC prediction. Several wavelengths between 2086–2326 nm were relevant in the PLSR models for AHS, but not in the SMLR models based on indices. However, the results obtained with both techniques were consistent, with the most important wavelengths in the red and SWIR regions. The red region of the spectrum was also relevant for the SOC and organic matter estimations in previous studies [8,51,82], and also the SWIR region, mainly between 2100–2500 nm [83,84]. The AHS channel at 679 nm can be associated with chlorophyll absorption [85], and channels at 2102 and 2150 nm with lignin and recalcitrant C [38,48,86].

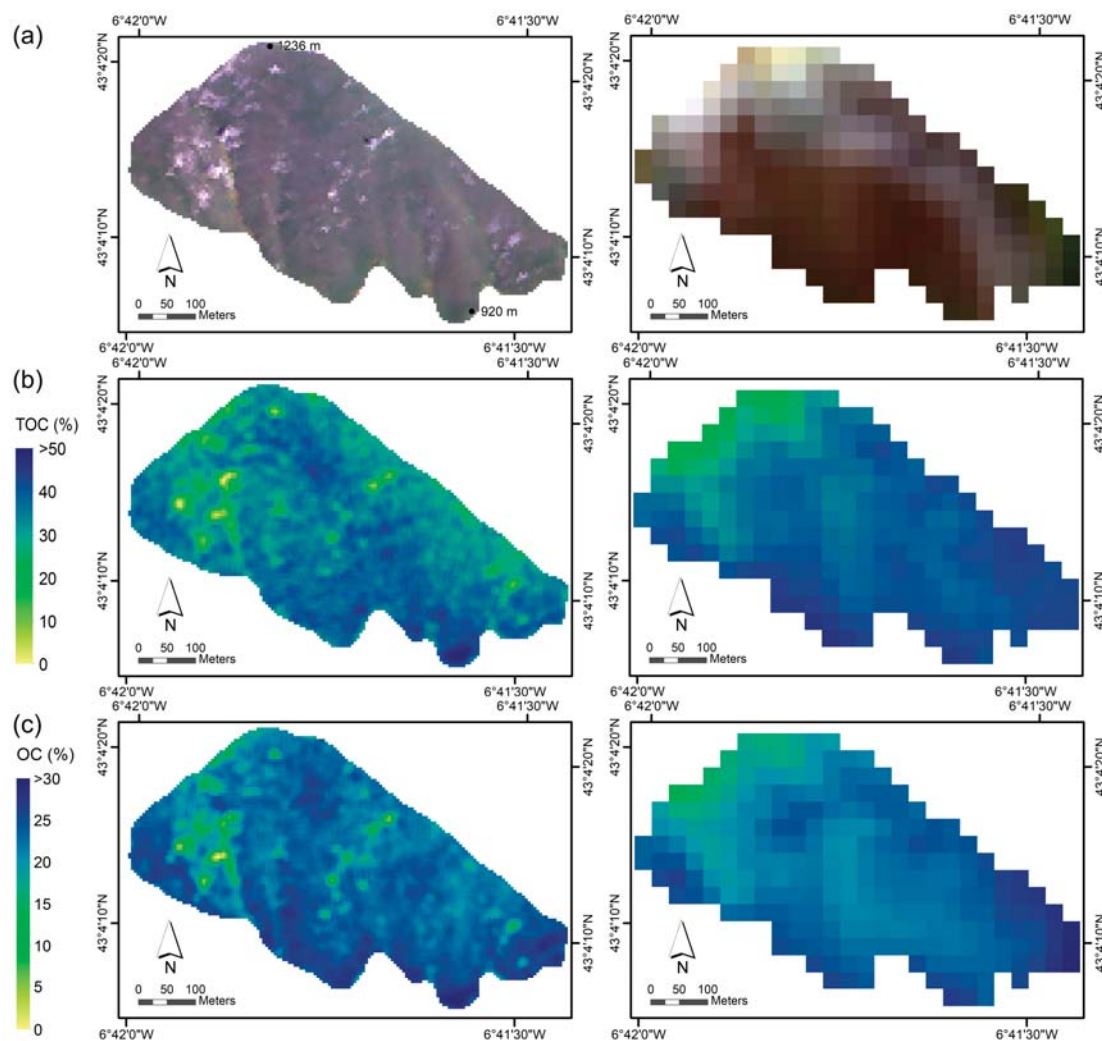
Regarding the Hyperion sensor, channels in the red region of the spectrum (610 nm and 681 nm), and spectral indices based on channels in the NIR region ( $SI_{1023-973\text{ nm}}$  and  $SI_{1033-973\text{ nm}}$ ), were found to be relevant to estimate TOC and OC, as shown in Section 3.2. The most reliable models for Hyperion were the SMLR models based on indices, with the reference wavelength at 1023/1033 nm and effective wavelengths distributed across the VIS–NIR–SWIR region, especially from 983 nm onwards. Hyperion channels in the visible region between 427–712 nm were also important for TOC/OC prediction, according to the PLSR results. These channels correspond to the region with the best SNR of the Hyperion sensor [60]. In general, the most significant regions to estimate SOC using Hyperion are consistent with the results found in previous studies, in which the red [8,51,82] and SWIR regions [83,84] were also important. Wavelengths at ~960 nm, ~1020–1030 nm, and ~2000–2200 nm might be related to organic pigments, organic C, and carbon-hydrogen/nitrogen-hydrogen groups, respectively [48]. Other relevant wavelengths in the regression models could also be associated with organic compounds such as starch, lignin, and cellulose [64], but the attribution to a single component is difficult, as many compounds show overlapping bands in the region 700–2500 nm [87].

Although Hyperion has more channels, and narrower channels, than AHS, which are located in regions not covered by AHS that might be relevant for SOC estimation, the predictions were slightly

worse for Hyperion than AHS. The larger number of indices involved in the SMLR models for Hyperion (18–20 indices) compared with AHS (2–8 indices) also reflects the relatively lower performance of the Hyperion models. These results were attributed to the lower SNR of the Hyperion sensor.

### 3.5. SOC Mapping

The best regression models for both sensors and both soil properties, which were based on SMLR and spectral indices (Table 3), were applied pixel by pixel to the geometrically and radiometrically corrected images. For illustration purposes, maps of TOC and OC content in the upper 5 cm of soils were obtained for the Combo site ( $6^{\circ}41'43.9''\text{W}$ ,  $43^{\circ}4'13.5''\text{N}$ ) (Figure 6). This site corresponds to a  $\sim 20$  ha burned slope located within the overlap region of the AHS and Hyperion images (see location in Figure 1). The altitude of Combo site varies along a NW–SE gradient, from  $\sim 1230$  m in the northwestern part of the slope to  $\sim 920$  m in the southeastern part. TOC and OC prediction at the Combo site was performed at two spatial resolutions, using the 5-m AHS image and the 30-m Hyperion image. Maps derived from the AHS image were smoothed by applying a mean filter with a window size of  $3 \times 3$  pixels, to reduce residual noise and clearly show the spatial distribution of both TOC and OC.



**Figure 6.** True-color composite (a) and maps of topsoil TOC (b) and OC content (c) predicted using the SMLR models based on spectral indices at the Combo site. Left: AHS image (airborne, spatial resolution of 5 m). Right: Hyperion image (satellite, spatial resolution of 30 m). The location of the Combo site is shown in Figure 1.

The descriptive statistics of the maps in Figure 6 showed values in the same range as the calibration datasets, with mean TOC = 35.7–38.0% and mean OC = 21.2–22.4%, for the maps based on the AHS and Hyperion images, respectively. In general, the prediction was consistent for the AHS and Hyperion images, despite the significant difference in their spatial resolution. The TOC content in the maps were higher than the OC content, as expected. TOC and OC content were also highly correlated in both the maps derived from AHS ( $R = 0.84$ ) and Hyperion ( $R = 0.90$ ). The spatial distribution of TOC and OC content within the slope seems to be linked to the altitude and topography, with lower contents in the upper areas, and higher contents in the lower and depressed areas. This distribution might be explained by local transfer processes such as the erosion, which led to the accumulation of SOC in the lower areas. The relief and topography were found to be related to SOC distribution in previous studies, which focused on agricultural fields [8,21,23,88].

#### 4. Discussion

The performance of the SMLR models based on spectral indices was compared with the results found in previous studies, in which SOC and organic matter were estimated using airborne and satellite hyperspectral data. The validation statistics of these studies are shown in Table 4, in which the results obtained in this study were also included for comparison purposes. The comparison was performed using the  $R^2$  and RPD values, and not the RMSE values, as they are not comparable among studies that estimate slightly different soil properties, which have different ranges of variation, and are expressed in different units.

SOC and organic matter were estimated in several studies using airborne hyperspectral imagery, with a number of channels between 20 and 282 in the VIS–NIR–SWIR region, and spatial resolutions ranging from 1 m to 8 m. Most of these studies were aimed at estimating SOC over agricultural or bare soil areas. Only three out of 19 estimated SOC over areas partially covered by vegetation, all of them using PLSR [36–38]. The results obtained in this study using AHS data ( $R^2 \geq 0.60$  and  $RPD \geq 1.60$ ) were in the range of those found in the literature. Bartholomeus et al. [37] used AHS data and the residual spectral unmixing technique to estimate SOC in fields partially covered by maize, and obtained slightly worse results in the validation ( $R^2 = 0.56$  and  $RPD = 1.50$ ). Fernández et al. [38] calibrated PLSR models using laboratory reflectance spectra that were subsequently applied to an AHS image to estimate SOC. They obtained slightly better results ( $R^2 = 0.72$ – $0.73$  and  $RPD = 1.89$ – $1.92$ ) than those obtained in this study. However, the application of the method proposed in Fernández et al. [38] is more complicated, as it requires the collection of laboratory reflectance spectra of the soil samples, as well as the determination of a correction factor to obtain soil maps from lab predictions. The model for organic matter prediction by Franceschini et al. [36] showed comparable results ( $R^2 = 0.60$  and  $RPD = 1.60$ ) to those obtained here.

The validation results of previous studies that used airborne hyperspectral data to predict SOC/organic matter over agricultural or bare soil areas were heterogeneous, with  $R^2$  between 0.02–0.96, and RPD values between 0.99 and 3.13. Denis et al. [29] obtained the best results ( $R^2 = 0.96$  and  $RPD = 3.13$ ) by correcting the soil shadow effect on the image reflectance through using a wavelength-dependent correction factor calculated from soil vertical photographs taken in the field. Stevens et al. [27] used a large dataset with 400 samples and obtained good results ( $R^2 = 0.79$  and  $RPD = 2.33$ ) by performing local models for the different regions and soil textures found in the study area. The SOC prediction models by Hbirkou et al. [21] were calibrated using a relatively large dataset with 204 samples, and obtained good results in the validation ( $R^2 = 0.83$  and  $RPD = 2.45$ ). These authors also suggested the use of local calibrations for different surface conditions to improve the accuracy of the models. Most of the studies for SOC prediction over bare soil areas using airborne imagery were based on PLSR, and showed an intermediate prediction ability, with RPD values typically between 1.4 and 1.9, and  $R^2$  between  $\sim 0.6$ – $0.8$ .

**Table 4.** Validation statistics of previous studies for SOC/organic matter estimation using airborne and satellite hyperspectral data in the VIS–NIR–SWIR region.

Sensor <sup>a</sup>	Spectral Range (nm) <sup>b</sup> , Number of Bands, and Spatial Resolution (m)	Study Area (Country) <sup>c</sup>	Soil Property <sup>d</sup>	Modeling Technique <sup>e</sup>	$r_{\text{val}}$   $r_{\text{val}}$ <sup>f</sup>	RMSE <sup>g</sup>	R <sup>2</sup> <sup>g</sup>	RPD <sup>g</sup>	Authors
AHS *	400–1600 (VNS), 21, 2.6	Agric. fields (Belgium)	C.org.	PLSR (2)	110 xval	1.7 g/kg	0.54	1.47	Stevens et al. [30]
AHS *	430–1600 (VNS), 21, 2.6	Agric. fields (Luxembourg)	C.org.	PLSR	267   134	4.3 g/kg	0.72	1.89	Stevens et al. [8]
AHS *	430–1600 (VNS), 21, 2.6	Agric. fields (Luxembourg)	C.org.	PLSR	400 xval	3.9 g/kg	0.79	2.33	Stevens et al. [27]
AHS *	430–2540 (VNS), 63, 2.6	Agric. fields (Luxembourg)	C.org.	PLSR	91 xval	3.7 g/kg	0.96	3.13	Denis et al. [29]
AHS *	450–2120 (VNS), 30, 2.6	Partially vegetated agric. fields (Belgium)	C.org.	PLSR (8)	52   16	1.7 g/kg	0.56	1.50	Bartholomeus et al. [37]
AHS *	442–1019 (VNI), 20, 2.6	Agric. fields (Luxembourg)	C.org.	PLSR	46   31	2.2 g/kg	0.74	1.9	Steinberg et al. [28]
AHS *	430–2335 (VNS), 38, 5	Partially vegetated burned areas (Spain)	C total C oxid.	PLSR (7) PLSR (7)	89   10 89   10	7.8% 5.1%	0.73 0.72	1.92 1.89	Fernandez et al. [38]
AHS *	430–2335 (VNS), 38, 5	Partially vegetated burned areas (Spain)	C total C oxid.	SMILR (8) SMILR (2)	39 xval 39 xval	9.1% 6.4%	0.62 0.60	1.62 1.60	Peón et al. [this paper]
HypMap *	420–2480 (VNS), 127, 6	Agric. fields (Germany)	C.org.	PLSR (7)	60 xval	0.29%	0.90		Selige et al. [22]
HypMap *	450–2500 (VNS), 128, 4	Agric. fields (Germany)	C.org.	MLR (4)	60 xval	0.22%	0.86		
HypMap *	450–2500 (VNS), 128, 4	Agric. fields (Germany)	C.org.	PLSR	9 xval	1.6 g/kg	0.74		Patzold et al. [26]
HypMap *	420–2480 (VNS), 110, 6	Bare soils (Spain)	C total	PLSR	61   61	0.13%	0.77	1.92	Schwanghart and Janner [23]
HypMap *	450–2480 (VNS), 128, 4	Agric. fields (Germany)	C.org.	PLSR (2)	38   29	2.1 g/kg	0.71	1.80	Gerighausen et al. [24]
HypMap *	400–2500 (VNS), 124, 5	Agric. fields (France)	C.org.	PLSR	95 xval	2.6 g/kg	0.02	0.99	Gomez et al. [25]
HypMap *	539–2477 (VNS), 126, 8	Agric. fields (Germany)	C.org.	PLSR (7)	204 xval	1.1 g/kg	0.83	2.45	Hibikou et al. [21]
DAS *	400–2500 (VNS), 69, 8	Agric. fields (Israel)	OM	MLR (4)	62   15		0.83		Ben-Dor et al. [34]
HSTIR *	400–2450 (VNS), 178, 2.5	Agric. fields (USA)	C.org.	PLSR (8)	269 xval	0.18%	0.64	1.39	Hively et al. [35]
P-AISA *	400–2500 (VNS), 282, 1	Weathered soils (Brazil)	OM	PLSR (8)	60 xval	2.8 g/kg	0.60	1.60	Franceschini et al. [36]
AVNIR *	429–1010 (VNI), 60, 1.2	Agric. fields (California)	C total OM	MLR (4) MLR (4)	321   - 321   -	0.08% 0.08%	0.27 0.49		DeTar et al. [33]
CASI *	409–947 (VNI), 71, 2	Agric. fields (Canada)	OM	PCA-SMILR	47 xval	0.5%	0.75	1.57	Umo et al. [32]
CASI *	405–950 (VNI), 96, 6	Agric. fields (Belgium)	C.org.	PLSR (2)	170   57	5.1 g/kg	0.85	1.86	Stevens et al. [31]
HYP **	427–2355 (VNS), 152, 30	Agric. fields and pastures (Australia)	C.org.	PLSR (3)	72 xval	0.73%	0.51	1.43	Gomez et al. [39]
HYP **	468–1770 (VNS), 98, 30	Forests, pastures and agric. fields (USA)	C.org.	SMILR-ANN	227   76	11.3 t/ha		0.68	Jaber et al. [43]
HYP **	400–2500 (VNS), 158, 30	Agric. fields (China)	C.org.	PLSR (3)	47 xval	1.6 g/kg	0.63	1.65	Lu et al. [40]
HYP **	400–2500 (VNS), 150, 30	Agric. fields (USA)	C total OM	PLSR (3) PLSR (4)	20   8 20   8	0.33% 0.66%	0.48 0.74	1.48 1.91	Zhang et al. [41]
HYP **	436–2345 (VNS), 171, 30	Maize crops (Italy)	OM	OLS MNF	72 xval	0.15%		2.93	Casaldi et al. [42]
HYP **	427–2335 (VNS), 155, 30	Partially vegetated burned areas (Spain)	C total C oxid.	SMILR (18) SMILR (20)	200 xval 200 xval	7.6% 3.7%	0.49 0.61	1.39 1.58	Peón et al. [this paper]

<sup>a</sup> Asterisks indicate the sensor type: airborne (\*), satellite (\*\*). <sup>b</sup> Sensor names: HSTIR = HyperSpectIR, P-AISA = ProSpectIR-AISA, HYP = Hyperion. <sup>c</sup> The spectral region is shown in brackets: visible (V, 400–700 nm), near infrared (N, 700–1300 nm), short-wave infrared (S, 1300–2500 nm). <sup>d</sup> C.org. = C organic, C.oxid. = C oxidizable, OM = organic matter. <sup>e</sup> MLR = multiple linear regression, PCA = principal component analysis, ANN = artificial neural network, OLS MNF = ordinary least squares using the minimum noise fraction eigenvectors. <sup>f</sup> The number of channels or PLSR factors used in the models is shown in brackets. <sup>g</sup>  $r_{\text{val}}$  |  $r_{\text{val}}$  indicate the number of samples used in the calibration and in the validation, respectively. “xval” indicates that the validation was performed using the cross-validation technique. <sup>h</sup> RMSE, R<sup>2</sup>, and RPD obtained in the validation.



SOC has rarely been estimated using satellite hyperspectral data, and only the Hyperion sensor with a spatial resolution of 30 m was used (Table 4). The validation statistics obtained with Hyperion data in this study ( $R^2 = 0.49\text{--}0.61$  and  $RPD = 1.39\text{--}1.58$ ) were comparable to those found in bare soil or agricultural areas [39–41]. PLSR models obtained in these studies also provided an intermediate prediction ability, with  $R^2 = 0.48\text{--}0.74$ , and  $RPD = 1.43\text{--}1.91$ . Regarding the studies in areas covered by vegetation, heterogeneous validation results were reported. The results obtained in this study were better than those reported by Jaber et al. [43], which used a large dataset with 227 samples to model SOC over forests, pastures, and agricultural fields, using SMLR and artificial neural networks. Their results using both SMLR and artificial neural networks were significantly better than those using only SMLR or PLSR, but their models showed a low prediction ability, with  $RPD = 0.68$ . Castaldi et al. [42] used Hyperion data to estimate organic matter in maize crops and did not find significant differences between the validation results obtained under bare soil and vegetation cover conditions. They obtained PLSR models with low prediction ability ( $RPD = 1.02$ ) under vegetation conditions, using a calibration dataset with organic matter in the range of 1.1–2.7%. However, the performance of these models was improved significantly using the ordinary least squares technique and the minimum noise fraction (MNF) eigenvectors instead of the reflectance spectra ( $RPD = 2.93$ ).

The results obtained in the Monte Carlo simulation that was performed to analyze the error propagation in the best models for the Hyperion sensor (mean  $RPD = 1.23$  for TOC and mean  $RPD = 1.20$  for OC) were slightly lower than those obtained in the cross-validation of the same models (Table 2), but still comparable to those found in previous studies in Table 4.

Based on the results obtained in previous studies for SOC estimation using either airborne or satellite hyperspectral data (Table 4), SOC prediction is expected to improve by using large datasets, which would allow the calibration of local models for the different regions and soil textures in the study area. The prediction could also be improved by applying methods to reduce the soil relative shadows, as well as using more sophisticated modeling techniques, such as multivariate adaptive regression splines (MARS) or artificial neural networks, which are currently used for SOC estimation with lab spectroscopy [11]. The use of the MNF transformation before modeling might effectively segregate the noise in the reflectance spectra and improve the estimation. The prediction of SOC over areas partially covered by vegetation might be improved with the application of spectral unmixing techniques.

However, the use of complex modeling techniques or methods that require extensive field data collection contrasts with the idea of operational soil mapping. Field campaigns for the collection of soil samples are expensive and time-consuming. The use of legacy data to calibrate models might be very profitable for operational soil mapping [89]. Efforts should also focus on the development of simple techniques to estimate SOC, such as the use of spectral indices in combination with SMLR. The identification of spectral regions that are important for SOC prediction could also help create new indices with high potential to be transferred to future hyperspectral sensors. Several next generation satellite VIS–NIR–SWIR hyperspectral sensors are planned to be launched, including: HISUI from Japan [90], PRISMA from Italy [91], and EnMAP from Germany in 2018 [92]; HYPXIM from France in 2020 [93]; SHALOM from Italy and Israel in 2021 [94]; and HypSIIRI from USA in ~2022 [95]. These hyperspectral sensors, which have spatial resolutions between ~8–30 m, are expected to provide higher SNRs than current sensors, especially in the SWIR region, and could allow for an operational quantitative SOC mapping at low cost with global coverage. SOC could be estimated using the forthcoming sensors PRISMA, EnMAP, and HypSIIRI with an intermediate accuracy (RMSE about 0.2% and  $R^2$  between ~0.5–0.7), according to the tests performed by Castaldi et al. [96] using simulated data.

## 5. Conclusions

Topsoil organic carbon was estimated using hyperspectral data acquired by an airborne sensor (AHS) and a satellite sensor (Hyperion), which are characterized by different spectral and spatial resolutions. The prediction was performed in burned mountain areas far from the bare soil ideal conditions, because they were slightly covered by heather. Despite the significant difference in the

spectral and spatial resolution of the AHS and Hyperion images, SOC estimations were consistent using both sensors, and the validation results were comparable in terms of  $R^2$  and the RPD to those found in the literature, even to those reported in several studies that focused on agricultural fields or bare soil areas. Slightly worse results were obtained for the Hyperion sensor, and this was attributed to the lower SNR of this sensor.

SOC modeling using simple techniques such as SMLR based on spectral indices showed a performance comparable to the more complex PLSR method, but with several advantages, including the use of a lower number of channels (38/155 channels in PLSR and a maximum of 21 in SMLR) and easier application to the images. As the SOC prediction models were based on the simple SMLR technique and used a relatively low number of indices, they could be transferred easily to other hyperspectral sensors, such as the upcoming satellite hyperspectral sensors with improved SNR. These models might even be transferred to current or future multispectral sensors with bands at relevant wavelengths for SOC prediction. Important wavelengths to estimate SOC were the red region of the spectrum (600–700 nm), as well as the SWIR region between ~2000–2250 nm. The development of spectral indices based on these regions, in combination with the use of simple modeling techniques, might be very useful for increasing the applicability of these SOC mapping methods. Although the operational topsoil mapping using these methods still remains a challenge, the results showed the potential of hyperspectral sensors to estimate SOC.

**Acknowledgments:** This research was supported by the Government of Asturias through the project SV-PA-13-ECOEMP-40. J.P. acknowledges the following Ph.D. Grants: “FPU” from the Spanish Ministry of Education (FPU14/01350), “Severo Ochoa” from the Government of Asturias (BP14-104) and “Predoctoral Grant” from the University of Oviedo. INTA is gratefully acknowledged for the organization of the flight campaign and the geometric and radiometric correction of the AHS image. J.P. also acknowledges the help and technical assistance provided by the INTA team during his short stay for the radiometric correction of the Hyperion image. We thank Cristina Santín for comments about soil C analysis and Carlos Cabo for suggestions about error propagation.

**Author Contributions:** J.P., C.R., S.F. and J.F.C. contributed in the design of the study and performed the field sampling. J.P. designed and submitted the request for the acquisition of the Hyperion data, carried out the statistical analysis, the accuracy assessment and the interpretation of the results. He wrote and edited the paper. C.R. and S.F. supervised the study and assisted in the interpretation of the results. J.F.C. contributed to the critical analysis of the paper. E.D.M. and L.C. provided expertise in processing the imagery and performed the geometric and radiometric correction of the imagery in collaboration with J.P. and C.R. All authors contributed to proofreading and making comments on the manuscript.

**Conflicts of Interest:** The authors declare no conflict of interest.

## References

1. Lal, R. Soil carbon sequestration impacts on global climate change and food security. *Science* **2004**, *304*, 1623–1627. [[CrossRef](#)] [[PubMed](#)]
2. Houghton, R.A. Balancing the global carbon budget. *Annu. Rev. Earth Planet. Sci.* **2007**, *35*, 313–347. [[CrossRef](#)]
3. Smith, P.; Gottschalk, P.; Smith, J. Climate change and soil carbon impacts. In *Soil Carbon: Science, Management and Policy for Multiple Benefits*; Banwart, S.A., Noellemeier, E., Milne, E., Eds.; CABI: London, UK, 2014; pp. 235–242.
4. Lal, R. Challenges and opportunities in soil organic matter research. *Eur. J. Soil Sci.* **2009**, *60*, 158–169. [[CrossRef](#)]
5. Sreenivas, K.; Dadhwal, V.K.; Kumar, S.; Harsha, G.S.; Mitran, T.; Sujatha, G.; Suresh, G.J.R.; Fyzee, M.A.; Ravisankar, T. Digital mapping of soil organic and inorganic carbon status in India. *Geoderma* **2016**, *269*, 160–173. [[CrossRef](#)]
6. Saiano, F.; Oddo, G.; Scalenghe, R.; La Mantia, T.; Ajmone-Marsan, F. DRIFTS sensor: Soil carbon validation at large scale (Pantelleria, Italy). *Sensors* **2013**, *13*, 5603–5613. [[CrossRef](#)] [[PubMed](#)]
7. Minasny, B.; McBratney, A.B.; Malone, B.P.; Wheeler, I. Digital mapping of soil carbon. In *Advances in Agronomy*; Sparks, D.L., Ed.; Elsevier Academic Press Inc.: San Diego, CA, USA, 2013; Volume 118, pp. 1–47.

8. Stevens, A.; Udelhoven, T.; Denis, A.; Tychon, B.; Liou, R.; Hoffmann, L.; van Wesemael, B. Measuring soil organic carbon in croplands at regional scale using airborne imaging spectroscopy. *Geoderma* **2010**, *158*, 32–45. [[CrossRef](#)]
9. Heiri, O.; Lotter, A.F.; Lemcke, G. Loss on ignition as a method for estimating organic and carbonate content in sediments: Reproducibility and comparability of results. *J. Paleolimnol.* **2001**, *25*, 101–110. [[CrossRef](#)]
10. Walkley, A.; Black, I.A. An examination of the Degtjareff method for determining soil organic matter, and a proposed modification of the chromic acid titration method. *Soil Sci.* **1934**, *37*, 29–38. [[CrossRef](#)]
11. Viscarra Rossel, R.A.; Walvoort, D.J.J.; McBratney, A.B.; Janik, L.J.; Skjemstad, J.O. Visible, near infrared, mid infrared or combined diffuse reflectance spectroscopy for simultaneous assessment of various soil properties. *Geoderma* **2006**, *131*, 59–75. [[CrossRef](#)]
12. Martin, P.D.; Malley, D.F.; Manning, G.; Fuller, L. Determination of soil organic carbon and nitrogen at the field level using near-infrared spectroscopy. *Can. J. Soil Sci.* **2002**, *82*, 413–422. [[CrossRef](#)]
13. Reeves, J.B.; McCarty, G.W. Quantitative analysis of agricultural soils using near infrared reflectance spectroscopy and a fibre-optic probe. *J. Near Infrared Spectrosc.* **2001**, *9*, 25–34. [[CrossRef](#)]
14. Mouazen, A.M.; Kuang, B.; De Baerdemaeker, J.; Ramon, H. Comparison among principal component, partial least squares and back propagation neural network analyses for accuracy of measurement of selected soil properties with visible and near infrared spectroscopy. *Geoderma* **2010**, *158*, 23–31. [[CrossRef](#)]
15. Nocita, M.; Kooistra, L.; Bachmann, M.; Mueller, A.; Powell, M.; Weel, S. Predictions of soil surface and topsoil organic carbon content through the use of laboratory and field spectroscopy in the Albany Thicket Biome of Eastern Cape Province of South Africa. *Geoderma* **2011**, *167–168*, 295–302. [[CrossRef](#)]
16. Reeves, J.B.; McCarty, G.W.; Meisinger, J.J. Near infrared reflectance spectroscopy for the analysis of agricultural soils. *J. Near Infrared Spectrosc.* **1999**, *7*, 179–193. [[CrossRef](#)]
17. Madari, B.E.; Reeves, J.B.; Machado, P.L.O.A.; Guimarães, C.M.; Torres, E.; McCarty, G.W. Mid- and near-infrared spectroscopic assessment of soil compositional parameters and structural indices in two Ferralsols. *Geoderma* **2006**, *136*, 245–259. [[CrossRef](#)]
18. Vohland, M.; Besold, J.; Hill, J.; Fründ, H.-C. Comparing different multivariate calibration methods for the determination of soil organic carbon pools with visible to near infrared spectroscopy. *Geoderma* **2011**, *166*, 198–205. [[CrossRef](#)]
19. Ben-Dor, E.; Chabrilat, S.; Dematte, J.A.M.; Taylor, G.R.; Hill, J.; Whiting, M.L.; Sommer, S. Using Imaging Spectroscopy to study soil properties. *Remote Sens. Environ.* **2009**, *113*, S38–S55. [[CrossRef](#)]
20. Croft, H.; Kuhn, N.J.; Anderson, K. On the use of remote sensing techniques for monitoring spatio-temporal soil organic carbon dynamics in agricultural systems. *Catena* **2012**, *94*, 64–74. [[CrossRef](#)]
21. Hbirkou, C.; Paetzold, S.; Mahlein, A.-K.; Welp, G. Airborne hyperspectral imaging of spatial soil organic carbon heterogeneity at the field-scale. *Geoderma* **2012**, *175*, 21–28. [[CrossRef](#)]
22. Selige, T.; Boehner, J.; Schmidhalter, U. High resolution topsoil mapping using hyperspectral image and field data in multivariate regression modeling procedures. *Geoderma* **2006**, *136*, 235–244. [[CrossRef](#)]
23. Schwanghart, W.; Jarmer, T. Linking spatial patterns of soil organic carbon to topography—A case study from south-eastern Spain. *Geomorphology* **2011**, *126*, 252–263. [[CrossRef](#)]
24. Gerighausen, H.; Menz, G.; Kaufmann, H. Spatially explicit estimation of clay and organic carbon content in agricultural soils using multi-annual imaging spectroscopy data. *Appl. Environ. Soil Sci.* **2012**, *2012*, 868090. [[CrossRef](#)]
25. Gomez, C.; Lagacherie, P.; Coulouma, G. Regional predictions of eight common soil properties and their spatial structures from hyperspectral Vis-NIR data. *Geoderma* **2012**, *189*, 176–185. [[CrossRef](#)]
26. Patzold, S.; Mertens, F.M.; Bornemann, L.; Koleczek, B.; Franke, J.; Feilhauer, H.; Welp, G. Soil heterogeneity at the field scale: A challenge for precision crop protection. *Precis. Agric.* **2008**, *9*, 367–390. [[CrossRef](#)]
27. Stevens, A.; Miralles, I.; van Wesemael, B. Soil organic carbon predictions by airborne imaging spectroscopy: Comparing cross-validation and validation. *Soil Sci. Soc. Am. J.* **2012**, *76*, 2174–2183. [[CrossRef](#)]
28. Steinberg, A.; Chabrilat, S.; Stevens, A.; Segl, K.; Foerster, S. Prediction of common surface soil properties based on Vis-NIR airborne and simulated EnMAP imaging spectroscopy data: Prediction accuracy and influence of spatial resolution. *Remote Sens.* **2016**, *8*, 613. [[CrossRef](#)]
29. Denis, A.; Stevens, A.; van Wesemael, B.; Udelhoven, T.; Tychon, B. Soil organic carbon assessment by field and airborne spectrometry in bare croplands: Accounting for soil surface roughness. *Geoderma* **2014**, *226–227*, 94–102. [[CrossRef](#)]

30. Stevens, A.; van Wesemael, B.; Bartholomeus, H.; Rosillon, D.; Tychon, B.; Ben-Dor, E. Laboratory, field and airborne spectroscopy for monitoring organic carbon content in agricultural soils. *Geoderma* **2008**, *144*, 395–404. [[CrossRef](#)]
31. Stevens, A.; van Wesemael, B.; Vandenschrack, G.; Toure, S.; Tychon, B. Detection of carbon stock change in agricultural soils using spectroscopic techniques. *Soil Sci. Soc. Am. J.* **2006**, *70*, 844–850. [[CrossRef](#)]
32. Uno, Y.; Prasher, S.O.; Patel, R.M.; Strachan, I.B.; Pattey, E.; Karimi, Y. Development of field-scale soil organic matter content estimation models in Eastern Canada using airborne hyperspectral imagery. *Can. Biosyst. Eng.* **2005**, *47*, 9–14.
33. DeTar, W.R.; Chesson, J.H.; Penner, J.V.; Ojala, J.C. Detection of soil properties with airborne hyperspectral measurements of bare fields. *Trans. ASABE* **2008**, *51*, 463–470. [[CrossRef](#)]
34. Ben-Dor, E.; Patkin, K.; Banin, A.; Karnieli, A. Mapping of several soil properties using DAIS-7915 hyperspectral scanner data—A case study over clayey soils in Israel. *Int. J. Remote Sens.* **2002**, *23*, 1043–1062. [[CrossRef](#)]
35. Hively, W.D.; McCarty, G.W.; Reeves, J.B.; Lang, M.W.; Oesterling, R.A.; Delwiche, S.R. Use of airborne hyperspectral imagery to map soil properties in tilled agricultural fields. *Appl. Environ. Soil Sci.* **2011**, *2011*, 358193. [[CrossRef](#)]
36. Franceschini, M.H.D.; Demattê, J.A.M.; da Silva Terra, F.; Vicente, L.E.; Bartholomeus, H.; de Souza Filho, C.R. Prediction of soil properties using imaging spectroscopy: Considering fractional vegetation cover to improve accuracy. *Int. J. Appl. Earth Obs.* **2015**, *38*, 358–370. [[CrossRef](#)]
37. Bartholomeus, H.; Kooistra, L.; Stevens, A.; van Leeuwen, M.; van Wesemael, B.; Ben-Dor, E.; Tychon, B. Soil Organic Carbon mapping of partially vegetated agricultural fields with imaging spectroscopy. *Int. J. Appl. Earth Obs.* **2011**, *13*, 81–88. [[CrossRef](#)]
38. Fernández, S.; Peón, J.; Recondo, C.; Calleja, J.F.; Guerrero, C. Spatial modelling of organic carbon in burned mountain soils using hyperspectral images, field datasets, and NIR spectroscopy (Cantabrian Range; NW Spain). *Land Degrad. Dev.* **2016**, *27*, 1479–1488. [[CrossRef](#)]
39. Gomez, C.; Viscarra Rossel, R.A.; McBratney, A.B. Soil organic carbon prediction by hyperspectral remote sensing and field vis-NIR spectroscopy: An Australian case study. *Geoderma* **2008**, *146*, 403–411. [[CrossRef](#)]
40. Lu, P.; Wang, L.; Niu, Z.; Li, L.; Zhang, W. Prediction of soil properties using laboratory VIS-NIR spectroscopy and Hyperion imagery. *J. Geochem. Explor.* **2013**, *132*, 26–33. [[CrossRef](#)]
41. Zhang, T.; Li, L.; Zheng, B. Estimation of agricultural soil properties with imaging and laboratory spectroscopy. *J. Appl. Remote Sens.* **2013**, *7*, 73587. [[CrossRef](#)]
42. Castaldi, F.; Casa, R.; Castrignanò, A.; Pascucci, S.; Palombo, A.; Pignatti, S. Estimation of soil properties at the field scale from satellite data: A comparison between spatial and non-spatial techniques. *Eur. J. Soil Sci.* **2014**, *65*, 842–851. [[CrossRef](#)]
43. Jaber, S.M.; Lant, C.L.; Al-Qinna, M.I. Estimating spatial variations in soil organic carbon using satellite hyperspectral data and map algebra. *Int. J. Remote Sens.* **2011**, *32*, 5077–5103. [[CrossRef](#)]
44. Dalal, R.C.; Henry, R.J. Simultaneous determination of moisture, organic carbon, and total nitrogen by near infrared reflectance spectrophotometry. *Soil Sci. Soc. Am. J.* **1986**, *50*, 120–123. [[CrossRef](#)]
45. Vasques, G.M.; Grunwald, S.; Sickman, J.O. Comparison of multivariate methods for inferential modeling of soil carbon using visible/near-infrared spectra. *Geoderma* **2008**, *146*, 14–25. [[CrossRef](#)]
46. Chang, C.W.; Laird, D.A.; Mausbach, M.J.; Hurburgh, C.R. Near-infrared reflectance spectroscopy-principal components regression analyses of soil properties. *Soil Sci. Soc. Am. J.* **2001**, *65*, 480–490. [[CrossRef](#)]
47. Islam, K.; Singh, B.; McBratney, A. Simultaneous estimation of several soil properties by ultra-violet, visible, and near-infrared reflectance spectroscopy. *Aust. J. Soil Res.* **2003**, *41*, 1101–1114. [[CrossRef](#)]
48. Vasques, G.M.; Grunwald, S.; Sickman, J.O. Modeling of soil organic carbon fractions using visible-near-infrared spectroscopy. *Soil Sci. Soc. Am. J.* **2009**, *73*, 176–184. [[CrossRef](#)]
49. Viscarra Rossel, R.A.; Behrens, T. Using data mining to model and interpret soil diffuse reflectance spectra. *Geoderma* **2010**, *158*, 46–54. [[CrossRef](#)]
50. Li, D.; Chen, X.Z.; Peng, Z.P.; Chen, S.S.; Chen, W.Q.; Han, L.S.; Li, Y.J. Prediction of soil organic matter content in a litchi orchard of South China using spectral indices. *Soil Tillage Res.* **2012**, *123*, 78–86. [[CrossRef](#)]
51. Bartholomeus, H.M.; Schaepman, M.E.; Kooistra, L.; Stevens, A.; Hoogmoed, W.B.; Spaargaren, O.S.P. Spectral reflectance based indices for soil organic carbon quantification. *Geoderma* **2008**, *145*, 28–36. [[CrossRef](#)]

52. FAO. *World Reference Base for Soil Resources 2014*; World Soil Resources Report 106; Food and Agriculture Organization: Rome, Italy, 2014.
53. Álvarez, M.A.; Marquínez, J. *Impacto de los Incendios Forestales en Asturias. Análisis de los Últimos 30 años*; KRK Ediciones: Oviedo, Spain, 2007.
54. Fernández, S.; Marquínez, J.; Duarte, R.M. A susceptibility model for post wildfire soil erosion in a temperate oceanic mountain area of Spain. *Catena* **2005**, *61*, 256–272. [[CrossRef](#)]
55. Díaz, T.E.; Fernández, J.A. El paisaje vegetal de Asturias: Guía de la excursión. *Itinera Geobot.* **1994**, *8*, 5–242.
56. Recondo, C.; Wozniak, E.; Pérez-Morandeira, C.S. Map of Burnt Zones in Asturias in the Period 1991–2001 created from Landsat-TM Images. In Proceedings of the 4th Workshop on Remote Sensing and GIS Applications to Forest Fires Management, Ghent, Belgium, 5–7 June 2003; Chuvieco, E., Martín, P., Justice, C., Eds.; 2003; pp. 193–196.
57. Schlapfer, D.; Richter, R. Geo-atmospheric processing of airborne imaging spectrometry data. Part 1: Parametric orthorectification. *Int. J. Remote Sens.* **2002**, *23*, 2609–2630. [[CrossRef](#)]
58. Richter, R.; Schlapfer, D. Geo-atmospheric processing of airborne imaging spectrometry data. Part 2: Atmospheric/topographic correction. *Int. J. Remote Sens.* **2002**, *23*, 2631–2649. [[CrossRef](#)]
59. Richards, J.A. *Remote Sensing Digital Image Analysis*, 5th ed.; Springer: Berlin, Germany, 2013; p. 494.
60. Pearlman, J.S.; Barry, P.S.; Segal, C.C.; Shepanski, J.; Beiso, D.; Carman, S.L. Hyperion, a space-based imaging spectrometer. *IEEE Trans. Geosci. Remote Sens.* **2003**, *41*, 1160–1173. [[CrossRef](#)]
61. Datt, B.; McVicar, T.R.; Van Niel, T.G.; Jupp, D.L.B.; Pearlman, J.S. Preprocessing EO-1 Hyperion hyperspectral data to support the application of agricultural indexes. *IEEE Trans. Geosci. Remote Sens.* **2003**, *41*, 1246–1259. [[CrossRef](#)]
62. Jackson, R.D.; Huete, A.R. Interpreting vegetation indices. *Prev. Vet. Med.* **1991**, *11*, 185–200. [[CrossRef](#)]
63. Rouse, J.W.; Haas, R.H.; Schell, J.A.; Deering, D.W. Monitoring Vegetation Systems in the Great Plains with ERTS. In Proceedings of the 3rd Earth Resource Technology Satellite (ERTS) Symposium, Washington, DC, USA, 10–14 December 1973; pp. 309–317.
64. Ben-Dor, E.; Inbar, Y.; Chen, Y. The reflectance spectra of organic matter in the visible near-infrared and short wave infrared region (400–2500 nm) during a controlled decomposition process. *Remote Sens. Environ.* **1997**, *61*, 1–15. [[CrossRef](#)]
65. Beyer, L.; Kahle, P.; Kretschmer, H.; Wu, Q. Soil organic matter composition of man-impacted urban sites in North Germany. *J. Plant Nutr. Soil Sci.* **2001**, *164*, 359–364. [[CrossRef](#)]
66. Yu, X.; Liu, Q.; Wang, Y.B.; Liu, X.Y.; Liu, X. Evaluation of MLSP and PLSR for estimating soil element contents using visible/near-infrared spectroscopy in apple orchards on the Jiaodong peninsula. *Catena* **2016**, *137*, 340–349. [[CrossRef](#)]
67. Venables, W.N.; Ripley, B.D. *Modern Applied Statistics with S*, 4th ed.; Springer: New York, NY, USA, 2002.
68. Wold, S.; Sjöström, M.; Eriksson, L. PLS-regression: A basic tool of chemometrics. *Chemom. Intell. Lab.* **2001**, *58*, 109–130. [[CrossRef](#)]
69. Haaland, D.M.; Thomas, E.V. Partial least-squares methods for spectral analyses. 1. Relation to other quantitative calibration methods and the extraction of qualitative information. *Anal. Chem.* **1988**, *60*, 1193–1202. [[CrossRef](#)]
70. Akaike, H. Fitting autoregressive models for prediction. *Ann. Inst. Stat. Math.* **1969**, *21*, 243–247. [[CrossRef](#)]
71. Li, B.; Morris, J.; Martin, E.B. Model selection for partial least squares regression. *Chemom. Intell. Lab.* **2002**, *64*, 79–89. [[CrossRef](#)]
72. Viscarra Rossel, R.A.; Jeon, Y.S.; Odeh, I.O.A.; McBratney, A.B. Using a legacy soil sample to develop a mid-IR spectral library. *Soil Res.* **2008**, *46*, 1–16. [[CrossRef](#)]
73. Chong, I.G.; Jun, C.H. Performance of some variable selection methods when multicollinearity is present. *Chemom. Intell. Lab.* **2005**, *78*, 103–112. [[CrossRef](#)]
74. Chang, C.W.; Laird, D.A. Near-infrared reflectance spectroscopic analysis of soil C and N. *Soil Sci.* **2002**, *167*, 110–116. [[CrossRef](#)]
75. Hammersley, J.M.; Handscomb, D.C. *Monte Carlo Methods*; Chapman and Hall: London, UK, 1979.
76. Metropolis, N.; Ulam, S. The Monte Carlo method. *J. Am. Stat. Assoc.* **1949**, *44*, 335–341. [[CrossRef](#)] [[PubMed](#)]
77. Shapiro, S.S.; Wilk, M.B. An analysis of variance test for normality (complete samples). *Biometrika* **1965**, *52*, 591–611. [[CrossRef](#)]

78. Santín, C.; Knicker, H.; Fernández, S.; Menéndez-Duarte, R.; Álvarez, M.A. Wildfires influence on soil organic matter in an Atlantic mountainous region (NW of Spain). *Catena* **2008**, *74*, 286–295. [[CrossRef](#)]
79. Menéndez Duarte, R.; Wozniak, E.; Recondo, C.; Cabo, C.; Marquínez, J.; Fernández, S. Estimation of surface roughness and stone cover in burnt soils using SAR images. *Catena* **2008**, *74*, 264–272. [[CrossRef](#)]
80. Stoner, E.R.; Baumgardner, M.F. Characteristic variations in reflectance of surface soils. *Soil Sci. Soc. Am. J.* **1981**, *45*, 1161–1165. [[CrossRef](#)]
81. Schulze, D.G.; Nagel, J.L.; Van Scoyoc, G.E.; Henderson, T.L.; Baumgardner, M.F.; Scott, D.E. Significance of organic matter in determining soil colors. In *Soil Color*; Bigham, J.M., Ciolkosz, E.J., Eds.; Soil Science Society of America: Madison, WI, USA, 1993; pp. 71–90.
82. Vinogradov, B.V. Remote sensing of the humus content of soils. *Sov. Soil Sci.* **1981**, *11*, 114–123.
83. Hummel, J.W.; Sudduth, K.A.; Hollinger, S.E. Soil moisture and organic matter prediction of surface and subsurface soils using an NIR soil sensor. *Comput. Electron. Agric.* **2001**, *32*, 149–165. [[CrossRef](#)]
84. Henderson, T.L.; Baumgardner, M.F.; Franzmeier, D.P.; Stott, D.E.; Coster, D.C. High dimensional reflectance analysis of soil organic matter. *Soil Sci. Soc. Am. J.* **1992**, *56*, 865–872. [[CrossRef](#)]
85. Gitelson, A.A.; Merzlyak, M.N.; Lichtenthaler, H.K. Detection of red edge position and chlorophyll content by reflectance measurements near 700 nm. *J. Plant Physiol.* **1996**, *148*, 501–508. [[CrossRef](#)]
86. Huang, A.; Li, G.; Fu, F.; Fei, B. Use of visible and near infrared spectroscopy to predict klason lignin content of bamboo, Chinese fir, Paulownia, and Poplar. *J. Wood Chem. Technol.* **2008**, *28*, 194–206. [[CrossRef](#)]
87. Kooistra, L.; Wanders, J.; Epema, G.F.; Leuven, R.S.E.W.; Wehrens, R.; Buydens, L.M.C. The potential of field spectroscopy for the assessment of sediment properties in river floodplains. *Anal. Chim. Acta* **2003**, *484*, 189–200. [[CrossRef](#)]
88. De Gryze, S.; Six, J.; Bossuyt, H.; Van Oost, K.; Merckx, R. The relationship between landform and the distribution of soil C, N and P under conventional and minimum tillage. *Geoderma* **2008**, *144*, 180–188. [[CrossRef](#)]
89. Gomez, C.; Gholizadeh, A.; Borůvka, L.; Lagacherie, P. Using legacy data for correction of soil surface clay content predicted from VNIR/SWIR hyperspectral airborne images. *Geoderma* **2016**, *276*, 84–92. [[CrossRef](#)]
90. Tanii, J.; Ito, Y.; Iwasaki, A. Instrument development status and performances of hyperspectral imager suite (HISUI)—Onboard data correction. In Proceedings of the 2014 IEEE Geoscience and Remote Sensing Symposium, Quebec City, QC, Canada, 13–18 July 2014; pp. 2007–2010.
91. Meini, M.; Fossati, E.; Giunti, L.; Molina, M.; Formaro, R.; Longo, F.; Varacalli, G. The PRISMA mission hyperspectral payload. In Proceedings of the 66th International Astronautical Congress (IAC 2015), Jerusalem, Israel, 12–16 October 2015; p. 30270.
92. Guanter, L.; Kaufmann, H.; Segl, K.; Foerster, S.; Rogass, C.; Chabrillat, S.; Kuester, T.; Hollstein, A.; Rossner, G.; Chlebek, C.; et al. The EnMAP spaceborne imaging spectroscopy mission for Earth observation. *Remote Sens.* **2015**, *7*, 8830–8857. [[CrossRef](#)]
93. Michel, S.; Gamet, P.; Lefevre-Fonollosa, M.J. HYPXIM—A hyperspectral satellite defined for science, security and defence users. In Proceedings of the 3rd Workshop on Hyperspectral Image and Signal Processing: Evolution in Remote Sensing (WHISPERS), Lisbon, Portugal, 6–9 June 2011; pp. 1–4.
94. Sagi, E. SHALOM—Spaceborne Hyperspectral Applciative Land and Ocean Mission. In Proceedings of the 66th International Astronautical Congress (IAC 2015), Jerusalem, Israel, 12–16 October 2015; p. 31056.
95. Lee, C.M.; Cable, M.L.; Hook, S.J.; Green, R.O.; Ustin, S.L.; Mandl, D.J.; Middleton, E.M. An introduction to the NASA Hyperspectral InfraRed Imager (HyspIRI) mission and preparatory activities. *Remote Sens. Environ.* **2015**, *167*, 6–19. [[CrossRef](#)]
96. Castaldi, F.; Palombo, A.; Santini, F.; Pascucci, S.; Pignatti, S.; Casa, R. Evaluation of the potential of the current and forthcoming multispectral and hyperspectral imagers to estimate soil texture and organic carbon. *Remote Sens. Environ.* **2016**, *179*, 54–65. [[CrossRef](#)]



© 2017 by the authors. Licensee MDPI, Basel, Switzerland. This article is an open access article distributed under the terms and conditions of the Creative Commons Attribution (CC BY) license (<http://creativecommons.org/licenses/by/4.0/>).

## Factor de impacto de las publicaciones

En esta sección se incluye el factor de impacto de las publicaciones presentadas en la tesis. Los datos han sido extraídos de la edición *Science Citation Index Expanded* (SCIE) de la base de datos *InCites Journal Citation Reports* (JCR) de Clarivate Analytics. Se incluye también el número de citas de las publicaciones en la base de datos *Web of Science - Core Collection* (WOS-CC) de Clarivate Analytics y en *Scopus* de Elsevier.

### Publicación 1

AUTORES (p.o. de firma): **Peón, J.**, Fernández, S., Recondo, C. y Calleja, J.F.

TÍTULO: Evaluation of the spectral characteristics of five hyperspectral and multispectral sensors for soil organic carbon estimation in burned areas.

NOMBRE DE LA REVISTA: International Journal of Wildland Fire

Volumen: 26

Páginas: 230-239

Editorial: CSIRO PUBLISHING

País de publicación: Australia

Año de publicación: 2017

ISSN: 1049-8001

DOI: 10.1071/WF16122

Datos del JCR para el año 2017:

- Índice de impacto (Journal Impact Factor, JIF): **2.445**
- Categoría: FORESTRY - SCIE
  - Ranking: 11/66
  - Cuartil: Q1
  - Percentil JIF: 84.091

Número de citas (fecha de consulta: 12 de abril de 2019): **5** (WOS-CC) / **6** (Scopus)

- 2 en Remote Sensing of Environment (Gholizadeh *et al.* 2018b; Wang *et al.* 2018)
- 1 en Remote Sensing (Guo *et al.* 2018)
- 1 en Chinese Geographical Science (Guo *et al.* 2019)
- 1 en Proceedings of SPIE (Society of Photographic Instrumentation Engineers) - The International Society for Optical Engineering (Gholizadeh *et al.* 2018a)
- 1 en Acta Optica Sinica (Zhang *et al.* 2019)

## Publicación 2

AUTORES (p.o. de firma): Fernández, S., **Peón, J.**, Recondo, C., Calleja, J.F. y Guerrero, C.

TÍTULO: Spatial modelling of organic carbon in burned mountain soils using hyperspectral images, field datasets, and NIR spectroscopy (Cantabrian Range; NW Spain).

NOMBRE DE LA REVISTA: Land Degradation & Development

Volumen: 27

Páginas: 1479-1488

Editorial: Wiley

País de publicación: Inglaterra

Año de publicación: 2016

ISSN: 1085-3278

DOI: 10.1002/ldr.2452

Datos del JCR para el año 2016:

- Índice de impacto (Journal Impact Factor, JIF): **9.787**
- Categoría 1: ENVIRONMENTAL SCIENCES - SCIE
  - Ranking: 3/229
  - Cuartil: Q1
  - Percentil JIF: 98.908
- Categoría 2: SOIL SCIENCE - SCIE
  - Ranking: 1/34
  - Cuartil: Q1
  - Percentil JIF: 98.529

Número de citas (fecha de consulta: 12 de abril de 2019): **6** (WOS-CC) / **6** (Scopus)

- 1 en Land Degradation and Development (Martínez-Murillo *et al.* 2016)
- 1 en Remote Sensing (Peón *et al.* 2017b)
- 1 en Geoderma (Fernández *et al.* 2018)
- 1 en International Journal of Wildland Fire (Peón *et al.* 2017a)
- 1 en Land Use Policy (Theesfeld y Jelinek 2017)
- 1 en Archives of Agronomy and Soil Science (Yu *et al.* 2018)



### Publicación 3

AUTORES (p.o. de firma): **Peón, J.**, Recondo, C., Fernández, S., Calleja, J.F., De Miguel, E. y Carretero, L.

TÍTULO: Prediction of topsoil organic carbon using airborne and satellite hyperspectral imagery.

NOMBRE DE LA REVISTA: Remote Sensing

Volumen: 9

Páginas: 1211 (1-22)

Editorial: MDPI

País de publicación: Suiza

Año de publicación: 2017

ISSN: 2072-4292

DOI: 10.3390/rs9121211

Datos del JCR para el año 2017:

- Índice de impacto (Journal Impact Factor, JIF): **3.406**
- Categoría: REMOTE SENSING - SCIE
  - Ranking: 8/30
  - Cuartil: Q2
  - Percentil JIF: 75.000

Número de citas (fecha de consulta: 12 de abril de 2019): **6** más 2 pendientes de incluir (WOS-CC) / **7** más 2 pendientes de incluir (Scopus)

- 3 en Remote Sensing (Hong *et al.* 2018b; Angelopoulou *et al.* 2019; Peng *et al.* 2019)
- 2 en Science of the Total Environment (Hong *et al.* 2018a; Tao *et al.* 2019)
- 1 en International Journal of Applied Earth Observation and Geoinformation (Milewski *et al.* 2019)
- 1 en Geoderma (Ogen *et al.* 2018)
- 1 en Sensors (Liu *et al.* 2018)
- 1 en Journal of Central European Agriculture (Šestak *et al.* 2019)



## Bibliografía

- Akaike, H. (1969) Fitting autoregressive models for prediction. *Annals of the Institute of Statistical Mathematics* **21**, 243-247. DOI:10.1007/bf02532251
- Alexis, M.A., Rasse, D.P., Rumpel, C., Bardoux, G., Péchot, N., Schmalzer, P., Drake, B. y Mariotti, A. (2007) Fire impact on C and N losses and charcoal production in a scrub oak ecosystem. *Biogeochemistry* **82**, 201-216. DOI:10.1007/s10533-006-9063-1
- Álvarez, M.A. y Marquínez, J. (Eds) (2007) 'Impacto de los incendios forestales en Asturias. Análisis de los últimos 30 años.' (KRK Ediciones: Oviedo)
- Andela, N., Morton, D.C., Giglio, L., Chen, Y., van der Werf, G.R., Kasibhatla, P.S., DeFries, R.S., Collatz, G.J., Hantson, S., Kloster, S., Bachelet, D., Forrest, M., Lasslop, G., Li, F., Mangeon, S., Melton, J.R., Yue, C. y Randerson, J.T. (2017) A human-driven decline in global burned area. *Science* **356**, 1356. DOI:10.1126/science.aal4108
- Angelopoulou, T., Tziolas, N., Balafoutis, A., Zalidis, G. y Bochtis, D. (2019) Remote sensing techniques for soil organic carbon estimation: a review. *Remote Sensing* **11**, 676. DOI:10.3390/rs11060676
- Badía, D., Martí, C., Aguirre, A.J., Aznar, J.M., González-Pérez, J.A., De la Rosa, J.M., León, J., Ibarra, P. y Echeverría, T. (2014) Wildfire effects on nutrients and organic carbon of a Rendzic Phaeozem in NE Spain: Changes at cm-scale topsoil. *Catena* **113**, 267-275. DOI:10.1016/j.catena.2013.08.002
- Bartholomeus, H., Kooistra, L., Stevens, A., van Leeuwen, M., van Wesemael, B., Ben-Dor, E. y Tychon, B. (2011) Soil Organic Carbon mapping of partially vegetated agricultural fields with imaging spectroscopy. *International Journal of Applied Earth Observation and Geoinformation* **13**, 81-88. DOI:10.1016/j.jag.2010.06.009
- Bartholomeus, H.M., Schaepman, M.E., Kooistra, L., Stevens, A., Hoogmoed, W.B. y Spaargaren, O.S.P. (2008) Spectral reflectance based indices for soil organic carbon quantification. *Geoderma* **145**, 28-36. DOI:10.1016/j.geoderma.2008.01.010
- Batjes, N.H. (1996) Total carbon and nitrogen in the soils of the world. *European Journal of Soil Science* **47**, 151-163. DOI:10.1111/j.1365-2389.1996.tb01386.x
- Batjes, N.H. (2016) Harmonized soil property values for broad-scale modelling (WISE30sec) with estimates of global soil carbon stocks. *Geoderma* **269**, 61-68. DOI:10.1016/j.geoderma.2016.01.034

- Bellon-Maurel, V. y McBratney, A. (2011) Near-infrared (NIR) and mid-infrared (MIR) spectroscopic techniques for assessing the amount of carbon stock in soils - Critical review and research perspectives. *Soil Biology & Biochemistry* **43**, 1398-1410. DOI:10.1016/j.soilbio.2011.02.019
- Ben-Dor, E., Chabrillat, S., Dematte, J.A.M., Taylor, G.R., Hill, J., Whiting, M.L. y Sommer, S. (2009) Using imaging spectroscopy to study soil properties. *Remote Sensing of Environment* **113**, S38-S55. DOI:10.1016/j.rse.2008.09.019
- Ben-Dor, E., Inbar, Y. y Chen, Y. (1997) The reflectance spectra of organic matter in the visible near-infrared and short wave infrared region (400-2500 nm) during a controlled decomposition process. *Remote Sensing of Environment* **61**, 1-15. DOI:10.1016/s0034-4257(96)00120-4
- Ben-Dor, E., Patkin, K., Banin, A. y Karnieli, A. (2002) Mapping of several soil properties using DAIS-7915 hyperspectral scanner data - a case study over clayey soils in Israel. *International Journal of Remote Sensing* **23**, 1043-1062. DOI:10.1080/01431160010006962
- Beyer, L., Kahle, P., Kretschmer, H. y Wu, Q. (2001) Soil organic matter composition of man-impacted urban sites in North Germany. *Journal of Plant Nutrition and Soil Science* **164**, 359-364. DOI:10.1002/1522-2624(200108)164:4<359::AID-JPLN359>3.0.CO;2-M
- Brevik, E.C., Cerdà, A., Mataix-Solera, J., Pereg, L., Quinton, J.N., Six, J. y Van Oost, K. (2015) The interdisciplinary nature of SOIL. *SOIL* **1**, 117-129. DOI:10.5194/soil-1-117-2015
- Burras, L., Cheng, H.H., Kimble, J.M., Kissel, D.E., Lal, R., Luxmoore, R.J., Mausbach, M.J., Rice, C.W., Uehara, G. y Wilding, L.D., 2001. Carbon Sequestration: Position of the Soil Science Society of America. SSSA, Madison, Wisconsin.
- Canfield, H.E., Wilson, C.J., Lane, L.J., Crowell, K.J. y Thomas, W.A. (2005) Modeling scour and deposition in ephemeral channels after wildfire. *Catena* **61**, 273-291. DOI:10.1016/j.catena.2005.03.013
- Castaldi, F., Casa, R., Castrignanò, A., Pascucci, S., Palombo, A. y Pignatti, S. (2014) Estimation of soil properties at the field scale from satellite data: a comparison between spatial and non-spatial techniques. *European Journal of Soil Science* **65**, 842-851. DOI:10.1111/ejss.12202
- Castaldi, F., Palombo, A., Santini, F., Pascucci, S., Pignatti, S. y Casa, R. (2016) Evaluation of the potential of the current and forthcoming multispectral and hyperspectral imagers to estimate soil texture and organic carbon. *Remote Sensing of Environment* **179**, 54-65. DOI:10.1016/j.rse.2016.03.025
- Certini, G. (2005) Effects of fire on properties of forest soils: a review. *Oecologia* **143**, 1-10. DOI:10.1007/s00442-004-1788-8

- Chang, C.W. y Laird, D.A. (2002) Near-infrared reflectance spectroscopic analysis of soil C and N. *Soil Science* **167**, 110-116. DOI:10.1097/00010694-200202000-00003
- Chang, C.W., Laird, D.A., Mausbach, M.J. y Hurburgh, C.R. (2001) Near-infrared reflectance spectroscopy-principal components regression analyses of soil properties. *Soil Science Society of America Journal* **65**, 480-490. DOI:10.2136/sssaj2001.652480x
- Chong, I.G. y Jun, C.H. (2005) Performance of some variable selection methods when multicollinearity is present. *Chemometrics and Intelligent Laboratory Systems* **78**, 103-112. DOI:10.1016/j.chemolab.2004.12.011
- Cozzolino, D. y Morón, A. (2006) Potential of near-infrared reflectance spectroscopy and chemometrics to predict soil organic carbon fractions. *Soil and Tillage Research* **85**, 78-85. DOI:10.1016/j.still.2004.12.006
- Croft, H., Kuhn, N.J. y Anderson, K. (2012) On the use of remote sensing techniques for monitoring spatio-temporal soil organic carbon dynamics in agricultural systems. *Catena* **94**, 64-74. DOI:10.1016/j.catena.2012.01.001
- Dalal, R.C. y Henry, R.J. (1986) Simultaneous determination of moisture, organic carbon, and total nitrogen by near infrared reflectance spectrophotometry. *Soil Science Society of America Journal* **50**, 120-123. DOI:10.2136/sssaj1986.03615995005000010023x
- Datt, B., McVicar, T.R., Van Niel, T.G., Jupp, D.L.B. y Pearlman, J.S. (2003) Preprocessing EO-1 Hyperion hyperspectral data to support the application of agricultural indexes. *IEEE Transactions on Geoscience and Remote Sensing* **41**, 1246-1259. DOI:10.1109/TGRS.2003.813206
- De Gryze, S., Six, J., Bossuyt, H., Van Oost, K. y Merckx, R. (2008) The relationship between landform and the distribution of soil C, N and P under conventional and minimum tillage. *Geoderma* **144**, 180-188. DOI:10.1016/j.geoderma.2007.11.013
- De la Rosa, J.M., Faria, S.R., Varela, M.E., Knicker, H., González-Vila, F.J., González-Pérez, J.A. y Keizer, J. (2012) Characterization of wildfire effects on soil organic matter using analytical pyrolysis. *Geoderma* **191**, 24-30. DOI:10.1016/j.geoderma.2012.01.032
- Denis, A., Stevens, A., van Wesemael, B., Udelhoven, T. y Tychon, B. (2014) Soil organic carbon assessment by field and airborne spectrometry in bare croplands: Accounting for soil surface roughness. *Geoderma* **226-227**, 94-102. DOI:10.1016/j.geoderma.2014.02.015
- DeTar, W.R., Chesson, J.H., Penner, J.V. y Ojala, J.C. (2008) Detection of soil properties with airborne hyperspectral measurements of bare fields. *Transactions of the ASABE* **51**, 463-470. DOI:10.13031/2013.24388

- Díaz González, T.E. y Fernández, J.A. (1994) El paisaje vegetal de Asturias: Guía de la excursión. *Itinera Geobotanica* **8**, 5-242.
- Ellert, B.H., Janzen, H.H. y McConkey, B.G. (2001) Measuring and comparing soil carbon storage. En 'Soil processes and the carbon cycle.' (Eds R. Lal, J.M. Kimble, R.F. Follett y B.A. Stewart.) pp. 131-146 (CRC Press: Boca Raton, Florida)
- FAO (2014) 'World reference base for soil resources 2014. World Soil Resources Report 106.' (Food and Agriculture Organization: Rome)
- Fernández-Menéndez, S., Santín, C., Cabo, C., Menéndez, R.A. y Álvarez, M.A. C. Recondo y E. Pendás (Eds) (2011) 'Incendios forestales y transferencia de carbono biomasa-suelo en áreas montañosas de clima atlántico, XIV Congreso de la Asociación Española de Teledetección (AET): Bosques y cambio climático.' Mieres (Asturias).
- Fernández, I., Cabaneiro, A. y Carballas, T. (1999) Carbon mineralization dynamics in soils after wildfires in two Galician forests. *Soil Biology and Biochemistry* **31**, 1853-1865. DOI:10.1016/S0038-0717(99)00116-9
- Fernández, S., Cotos-Yáñez, T., Roca-Pardiñas, J. y Ordóñez, C. (2018) Geographically weighted principal components analysis to assess diffuse pollution sources of soil heavy metal: application to rough mountain areas in Northwest Spain. *Geoderma* **311**, 120-129. DOI:10.1016/j.geoderma.2016.10.012
- Fernández, S., Marquínez, J. y Duarte, R.M. (2005) A susceptibility model for post wildfire soil erosion in a temperate oceanic mountain area of Spain. *Catena* **61**, 256-272. DOI:10.1016/j.catena.2005.03.006
- Fernández, S., Peón, J., Recondo, C., Calleja, J.F. y Guerrero, C. (2016) Spatial modelling of organic carbon in burned mountain soils using hyperspectral images, field datasets, and NIR spectroscopy (Cantabrian Range; NW Spain). *Land Degradation & Development* **27**, 1479-1488. DOI:10.1002/ldr.2452
- Franceschini, M.H.D., Demattê, J.A.M., da Silva Terra, F., Vicente, L.E., Bartholomeus, H. y de Souza Filho, C.R. (2015) Prediction of soil properties using imaging spectroscopy: Considering fractional vegetation cover to improve accuracy. *International Journal of Applied Earth Observation and Geoinformation* **38**, 358-370. DOI:10.1016/j.jag.2015.01.019
- Francos, M., Úbeda, X., Pereira, P. y Alcañiz, M. (2018) Long-term impact of wildfire on soils exposed to different fire severities. A case study in Cadiretes Massif (NE Iberian Peninsula). *Science of the Total Environment* **615**, 664-671. DOI:10.1016/j.scitotenv.2017.09.311

- Gehl, R.J. y Rice, C.W. (2007) Emerging technologies for in situ measurement of soil carbon. *Climatic Change* **80**, 43-54. DOI:10.1007/s10584-006-9150-2
- Geladi, P. (2003) Chemometrics in spectroscopy. Part 1. Classical chemometrics. *Spectrochimica Acta Part B: Atomic Spectroscopy* **58**, 767-782. DOI:10.1016/S0584-8547(03)00037-5
- Gerighausen, H., Menz, G. y Kaufmann, H. (2012) Spatially explicit estimation of clay and organic carbon content in agricultural soils using multi-annual imaging spectroscopy data. *Applied and Environmental Soil Science* **2012**, 868090. DOI:10.1155/2012/868090
- Gholizadeh, A., Zizala, D., Saberioon, M. y Boruvka, L. (2018a) 'Soil organic carbon content monitoring and mapping using airborne and Sentinel-2 spectral imaging, Sixth International Conference on Remote Sensing and Geoinformation of the Environment (RSCy2018).' (SPIE: Cyprus)
- Gholizadeh, A., Žižala, D., Saberioon, M. y Borůvka, L. (2018b) Soil organic carbon and texture retrieving and mapping using proximal, airborne and Sentinel-2 spectral imaging. *Remote Sensing of Environment* **218**, 89-103. DOI:10.1016/j.rse.2018.09.015
- Gitelson, A.A., Merzlyak, M.N. y Lichtenthaler, H.K. (1996) Detection of red edge position and chlorophyll content by reflectance measurements near 700 nm. *Journal of Plant Physiology* **148**, 501-508. DOI:10.1016/S0176-1617(96)80285-9
- Gomez, C., Gholizadeh, A., Borůvka, L. y Lagacherie, P. (2016) Using legacy data for correction of soil surface clay content predicted from VNIR/SWIR hyperspectral airborne images. *Geoderma* **276**, 84-92. DOI:10.1016/j.geoderma.2016.04.019
- Gomez, C., Lagacherie, P. y Coulouma, G. (2012) Regional predictions of eight common soil properties and their spatial structures from hyperspectral Vis-NIR data. *Geoderma* **189**, 176-185. DOI:10.1016/j.geoderma.2012.05.023
- Gomez, C., Ultra-Carrió, R., Bacha, S., Lagacherie, P. y Briottet, X. (2015) Evaluating the sensitivity of clay content prediction to atmospheric effects and degradation of image spatial resolution using Hyperspectral VNIR/SWIR imagery. *Remote Sensing of Environment* **164**, 1-15. DOI:10.1016/j.rse.2015.02.019
- Gomez, C., Viscarra Rossel, R.A. y McBratney, A.B. (2008) Soil organic carbon prediction by hyperspectral remote sensing and field vis-NIR spectroscopy: An Australian case study. *Geoderma* **146**, 403-411. DOI:10.1016/j.geoderma.2008.06.011
- González-Pérez, J.A., González-Vila, F.J., Almendros, G. y Knicker, H. (2004) The effect of fire on soil organic matter - a review. *Environment International* **30**, 855-870. DOI:10.1016/j.envint.2004.02.003

- Griffiths, P.R. y Dahm, D.J. (2007) Continuum and Discontinuum Theories of Diffuse Reflection. En 'Handbook of Near-Infrared Analysis, Third Edition.' (Eds D.A. Burns y E.W. Ciurczak.) pp. 21-64 (CRC Press: Boca Raton, Florida)
- Guanter, L., Kaufmann, H., Segl, K., Foerster, S., Rogass, C., Chabrillat, S., Kuester, T., Hollstein, A., Rossner, G., Chlebek, C., Straif, C., Fischer, S., Schrader, S., Storch, T., Heiden, U., Mueller, A., Bachmann, M., Muhle, H., Muller, R., Habermeyer, M., Ohndorf, A., Hill, J., Buddenbaum, H., Hostert, P., van der Linden, S., Leitao, P.J., Rabe, A., Doerffer, R., Krasemann, H., Xi, H.Y., Mauser, W., Hank, T., Locherer, M., Rast, M., Staenz, K. y Sang, B. (2015) The EnMAP spaceborne imaging spectroscopy mission for Earth observation. *Remote Sensing* **7**, 8830-8857. DOI:10.3390/rs70708830
- Guénon, R., Vennetier, M., Dupuy, N., Roussos, S., Pailler, A. y Gros, R. (2013) Trends in recovery of Mediterranean soil chemical properties and microbial activities after infrequent and frequent wildfires. *Land Degradation & Development* **24**, 115-128. DOI:10.1002/ldr.1109
- Guerrero, C., Mataix-Solera, J., Arcenegui, V., Mataix-Beneyto, J. y Gomez, I. (2007) Near-infrared spectroscopy to estimate the maximum temperatures reached on burned soils. *Soil Science Society of America Journal* **71**, 1029-1037. DOI:10.2136/sssaj2006.0187
- Guo, L., Linderman, M., Shi, T., Chen, Y., Duan, L. y Zhang, H. (2018) Exploring the sensitivity of sampling density in digital mapping of soil organic carbon and its application in soil sampling. *Remote Sensing* **10**, 888. DOI:10.3390/rs10060888
- Guo, L., Zhang, H., Chen, Y. y Qian, J. (2019) Combining environmental factors and lab VNIR spectral data to predict SOM by geospatial techniques. *Chinese Geographical Science* **29**, 258-269. DOI:10.1007/s11769-019-1020-8
- Haaland, D.M. y Thomas, E.V. (1988) Partial least-squares methods for spectral analyses. 1. Relation to other quantitative calibration methods and the extraction of qualitative information. *Analytical Chemistry* **60**, 1193-1202. DOI:10.1021/ac00162a020
- Hammersley, J.M. y Handscomb, D.C. (1979) 'Monte Carlo methods.' (Chapman and Hall: London)
- Hatcher, P.G. y Spiker, E.C. F.H. Frimmel, R.F. Christman y J.M. Bracewell (Eds) (1988) 'Selective degradation of plant biomolecules, Dahlem Workshop on Humic Substances and Their Role in the Environment.' (Wiley: New York)
- Hbirkou, C., Paetzold, S., Mahlein, A.-K. y Welp, G. (2012) Airborne hyperspectral imaging of spatial soil organic carbon heterogeneity at the field-scale. *Geoderma* **175**, 21-28. DOI:10.1016/j.geoderma.2012.01.017



- Heiri, O., Lotter, A.F. y Lemcke, G. (2001) Loss on ignition as a method for estimating organic and carbonate content in sediments: Reproducibility and comparability of results. *Journal of Paleolimnology* **25**, 101-110. DOI:10.1023/A:1008119611481
- Henderson, T.L., Baumgardner, M.F., Franzmeier, D.P., Stott, D.E. y Coster, D.C. (1992) High dimensional reflectance analysis of soil organic matter. *Soil Science Society of America Journal* **56**, 865-872.
- Hengl, T., Mendes de Jesus, J., Heuvelink, G.B.M., Ruiperez Gonzalez, M., Kilibarda, M., Blagotić, A., Shangquan, W., Wright, M.N., Geng, X., Bauer-Marschallinger, B., Guevara, M.A., Vargas, R., MacMillan, R.A., Batjes, N.H., Leenaars, J.G.B., Ribeiro, E., Wheeler, I., Mantel, S. y Kempen, B. (2017) SoilGrids250m: Global gridded soil information based on machine learning. *PLoS One* **12**, e0169748. DOI:10.1371/journal.pone.0169748
- Hively, W.D., McCarty, G.W., Reeves, J.B., Lang, M.W., Oesterling, R.A. y Delwiche, S.R. (2011) Use of airborne hyperspectral imagery to map soil properties in tilled agricultural fields. *Applied and Environmental Soil Science* **2011**, 13. DOI:10.1155/2011/358193
- Hong, Y., Chen, S., Zhang, Y., Chen, Y., Yu, L., Liu, Y., Liu, Y., Cheng, H. y Liu, Y. (2018a) Rapid identification of soil organic matter level via visible and near-infrared spectroscopy: Effects of two-dimensional correlation coefficient and extreme learning machine. *Science of the Total Environment* **644**, 1232-1243. DOI:10.1016/j.scitotenv.2018.06.319
- Hong, Y., Chen, Y., Yu, L., Liu, Y., Liu, Y., Zhang, Y., Liu, Y. y Cheng, H. (2018b) Combining fractional order derivative and spectral variable selection for organic matter estimation of homogeneous soil samples by VIS–NIR spectroscopy. *Remote Sensing* **10**, 479. DOI:10.3390/rs10030479
- Houghton, R.A. (2007) Balancing the global carbon budget. *Annual Review of Earth and Planetary Sciences* **35**, 313-347. DOI:10.1146/annurev.earth.35.031306.140057
- Huang, A., Li, G., Fu, F. y Fei, B. (2008) Use of visible and near infrared spectroscopy to predict klason lignin content of bamboo, Chinese fir, Paulownia, and Poplar. *Journal of Wood Chemistry and Technology* **28**, 194-206. DOI:10.1080/02773810802347008
- Huang, X., Senthilkumar, S., Kravchenko, A., Thelen, K. y Qi, J. (2007) Total carbon mapping in glacial till soils using near-infrared spectroscopy, Landsat imagery and topographical information. *Geoderma* **141**, 34-42. DOI:10.1016/j.geoderma.2007.04.023
- Huang, X., Xu, Q.-S. y Liang, Y.-Z. (2012) PLS regression based on sure independence screening for multivariate calibration. *Analytical Methods* **4**, 2815-2821. DOI:10.1039/C2AY25032B

- Hummel, J.W., Sudduth, K.A. y Hollinger, S.E. (2001) Soil moisture and organic matter prediction of surface and subsurface soils using an NIR soil sensor. *Computers and Electronics in Agriculture* **32**, 149-165. DOI:10.1016/S0168-1699(01)00163-6
- Irons, J.R., Weismiller, R.A. y Petersen, G.W. (1989) Soil Reflectance. En 'Theory and Applications of Optical Remote Sensing.' (Ed. G. Asrar.) pp. 66–106 (John Wiley and Sons: New York, USA)
- Islam, K., Singh, B. y McBratney, A. (2003) Simultaneous estimation of several soil properties by ultra-violet, visible, and near-infrared reflectance spectroscopy. *Australian Journal of Soil Research* **41**, 1101-1114. DOI:10.1071/sr02137
- Jaber, S.M., Lant, C.L. y Al-Qinna, M.I. (2011) Estimating spatial variations in soil organic carbon using satellite hyperspectral data and map algebra. *International Journal of Remote Sensing* **32**, 5077-5103. DOI:10.1080/01431161.2010.494637
- Jackson, R.D. y Huete, A.R. (1991) Interpreting vegetation indices. *Preventive Veterinary Medicine* **11**, 185-200. DOI:10.1016/S0167-5877(05)80004-2
- Janik, L.J., Merry, R.H. y Skjemstad, J.O. (1998) Can mid infrared diffuse reflectance analysis replace soil extractions? *Australian Journal of Experimental Agriculture* **38**, 681-696. DOI:10.1071/ea97144
- Jarmer, T., Hill, J., Lavée, H. y Sarah, P. (2010) Mapping topsoil organic carbon in non-agricultural semi-arid and arid ecosystems of Israel. *Photogrammetric Engineering and Remote Sensing* **76**, 85-94. DOI:10.14358/PERS.76.1.85
- Jiang, Q.H., Chen, Y.Y., Guo, L., Fei, T. y Qi, K. (2016) Estimating Soil Organic Carbon of Cropland Soil at Different Levels of Soil Moisture Using VIS-NIR Spectroscopy. *Remote Sensing* **8**, 16. DOI:10.3390/rs8090755
- Jin, J. y Wang, Q. (2019) Evaluation of informative bands used in different PLS regressions for estimating leaf biochemical contents from hyperspectral reflectance. *Remote Sensing* **11**, DOI:10.3390/rs11020197
- Knicker, H. (2007) How does fire affect the nature and stability of soil organic nitrogen and carbon? A review. *Biogeochemistry* **85**, 91-118. DOI:10.1007/s10533-007-9104-4
- Knicker, H., Gonzalez-Vila, F.J., Polvillo, O., Gonzalez, J.A. y Almendros, G. (2005) Fire-induced transformation of C- and N-forms in different organic soil fractions from a Dystric Cambisol under a Mediterranean pine forest (*Pinus pinaster*). *Soil Biology & Biochemistry* **37**, 701-718. DOI:10.1016/j.soilbio.2004.09.008

- Kooistra, L., Wanders, J., Epema, G.F., Leuven, R.S.E.W., Wehrens, R. y Buydens, L.M.C. (2003) The potential of field spectroscopy for the assessment of sediment properties in river floodplains. *Analytica Chimica Acta* **484**, 189-200. DOI:10.1016/S0003-2670(03)00331-3
- Kowalski, B.R. (1980) Chemometrics. *Analytical Chemistry* **52**, 112R-122R. DOI:10.1021/ac50055a016
- Krishnan, P., Alexander, J.D., Butler, B.J. y Hummel, J.W. (1980) Reflectance Technique for Predicting Soil Organic Matter. *Soil Science Society of America Journal* **44**, 1282-1285. DOI:10.2136/sssaj1980.03615995004400060030x
- Kuhlbusch, T.A.J. y Crutzen, P.J. (1995) Toward a global estimate of black carbon in residues of vegetation fires representing a sink of atmospheric CO<sub>2</sub> and a source of O<sub>2</sub>. *Global Biogeochemical Cycles* **9**, 491-501. DOI:10.1029/95gb02742
- Lal, R. (2004) Soil carbon sequestration impacts on global climate change and food security. *Science* **304**, 1623-1627. DOI:10.1126/science.1097396
- Lal, R. (2009) Challenges and opportunities in soil organic matter research. *European Journal of Soil Science* **60**, 158-169. DOI:10.1111/j.1365-2389.2008.01114.x
- Lee, C.M., Cable, M.L., Hook, S.J., Green, R.O., Ustin, S.L., Mandl, D.J. y Middleton, E.M. (2015) An introduction to the NASA Hyperspectral InfraRed Imager (HyspIRI) mission and preparatory activities. *Remote Sensing of Environment* **167**, 6-19. DOI:10.1016/j.rse.2015.06.012
- Lee, K.S., Lee, D.H., Sudduth, K.A., Chung, S.O., Kitchen, N.R. y Drummond, S.T. (2009) Wavelength identification and diffuse reflectance estimation for surface and profile soil properties. *Transactions of the ASABE* **52**, 683-695. DOI:10.13031/2013.27385
- Li, B., Morris, J. y Martin, E.B. (2002) Model selection for partial least squares regression. *Chemometrics and Intelligent Laboratory Systems* **64**, 79-89. DOI:10.1016/S0169-7439(02)00051-5
- Liu, L., Ji, M. y Buchroithner, M. (2018) Transfer learning for soil spectroscopy based on convolutional neural networks and its application in soil clay content mapping using hyperspectral imagery. *Sensors* **18**, 3169. DOI:10.3390/s18093169
- Lu, P., Wang, L., Niu, Z., Li, L. y Zhang, W. (2013) Prediction of soil properties using laboratory VIS-NIR spectroscopy and Hyperion imagery. *Journal of Geochemical Exploration* **132**, 26-33. DOI:10.1016/j.gexplo.2013.04.003

- Luca, F., Conforti, M., Castrignano, A., Matteucci, G. y Buttafuoco, G. (2017) Effect of calibration set size on prediction at local scale of soil carbon by Vis-NIR spectroscopy. *Geoderma* **288**, 175-183. DOI:10.1016/j.geoderma.2016.11.015
- Madari, B.E., Reeves, J.B., Machado, P.L.O.A., Guimarães, C.M., Torres, E. y McCarty, G.W. (2006) Mid- and near-infrared spectroscopic assessment of soil compositional parameters and structural indices in two Ferralsols. *Geoderma* **136**, 245-259. DOI:10.1016/j.geoderma.2006.03.026
- Marquínez, J., Wozniak, E., Fernandez, S. y Martinez, R. (2008) Analysis of the evolution of soil erosion classes using multitemporal Landsat imagery. *International Journal of Wildland Fire* **17**, 549-558. DOI:10.1071/wf06138
- Martin, P.D., Malley, D.F., Manning, G. y Fuller, L. (2002) Determination of soil organic carbon and nitrogen at the field level using near-infrared spectroscopy. *Canadian Journal of Soil Science* **82**, 413-422. DOI:10.4141/S01-054
- Martínez-Murillo, J.F., Neris, J., Hyde, K. y Keizer, J.J. (2016) Advances towards an integrated assessment of fire effects on soils, vegetation and geomorphological processes. *Land Degradation & Development* **27**, 1314-1318. DOI:10.1002/ldr.2520
- Mataix-Solera, J. y Guerrero, C. (2007) Efectos de los incendios forestales en las propiedades edáficas. En 'Incendios Forestales, Suelos y Erosión Hídrica.' (Ed. J. Mataix-Solera.) pp. 5-40 (Caja Mediterráneo CEMACAM Font Roja-Alcoi: Alicante)
- McCarty, G.W., Reeves, J.B., Reeves, V.B., Follett, R.F. y Kimble, J.M. (2002) Mid-infrared and near-infrared diffuse reflectance spectroscopy for soil carbon measurement. *Soil Science Society of America Journal* **66**, 640-646. DOI:10.2136/sssaj2002.0640
- McMorrow, J.M., Cutler, M.E.J., Evans, M.G. y Al-Roichdi, A. (2004) Hyperspectral indices for characterizing upland peat composition. *International Journal of Remote Sensing* **25**, 313-325. DOI:10.1080/0143116031000117065
- Meini, M., Fossati, E., Giunti, L., Molina, M., Formaro, R., Longo, F. y Varacalli, G. (2015) 'The PRISMA mission hyperspectral payload, Proceedings of the 66th International Astronautical Congress (IAC 2015).' Jerusalem, Israel.
- Menéndez Duarte, R., Wozniak, E., Recondo, C., Cabo, C., Marquínez, J. y Fernández, S. (2008) Estimation of surface roughness and stone cover in burnt soils using SAR images. *Catena* **74**, 264-272. DOI:10.1016/j.catena.2008.05.003
- Metropolis, N. y Ulam, S. (1949) The Monte Carlo method. *Journal of the American Statistical Association* **44**, 335-341. DOI:10.1080/01621459.1949.10483310

- Michel, S., Gamet, P. y Lefevre-Fonollosa, M.J. (2011) 'HYPXIM - A hyperspectral satellite defined for science, security and defence users, 3rd Workshop on Hyperspectral Image and Signal Processing: Evolution in Remote Sensing (WHISPERS).' 6-9 June 2011.
- Milewski, R., Chabrillat, S., Brell, M., Schleicher, A.M. y Guanter, L. (2019) Assessment of the 1.75  $\mu\text{m}$  absorption feature for gypsum estimation using laboratory, air- and spaceborne hyperspectral sensors. *International Journal of Applied Earth Observation and Geoinformation* **77**, 69-83. DOI:10.1016/j.jag.2018.12.012
- Minasny, B., McBratney, A.B., Malone, B.P. y Wheeler, I. (2013) Digital mapping of soil carbon. En 'Advances in Agronomy, Vol 118.' (Ed. D.L. Sparks.) Vol. 118 pp. 1-47 (Elsevier Academic Press Inc: San Diego)
- Morgan, C.L.S., Waiser, T.H., Brown, D.J. y Hallmark, C.T. (2009) Simulated in situ characterization of soil organic and inorganic carbon with visible near-infrared diffuse reflectance spectroscopy. *Geoderma* **151**, 249-256. DOI:10.1016/j.geoderma.2009.04.010
- Mouazen, A.M., Kuang, B., De Baerdemaeker, J. y Ramon, H. (2010) Comparison among principal component, partial least squares and back propagation neural network analyses for accuracy of measurement of selected soil properties with visible and near infrared spectroscopy. *Geoderma* **158**, 23-31. DOI:10.1016/j.geoderma.2010.03.001
- Mouazen, A.M., Maleki, M.R., De Baerdemaeker, J. y Ramon, H. (2007) On-line measurement of some selected soil properties using a VIS-NIR sensor. *Soil and Tillage Research* **93**, 13-27. DOI:10.1016/j.still.2006.03.009
- Nanni, M.R. y Demattê, J.A.M. (2006) Spectral reflectance methodology in comparison to traditional soil analysis. *Soil Science Society of America Journal* **70**, 393-407. DOI:10.2136/sssaj2003.0285
- Nduwamungu, C., Ziadi, N., Tremblay, G.F. y Parent, L.-E. (2009) Near-infrared reflectance spectroscopy prediction of soil properties: effects of sample cups and preparation. *Soil Science Society of America Journal* **73**, 1896-1903. DOI:10.2136/sssaj2008.0213
- Neary, D.G., Klopatek, C.C., DeBano, L.F. y Ffolliott, P.F. (1999) Fire effects on belowground sustainability: A review and synthesis. *Forest Ecology and Management* **122**, 51-71. DOI:10.1016/S0378-1127(99)00032-8
- Nocita, M., Kooistra, L., Bachmann, M., Mueller, A., Powell, M. y Weel, S. (2011) Predictions of soil surface and topsoil organic carbon content through the use of laboratory and field spectroscopy in the Albany Thicket Biome of Eastern Cape Province of South Africa. *Geoderma* **167-68**, 295-302. DOI:10.1016/j.geoderma.2011.09.018

- Nocita, M., Stevens, A., van Wesemael, B., Aitkenhead, M., Bachmann, M., Barthès, B., Ben Dor, E., Brown, D.J., Clairrotte, M., Csorba, A., Dardenne, P., Demattê, J.A.M., Genot, V., Guerrero, C., Knadel, M., Montanarella, L., Noon, C., Ramirez-Lopez, L., Robertson, J., Sakai, H., Soriano-Disla, J.M., Shepherd, K.D., Stenberg, B., Towett, E.K., Vargas, R. y Wetterlind, J. (2015) Soil Spectroscopy: An Alternative to Wet Chemistry for Soil Monitoring. En 'Advances in Agronomy.' Vol. 132 pp. 139-159 (Academic Press:
- Novara, A., Gristina, L., Bodi, M.B. y Cerdà, A. (2011) The impact of fire on redistribution of soil organic matter on a mediterranean hillslope under maquia vegetation type. *Land Degradation & Development* **22**, 530-536. DOI:10.1002/ldr.1027
- Novara, A., Gristina, L., Rühl, J., Pasta, S., D'Angelo, G., La Mantia, T. y Pereira, P. (2013) Grassland fire effect on soil organic carbon reservoirs in a semiarid environment. *Solid Earth* **4**, 381-385. DOI:10.5194/se-4-381-2013
- Ogen, Y., Neumann, C., Chabrilat, S., Goldshleger, N. y Ben Dor, E. (2018) Evaluating the detection limit of organic matter using point and imaging spectroscopy. *Geoderma* **321**, 100-109. DOI:10.1016/j.geoderma.2018.02.011
- Okparanma, R.N. y Mouazen, A.M. (2013) Visible and Near-Infrared Spectroscopy Analysis of a Polycyclic Aromatic Hydrocarbon in Soils. *Scientific World Journal* DOI:10.1155/2013/160360
- Owen, T. (2000) 'Fundamentals of UV-visible Spectroscopy.' (Agilent Technologies: Germany)
- Patzold, S., Mertens, F.M., Bornemann, L., Koleczek, B., Franke, J., Feilhauer, H. y Welp, G. (2008) Soil heterogeneity at the field scale: a challenge for precision crop protection. *Precision Agriculture* **9**, 367-390. DOI:10.1007/s11119-008-9077-x
- Pearlman, J.S., Barry, P.S., Segal, C.C., Shepanski, J., Beiso, D. y Carman, S.L. (2003) Hyperion, a space-based imaging spectrometer. *IEEE Transactions on Geoscience and Remote Sensing* **41**, 1160-1173. DOI:10.1109/TGRS.2003.815018
- Peng, Y., Fan, M., Bai, L., Sang, W., Feng, J., Zhao, Z. y Tao, Z. (2019) Identification of the best hyperspectral indices in estimating plant species richness in sandy grasslands. *Remote Sensing* **11**, 588. DOI:10.3390/rs11050588
- Peng, Y., Xiong, X., Adhikari, K., Knadel, M., Grunwald, S. y Greve, M.H. (2015) Modeling Soil Organic Carbon at Regional Scale by Combining Multi-Spectral Images with Laboratory Spectra. *PLoS One* **10**, e0142295. DOI:10.1371/journal.pone.0142295

- Peón, J., Fernández, S., Recondo, C. y Calleja, J.F. (2017a) Evaluation of the spectral characteristics of five hyperspectral and multispectral sensors for soil organic carbon estimation in burned areas. *International Journal of Wildland Fire* **26**, 230-239. DOI:10.1071/WF16122
- Peón, J., Recondo, C., Fernández, S., Calleja, J.F., De Miguel, E. y Carretero, L. (2017b) Prediction of topsoil organic carbon using airborne and satellite hyperspectral imagery. *Remote Sensing* **9**, 1211. DOI:10.3390/rs9121211
- Recondo, C., Wozniak, E. y Pérez-Morandeira, C.S. (2007) Capítulo "Teledetección de incendios". En 'Impacto de los incendios forestales en Asturias. Análisis de los últimos 30 años.' (Eds M.A. Álvarez y J. Marquínez.) (KRK Ediciones: Oviedo)
- Recondo, C., Wozniak, E. y Pérez-Morandeira, C.S. E. Chuvieco, P. Martín y C. Justice (Eds) (2003) 'Map of burnt zones in Asturias in the period 1991-2001 created from Landsat-TM Images, Proceedings of the 4th workshop on remote sensing and GIS applications to forest fires management.' Ghent (Belgium).
- Reeves, J.B. y McCarty, G.W. (2001) Quantitative analysis of agricultural soils using near infrared reflectance spectroscopy and a fibre-optic probe. *Journal of Near Infrared Spectroscopy* **9**, 25-34. DOI:10.1255/jnirs.291
- Reeves, J.B., McCarty, G.W. y Meisinger, J.J. (1999) Near infrared reflectance spectroscopy for the analysis of agricultural soils. *Journal of Near Infrared Spectroscopy* **7**, 179-193. DOI:10.1255/jnirs.248
- Richards, J.A. (2013) 'Remote sensing digital image analysis. 5th edition.' (Berlin, Germany: Springer-Verlag)
- Richter, R. y Schlapfer, D. (2002) Geo-atmospheric processing of airborne imaging spectrometry data. Part 2: atmospheric/topographic correction. *International Journal of Remote Sensing* **23**, 2631-2649. DOI:10.1080/01431160110115834
- Rossello, P. y Baret, F. (2007) 'VALidation of Land European Remote sensing Instruments, CEOS/LPV-VALERI workshop.' Davos, Switzerland.
- Rouse, J.W., Haas, R.H., Schell, J.A. y Deering, D.W. (1973) 'Monitoring vegetation systems in the Great Plains with ERTS, 3rd Earth Resource Technology Satellite (ERTS) Symposium, NASA SP-351.' Washington DC, USA.
- Rumpel, C., Chaplot, V., Planchon, O., Bernadou, J., Valentin, C. y Mariotti, A. (2006) Preferential erosion of black carbon on steep slopes with slash and burn agriculture. *Catena* **65**, 30-40. DOI:10.1016/j.catena.2005.09.005

- Sagi, E. (2015) 'SHALOM – Spaceborne Hyperspectral Applciative Land and Ocean Mission, Proceedings of the 66th International Astronautical Congress (IAC 2015).' Jerusalem, Israel.
- Saiano, F., Oddo, G., Scalenghe, R., La Mantia, T. y Ajmone-Marsan, F. (2013) DRIFTS sensor: Soil carbon validation at large scale (Pantelleria, Italy). *Sensors* **13**, 5603-5613. DOI:10.3390/s130505603
- Salomonson, V.V., Barnes, W.L., Maymon, P.W., Montgomery, H.E. y Ostrow, H. (1989) MODIS: advanced facility instrument for studies of the Earth as a system. *Geoscience and Remote Sensing. IEEE Transactions on Geoscience and Remote Sensing* **27**, 145-153. DOI:10.1109/36.20292
- Sánchez Fanjul, J., 2013. Cartografía de zonas quemadas en Asturias entre los años 2009-2011 mediante imágenes Landsat. Proyecto Fin de Carrera de Ingeniería Técnica en Topografía. Directora: Carmen Recondo González. Escuela Politécnica de Mieres.
- Santín, C. y Doerr, S.H. (2016) Fire effects on soils: the human dimension. *Philosophical transactions of the Royal Society of London. Series B, Biological sciences* **371**, DOI:10.1098/rstb.2015.0171
- Santín, C. y Doerr, S.H. (2019) Carbon. En 'Fire effects on soil properties.' (Eds P. Pereira, J. Mataix-Solera, X. Úbeda, G. Rein y A. Cerdà.) pp. 115-128 (CSIRO Publishing: Australia)
- Santín, C., Knicker, H., Fernández, S., Menéndez-Duarte, R. y Álvarez, M.A. (2008) Wildfires influence on soil organic matter in an Atlantic mountainous region (NW of Spain). *Catena* **74**, 286-295. DOI:10.1016/j.catena.2008.01.001
- Savitzky, A. y Golay, M.J.E. (1964) Smoothing and Differentiation of Data by Simplified Least Squares Procedures. *Analytical Chemistry* **36**, 1627-1639. DOI:10.1021/ac60214a047
- Schlapfer, D. y Richter, R. (2002) Geo-atmospheric processing of airborne imaging spectrometry data. Part 1: parametric orthorectification. *International Journal of Remote Sensing* **23**, 2609-2630. DOI:10.1080/01431160110115825
- Schmidt, M.W.I. y Noack, A.G. (2000) Black carbon in soils and sediments: Analysis, distribution, implications, and current challenges. *Global Biogeochemical Cycles* **14**, 777-793. DOI:10.1029/1999gb001208
- Schulze, D.G., Nagel, J.L., Van Scoyoc, G.E., Henderson, T.L., Baumgardner, M.F. y Scott, D.E. (1993) Significance of organic matter in determining soil colors. En 'Soil color.' (Eds J.M. Bigham y E.J. Ciolkosz.) pp. 71–90 (Soil Science Society of America: Madison)
- Schulze, E.D., Wirth, C. y Heimann, M. (2000) Climate change - managing forests after Kyoto. *Science* **289**, 2058-2059. DOI:10.1126/science.289.5487.2058



- Schwanghart, W. y Jarmer, T. (2011) Linking spatial patterns of soil organic carbon to topography - A case study from south-eastern Spain. *Geomorphology* **126**, 252-263. DOI:10.1016/j.geomorph.2010.11.008
- Selige, T., Boehner, J. y Schmidhalter, U. (2006) High resolution topsoil mapping using hyperspectral image and field data in multivariate regression modeling procedures. *Geoderma* **136**, 235-244. DOI:10.1016/j.geoderma.2006.03.050
- Šestak, I., Mihaljevski Boltek, L., Mesić, M., Zgorelec, Z. y Perčin, A. (2019) Hyperspectral sensing of soil pH, total carbon and total nitrogen content based on linear and non-linear calibration methods. *Journal of Central European Agriculture* **20**, 504-523. DOI:10.5513/JCEA01/20.1.2158
- Shakesby, R.A. y Doerr, S.H. (2006) Wildfire as a hydrological and geomorphological agent. *Earth-Science Reviews* **74**, 269-307. DOI:10.1016/j.earscirev.2005.10.006
- Shapiro, S.S. y Wilk, M.B. (1965) An analysis of variance test for normality (complete samples). *Biometrika* **52**, 591-611. DOI:10.1093/biomet/52.3-4.591
- Skjemstad, J.O., Janik, L.J. y Taylor, J.A. (1998) Non-living soil organic matter: What do we know about it? *Australian Journal of Experimental Agriculture* **38**, 667-680. DOI:10.1071/EA97143
- Smith, P., Gottschalk, P. y Smith, J. (2014) Climate change and soil carbon impacts. En 'Soil carbon: Science, management and policy for multiple benefits.' (Eds S.A. Banwart, E. Noellemeyer y E. Milne.) pp. 235-242 (CABI: London)
- Soriano-Disla, J.M., Janik, L.J., Rossel, R.A.V., Macdonald, L.M. y McLaughlin, M.J. (2014) The performance of visible, near-, and mid-infrared reflectance spectroscopy for prediction of soil physical, chemical, and biological properties. *Applied Spectroscopy Reviews* **49**, 139-186. DOI:10.1080/05704928.2013.811081
- Sreenivas, K., Dadhwal, V.K., Kumar, S., Harsha, G.S., Mitran, T., Sujatha, G., Suresh, G.J.R., Fyzee, M.A. y Ravisankar, T. (2016) Digital mapping of soil organic and inorganic carbon status in India. *Geoderma* **269**, 160-173. DOI:10.1016/j.geoderma.2016.02.002
- St. Luce, M., Ziadi, N., Nyiraneza, J., Tremblay, G.F., Zebarth, B.J., Whalen, J.K. y Laterriere, M. (2012) Near infrared reflectance spectroscopy prediction of soil nitrogen supply in humid temperate regions of Canada. *Soil Science Society of America Journal* **76**, 1454-1461. DOI:10.2136/sssaj2011.0443
- Steinberg, A., Chabrillat, S., Stevens, A., Segl, K. y Foerster, S. (2016) Prediction of common surface soil properties based on Vis-NIR airborne and simulated EnMAP imaging spectroscopy data:

- Prediction accuracy and influence of spatial resolution. *Remote Sensing* **8**, 613. DOI:10.3390/rs8070613
- Stenberg, B., Viscarra Rossel, R.A., Mouazen, A.M. y Wetterlind, J. (2010) Visible And Near Infrared Spectroscopy In Soil Science. En 'Advances in Agronomy, Vol 107.' (Ed. D.L. Sparks.) Vol. 107 pp. 163-215
- Stevens, A., Miralles, I. y van Wesemael, B. (2012) Soil organic carbon predictions by airborne imaging spectroscopy: Comparing cross-validation and validation. *Soil Science Society of America Journal* **76**, 2174-2183. DOI:10.2136/sssaj2012.0054
- Stevens, A., Udelhoven, T., Denis, A., Tychon, B., Liroy, R., Hoffmann, L. y van Wesemael, B. (2010) Measuring soil organic carbon in croplands at regional scale using airborne imaging spectroscopy. *Geoderma* **158**, 32-45. DOI:10.1016/j.geoderma.2009.11.032
- Stevens, A., van Wesemael, B., Bartholomeus, H., Rosillon, D., Tychon, B. y Ben-Dor, E. (2008) Laboratory, field and airborne spectroscopy for monitoring organic carbon content in agricultural soils. *Geoderma* **144**, 395-404. DOI:10.1016/j.geoderma.2007.12.009
- Stevens, A., van Wesemael, B., Vandenschrick, G., Toure, S. y Tychon, B. (2006) Detection of carbon stock change in agricultural soils using spectroscopic techniques. *Soil Science Society of America Journal* **70**, 844-850. DOI:10.2136/sssaj2005.0025
- Stoner, E.R. y Baumgardner, M.F. (1981) Characteristic variations in reflectance of surface soils. *Soil Science Society of America Journal* **45**, 1161-1165. DOI:10.2136/sssaj1981.03615995004500060031x
- Tanii, J., Ito, Y. y Iwasaki, A. (2014) 'Instrument development status and performances of hyperspectral imager suite (HISUI) - Onboard data correction, 2014 IEEE Geoscience and Remote Sensing Symposium.' 13-18 July 2014.
- Tao, C., Wang, Y., Cui, W., Zou, B., Zou, Z. y Tu, Y. (2019) A transferable spectroscopic diagnosis model for predicting arsenic contamination in soil. *Science of the Total Environment* **669**, 964-972. DOI:10.1016/j.scitotenv.2019.03.186
- Tekin, Y., Tumsavas, Z. y Mouazen, A.M. (2012) Effect of moisture content on prediction of organic carbon and ph using visible and near-infrared spectroscopy. *Soil Science Society of America Journal* **76**, 188-198. DOI:10.2136/sssaj2011.0021
- Tessier, A., Campbell, P.G.C. y Bisson, M. (1979) Sequential extraction procedure for the speciation of particulate trace-metals. *Analytical Chemistry* **51**, 844-851. DOI:10.1021/ac50043a017

- Theesfeld, I. y Jelinek, L. (2017) A misfit in policy to protect Russia's black soil region. An institutional analytical lens applied to the ban on burning of crop residues. *Land Use Policy* **67**, 517-526. DOI:10.1016/j.landusepol.2017.06.018
- Trumbore, S.E. y Czimczik, C.I. (2008) An Uncertain Future for Soil Carbon. *Science* **321**, 1455. DOI:10.1126/science.1160232
- Úbeda, X. y Outeiro, L.R. (2009) Physical and Chemical Effects of Fire on Soil. En 'Fire Effects on Soils and Restoration Strategies.' (Eds A. Cerdà y P.R. Robichaud.) pp. 105-132 (Science Publishers. CRC Press: Boca Raton, Florida)
- Uno, Y., Prasher, S.O., Patel, R.M., Strachan, I.B., Pattey, E. y Karimi, Y. (2005) Development of field-scale soil organic matter content estimation models in Eastern Canada using airborne hyperspectral imagery. *Canadian Biosystems Engineering / Le Genie des biosystems au Canada* **47**, 9-14.
- Vågen, T.-G., Winowiecki, L.A., Tondoh, J.E., Desta, L.T. y Gumbrecht, T. (2016) Mapping of soil properties and land degradation risk in Africa using MODIS reflectance. *Geoderma* **263**, 216-225. DOI:10.1016/j.geoderma.2015.06.023
- Vasques, G.M., Grunwald, S. y Sickman, J.O. (2008) Comparison of multivariate methods for inferential modeling of soil carbon using visible/near-infrared spectra. *Geoderma* **146**, 14-25. DOI:10.1016/j.geoderma.2008.04.007
- Vasques, G.M., Grunwald, S. y Sickman, J.O. (2009) Modeling of soil organic carbon fractions using visible-near-infrared spectroscopy. *Soil Science Society of America Journal* **73**, 176-184. DOI:10.2136/sssaj2008.0015
- Vaudour, E., Gilliot, J.M., Bel, L., Lefevre, J. y Chehdi, K. (2016) Regional prediction of soil organic carbon content over temperate croplands using visible near-infrared airborne hyperspectral imagery and synchronous field spectra. *International Journal of Applied Earth Observation and Geoinformation* **49**, 24-38. DOI:10.1016/j.jag.2016.01.005
- Venables, W.N. y Ripley, B.D. (2002) 'Modern Applied Statistics with S. Fourth edition.' (Springer:
- Vinogradov, B.V. (1981) Remote sensing of the humus content of soils. *Soviet Soil Science* **11**, 114-123.
- Viscarra Rossel, R.A. (2007) Robust modelling of soil diffuse reflectance spectra by "bagging-partial least squares regression". *Journal of Near Infrared Spectroscopy* **15**, 39-47. DOI:10.1255/jnirs.694

- Viscarra Rossel, R.A. (2008) ParLeS: Software for chemometric analysis of spectroscopic data. *Chemometrics and Intelligent Laboratory Systems* **90**, 72-83. DOI:10.1016/j.chemolab.2007.06.006
- Viscarra Rossel, R.A. y Behrens, T. (2010) Using data mining to model and interpret soil diffuse reflectance spectra. *Geoderma* **158**, 46-54. DOI:10.1016/j.geoderma.2009.12.025
- Viscarra Rossel, R.A., Jeon, Y.S., Odeh, I.O.A. y McBratney, A.B. (2008) Using a legacy soil sample to develop a mid-IR spectral library. *Soil Research* **46**, 1-16. DOI:10.1071/SR07099
- Viscarra Rossel, R.A., Minasny, B., Roudier, P. y McBratney, A.B. (2006a) Colour space models for soil science. *Geoderma* **133**, 320-337. DOI:10.1016/j.geoderma.2005.07.017
- Viscarra Rossel, R.A., Walvoort, D.J.J., McBratney, A.B., Janik, L.J. y Skjemstad, J.O. (2006b) Visible, near infrared, mid infrared or combined diffuse reflectance spectroscopy for simultaneous assessment of various soil properties. *Geoderma* **131**, 59-75. DOI:10.1016/j.geoderma.2005.03.007
- Vohland, M., Besold, J., Hill, J. y Fründ, H.-C. (2011) Comparing different multivariate calibration methods for the determination of soil organic carbon pools with visible to near infrared spectroscopy. *Geoderma* **166**, 198-205. DOI:10.1016/j.geoderma.2011.08.001
- Walkley, A. y Black, I.A. (1934) An examination of the Degtjareff method for determining soil organic matter, and a proposed modification of the chromic acid titration method. *Soil Science* **37**, 29-38. DOI:10.1097/00010694-193401000-00003
- Wang, C., Wang, G., Wang, Y., Rafique, R., Ma, L., Hu, L. y Luo, Y. (2015) Fire alters vegetation and soil microbial community in alpine meadow. *Land Degradation & Development* DOI:10.1002/ldr.2367
- Wang, X., Zhang, F., Kung, H. y Johnson, V.C. (2018) New methods for improving the remote sensing estimation of soil organic matter content (SOMC) in the Ebinur Lake Wetland National Nature Reserve (ELWNNR) in northwest China. *Remote Sensing of Environment* **218**, 104-118. DOI:10.1016/j.rse.2018.09.020
- Wold, S., Sjöström, M. y Eriksson, L. (2001) PLS-regression: a basic tool of chemometrics. *Chemometrics and Intelligent Laboratory Systems* **58**, 109-130. DOI:10.1016/S0169-7439(01)00155-1
- Wondzell, S.M. y King, J.G. (2003) Postfire erosional processes in the Pacific Northwest and Rocky Mountain regions. *Forest Ecology and Management* **178**, 75-87. DOI:10.1016/s0378-1127(03)00054-9

- Yu, H., Kong, B., Wang, G., Du, R. y Qie, G. (2018) Prediction of soil properties using a hyperspectral remote sensing method. *Archives of Agronomy and Soil Science* **64**, 546-559. DOI:10.1080/03650340.2017.1359416
- Yu, X., Liu, Q., Wang, Y.B., Liu, X.Y. y Liu, X. (2016) Evaluation of MLSR and PLSR for estimating soil element contents using visible/near-infrared spectroscopy in apple orchards on the Jiaodong peninsula. *Catena* **137**, 340-349. DOI:10.1016/j.catena.2015.09.024
- Zhang, T., Li, L. y Zheng, B. (2013) Estimation of agricultural soil properties with imaging and laboratory spectroscopy. *Journal of Applied Remote Sensing* **7**, 73587. DOI:10.1117/1.JRS.7.073587
- Zhang, Z., Ding, J. y Wang, J. (2019) Spectral characteristics of oasis soil in arid area based on harmonic analysis algorithm. *Acta Optica Sinica* **39**, 0228003. DOI:10.3788/AOS201939.0228003



## Financiación

La realización de esta tesis ha sido posible gracias al apoyo económico recibido del proyecto de investigación y de las ayudas predoctorales que se indican a continuación.

Proyecto de investigación:

- Monitoreo del stock de carbono orgánico edáfico en suelos afectados por incendios forestales. Integración de imágenes de satélite, espectroscopía NIR, datos de campo y laboratorio. Entidad financiadora: Gobierno del Principado de Asturias. Investigador principal: Susana del Carmen Fernández Menéndez. Referencia: SV-PA-13-ECOEMP-40.

Ayudas predoctorales del autor de la tesis:

- Ayuda para la formación en investigación y docencia en la Universidad de Oviedo. Convocatoria 2013 para la selección de alumnos predoctorales. Organismo que la concede: Universidad de Oviedo. Periodo de disfrute: desde 01-01-2014 hasta 27-11-2014.
- Ayuda predoctoral “Severo Ochoa” para la formación en investigación y docencia del Principado de Asturias en el año 2014. Plan de Ciencia, Tecnología e Innovación del Principado de Asturias. Organismo que la concede: Gobierno del Principado de Asturias. Periodo de disfrute: desde 28-11-2014 hasta 31-08-2015. Referencia: BP14-104.
- Ayuda para la Formación de Profesorado Universitario “FPU”. Programa Estatal de Promoción del Talento y su Empleabilidad. Plan Estatal de Investigación Científica y Técnica y de Innovación 2013-2016 en I+D+i. Organismo que la concede: Ministerio de Educación, Cultura y Deporte; Gobierno de España. Periodo de disfrute: desde 01-09-2015 hasta 31-12-2017. Referencia: FPU14/01350.

